

بهینه سازی سیستم جامع تشخیص خطای سنسورهای توربین گاز

مدل V94.2 بواسطه KPCA-MLP

سعید فلاح

دانشجوی کارشناسی ارشد مهندسی کنترل

دانشگاه آزاد اسلامی واحد مشهد

مشهد مقدس، ایران

Calibronic@yahoo.com

نادر سرگلزایی

استادیار گروه کنترل - دانشکده فنی و مهندسی

دانشگاه آزاد اسلامی واحد مشهد

مشهد مقدس، ایران

Nader.Sargol@yahoo.com

واژه‌های کلیدی — توربین گاز V94.2؛ الگوریتم KPCA؛ تشخیص

خطا؛ ترموفلو

۱. مقدمه

امروزه توربین های گاز با سوخت طبیعی، سوخت دیزل، گازهای زیست توده و غیره کار می کنند. بخاطر ابعاد محدود، وزن کم و دو یا چندگانگی سوخت مصرفی، بعنوان نیروگاه های مناسب برای جایگاه های نصب شده در خشکی و دور از آبی شناخته شده اند [۱].

با این اوصاف استفاده از توربین های گاز در صنعت برق ایران نیز گسترش روز افزونی یافته است. این مسئله اهمیت حفظ و نگهداری بهینه آنها و جلوگیری از بروز هرگونه اختلال در عملکرد این سیستمها را به وضوح روشن می نماید. با توجه به هزینه بالای آن، تشخیص به موقع عیوب این سیستمها قبل از وقوع هر گونه اتفاق ناگواری می تواند بسیار مهم باشد، در نتیجه تشخیص خطاهای موجود در یک سیستم می تواند از وقوع حوادث پرهزینه و خطرناک جلوگیری کند [۲]. در واقع تشخیص خطا دو کاربرد مهم دارد، یکی واکنش نشان دادن نسبت به خرابی های ناگهانی و دیگری نشان دادن فرسودگی ها و خرابی هایی است که به صورت آهسته رخ می دهد.

داده های مربوط به پارامترهای توربین گاز که بیشتر دماها و فشارها بودند توسط نرم افزار ترموفلو برای یک رنج وسیعی از عملکرد تولید گردیدند. شبیه سازی خطای سنسورها با اضافه نمودن سطوح مختلفی از نویز به هر پارامتر

چکیده — در این مقاله، یک سیستم جامع تشخیص خطا مبتنی برافزونی تحلیل برای سنسورهای توربین گاز مدل V94.2(3) در داخل کشور توسعه داده شده است. روش ارائه شده بر پایه آموزش شبکه های عصبی مصنوعی طبقه بندی کننده و الگوریتم Kernel PCA برای تشخیص خطا سنسورهای توربین گاز می باشد.

این سیستم تشخیص خطا، بروز هر گونه تغییر و همچنین میزان انحراف آنها را از وضعیت سالم سنسورها آشکار سازی می کند. بدلیل ارتفاع متفاوت از سطح دریا در محل نصب هر نیروگاه، یک سیستم تشخیص خطا تنها می تواند برای شرایط محیطی مشخصی طراحی شده باشد پس هر سیستم تشخیص خطایی که برای یک نیروگاه طراحی می شود قابل استفاده برای نیروگاه های دیگر از همان مدل نمی باشد. در این مقاله برآن شدیم تا برای اولین بار یک سیستم تشخیص خطای یکپارچه و جامع برای سه نقطه مختلف کشور که بیشترین اختلاف را از لحاظ ارتفاع از سطح دریا نسبت به هم دارند طراحی کنیم و همچنین سعی شده است که این سه نقطه، نقاطی باشند که بیشترین توربین های گاز V94.2 در این مناطق نصب شده اند، تا بتوان این سیستم را بصورت جامع در کشور مورد استفاده قرار داد. نتایج نشان می دهد که این روش قادر به تشخیص زود هنگام خطای سنسور توربین گاز V94.2(3) بصورت جامع می باشد و استفاده از شبکه های عصبی مصنوعی و الگوریتم KPCA برای تأیید سنسور می تواند به نگهداری مقرون به صرفه و همچنین افزایش دسترسی و قابلیت اطمینان نیروگاه کمک کند.

و در شناخت خطاهای مکانیکی سریع عمل می‌کنند ولی از مشکلات عمده ای که افزونگی سخت افزار با آن مواجه می‌شود تجهیزات اضافی، هزینه تعمیر و نگهداری و همچنین فضای اضافی برای قرارگیری تجهیزات می‌باشد.

۳.۲. روش افزونگی تحلیلی

به دلیل هزینه زیاد و دیگر مشکلات روش اول، روش تشخیص با استفاده از افزونگی تحلیلی مطرح گردید که خود به دو روش مبتنی بر مدل و مبتنی بر داده طبقه بندی می‌شود. در روش افزونگی تحلیلی مبتنی بر مدل بیشتر برای سیستم های خطی توسعه داده شده است و قابلیت استفاده در سیستم های غیر خطی را نیز دارد. هر چند بر پایه مدل سیستم بنا شده و نمی‌توان آن را با استفاده از داده های عملکردی ایجاد نمود. موفقیت افزونگی تحلیلی مبتنی بر مدل برای اعتبار سنجی سنسورها به صحت سیستم یا اجزاء مدل وابسته است [۵]. روش هایی مانند فیلتر کالمن، رویت گرها، معادلات ترازنی و ... از جمله این روشها هستند.

در سیستم های افزونگی تحلیلی مبتنی بر داده علاوه بر اینکه جهت مدلسازی سیستم های غیرخطی کاربرد دارند، قابلیت توسعه با استفاده از داده های عملکردی بدون نیاز به دانستن مدل را نیز دارند. علاوه بر آن نیازمند دانش خاصی از سیستم و فرآیند نمی باشند، به همین دلیل برای تشخیص خطای فرآیندهای پیچیده که شناخت درستی از نحوه عملکردشان موجود نیست و قابل مدلسازی نیستند این روش بهترین گزینه است. به عنوان مثالی از این روش ها، می‌توان به سیستم های خبره، سیستم های فازی، آنالیز مولفه های اصلی (PCA)، شبکه های عصبی و غیره اشاره کرد. شکل ۱ بلوک دیاگرام یک سیستم افزونگی تحلیلی مبتنی بر داده نشان می‌دهد.

ورودی شبکه عصبی انجام گردید. در نتیجه یک شبکه عصبی طبقه بندی کننده برای آشکار سازی سنسورهای معیوب آموزش داده شده است.

روش مطرح شده برای پیاده سازی یک سیستم جامع تشخیص خطا برای توربین های گازی مدل (3)V94.2 گسترش یافت بدین ترتیب که در ابتدا ۳ نیروگاه از نقاط مختلف کشور که بیشترین فاصله از سطح دریا را نسبت به یکدیگر داشتند انتخاب شدند (نیروگاه گازی شیروان، نیروگاه گازی اصفهان و نیروگاه گازی سنندج) سپس در بار و دمای محیط مختلف داده های آنها استخراج گردید و این داده ها توسط الگوریتم KPCA جهت استخراج ویژگی های مهم، کاهش بعد یافتند و از این داده های کاهش بعد یافته، برای آموزش یک شبکه عصبی جامع جهت تشخیص انحرافات مثبت و منفی سنسورهای مورد ارزیابی، استفاده شدند.

۲. توربین گازی V94.2

توربین گاز V94.2 یک توربین تک محوره است که سیال عاملش هوا بوده که توسط یک کمپرسور ۱۶ مرحله ای متراکم می‌گردد. سوخت در دو محفظه احتراق با هوا ترکیب گردیده و محترق می‌گردد داغ با دمای تقریبی ۱۱۰۰ درجه سانتیگراد وارد توربین می‌گردد و با عبور از ۴ ردیف پره توربین منبسط شده و با فشار اتمسفر در محیط تخلیه می‌گردد [۳]. توربین های گازی V94.2 علاوه بر میزان سوخت که توسط کنترل ولو کنترل می‌گردد قادر می‌باشند که هوای ورودی به کمپرسور را توسط یک دریچه کنترلی که IGV نامیده می‌شود کنترل نمایند این دریچه به گونه ای است که در استارت واحد تا بار حداقل در مینیمم موقعیت خود قرار داشته و در حداکثر بار توربین نیز در ماکزیمم موقعیت خود جهت تنظیم دمای خروجی توربین گاز قرار گیرد

۳. روشهای تشخیص خطا

تشخیص خطا در واقع حاصل یک مقایسه است و این مقایسه در بحث آشکارسازی قاعداً باید بین سیستم مورد بررسی و یک سیستم سالم صورت گیرد. روش های تشخیص خطا را در حالت کلی می‌توان به دو روش افزونگی سخت افزاری و افزونگی تحلیلی طبقه بندی نمود.

۳.۱ روش افزونگی سخت افزار

در این حالت، داده های یک سنسور با داده های تعداد بیشتری از همان نوع سنسور مقایسه می‌شود و در روشی که به رای گیری مشهور است وجود خطا مشخص می‌شود [۴]. روش های رای گیری به راحتی قابل اجرا هستند

از روش گرادیان نزولی حاصل می شود که بیان می کند با حرکت های پی در پی خلاف جهت بردار گرادیان خطا، می توان به نقطه حداقل خطا رسید.

۵. آنالیز مولفه های اصلی مبتنی بر هسته

در حالت کلی می توان روش های کاهش ابعاد و استخراج ویژگی را به دو دسته روش خطی و غیرخطی تقسیم نمود. روش های PCA و KPCA دو روشی هستند که به ترتیب برای استخراج ویژگی از داده های خطی و غیر خطی مورد استفاده قرار می گیرند. اگر داده های بصورت غیر خطی باشند الگوریتم KPCA که تعمیم یافته روش PCA برای داده های غیر خطی است مورد استفاده قرار می گیرد. تکنیک اصلی KPCA محاسبه تبدیل PCA در فضای نگاشت یافته توسط یک تابع نگاشت غیرخطی است که از ایده هسته برای تخمین این نگاشت استفاده می شود [۹].

داده های نگاشت یافته $\varphi(x_1), \dots, \varphi(x_2)$ را در نظر بگیرید که میانگین آن ها صفر نباشد. ابتدا با رابطه ی (۴) میانگین داده های نگاشت یافته صفر می شود:

$$\hat{\varphi}(X_k) = \varphi(X_k) - \frac{1}{N} \sum_{i=1}^N \varphi(X_i) \quad (4)$$

ماتریس کوواریانس از رابطه (۵) محاسبه می شود:

$$\hat{\Sigma} = \frac{1}{N} \sum_{i=1}^N \hat{\varphi}(X_j) \hat{\varphi}(X_j)^T \quad (5)$$

معادله مقادیر ویژه برای ماتریس کوواریانس فوق بصورت $\hat{\Sigma} \hat{\nu} = \lambda \hat{\nu}$ می باشد. که $\lambda \geq 0$ مقادیر ویژه و $\hat{\nu} \in F\{0\}$ به معنی F به استثنای {0} بردار ویژه می باشند. معادله مقادیر ویژه را می توان به صورت رابطه (۶) نوشت:

$$\hat{\lambda}(\hat{\varphi}(X_j) \cdot \hat{\nu}) = (\hat{\varphi}(X_k) \cdot \hat{\Sigma} \hat{\nu}) \quad k = 1, \dots, N \quad (6)$$

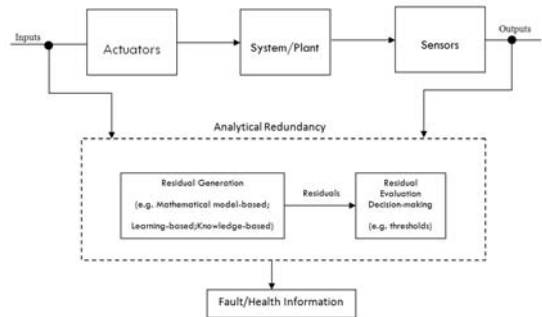
$\hat{\alpha}_k$ ها ضرایبی هستند که مقادیر آن ها به گونه ای انتخاب می شوند که رابطه (۷) برقرار باشد:

$$\hat{\nu} = \sum_{k=1}^N \hat{\alpha}_k \hat{\varphi}(X_k) \quad (7)$$

که با جایگزاری رابطه (۷) در رابطه (۶) خواهیم داشت:

$$\hat{\lambda} \alpha = K \alpha, \quad \alpha = \alpha_1, \alpha_2, \dots, \alpha^T \quad (8)$$

که K ماتریس هسته بوده و به صورت ماتریس مربعی $N \times N$ با عناصر K_{ij} که $(\varphi(X_i), \varphi(X_j)) = K(X_i, X_j)$ می باشد. برای نرمال سازی راه حل های (α_k, α^k) ، بایستی رابطه $\lambda_k(\alpha_k, \alpha^k) = 1$ در فضای نگاشت یافته اعمال



شکل ۱: بلوک دیاگرام سیستم تشخیص خطا مبتنی بر افزونگی تحلیلی (داده)

۴. شبکه عصبی پرسپترون

شبکه های MLP قابلیت نگاشت جامع را دارا می باشند. این ویژگی به این معنا است که یک شبکه MLP با یک لایه پنهان می تواند هر رابطه بین خروجی ورودی را با شرط وجود تعداد به اندازه کافی بزرگ نرون را تخمین بزند، این موضوع توسط Cybenko [۶] نشان داده شده است. قابلیت آموزش لایه های پنهان با استفاده از روش Back-Propagation امکان پذیر می شود. این روش یک باز فرمول نویسی قانون زنجیره ای در محیط حساب دیفرانسیل است. روش Back-Propagation اولین بار توسط Werbos [۷] ابداع شد اما توسط Rumelhart [۸] به صورت عمومی درآمد. این روش را می توان در شبکه های طبقه بندی کننده و یا شبکه های رگرسیون استفاده نمود. این الگوریتم مهمترین و پرکاربردترین تکنیک بهینه یابی در آموزش شبکه های عصبی محسوب می شود که در سال ۱۹۸۶ توسط راهمات و مکند مطرح شد. نام پس انتشار خطای یادگیری با توجه به اینکه خطای محاسبه شده از لایه خروجی به لایه میانی و نهایتاً به لایه ورودی بازگشت داده می شود، انتخاب شده است. پس از آموزش شبکه عصبی از داده های آزمایش (تصدیق) به منظور بررسی میزان جامعیت شبکه عصبی و انتخاب بهترین شبکه آموزش دیده استفاده می شود. الگوریتم پس انتشارخطا را می توان تعمیم یافته قانون دلتا نامید. روابط ۱ تا ۳ نحوه محاسبه وزن های شبکه بر اساس این قانون را نشان می دهد:

$$e_k = y_k^{real} - y_k^{predict} \quad (1)$$

$$\Delta w_t = \eta e_k p_{kj} \quad (2)$$

$$w_{t+1} = w_t + \Delta w_t \quad (3)$$

در روابط فوق، η ، e_k ، w و p_{kj} به ترتیب نشان دهنده نرخ یادگیری، خطای مشاهده شده و وزن مربوط به اتصال نرون k و j می باشد. اثبات قانون فوق

جدول ۳: مشخصات ارتفاع و توان نامی خروجی ۳ نیروگاه مورد بررسی

نیروگاه	دمای ISO	ارتفاع از سطح دریا	توان خروجی
شیروان	15 c	1115 m	136.9 MW
اصفهان	15 c	1748 m	124.7 MW
سنندج	15 c	1480 m	134 MW

۷. تولید و آماده‌سازی داده‌ها

در این مقاله شبکه عصبی طبقه‌بندی کننده جهت بررسی عملکرد سنسورهای جدول ۲ پیکربندی شده است:

جدول ۲: پارامترهای انتخابی

Parameters	Range	Unit
Ambient Temp	±25	°C
Compressor Mass Flow	9.397	Kg/s
Compressor Outlet Press	11.4	bar
Compressor Outlet Temp	331.2	°C
Exhaust Temp	542	°C
Fuel Mass Flow	9.397	Kg/s
Power	159	MW
Turbine Outlet Press	1.013	bar

در این طرح ۱۷ کلاس خروجی وجود دارد به گونه‌ای که برای مثال یک کلاس سالم شامل تنها داده‌های سالم سنسورها هستند. هر سنسور که معادل یک پارامتر است (مانند خروجی فشار کمپرسور) به دو کلاس تخصیص داده می‌شود، یکی برای مقدار مثبت انحراف سنسور و دیگری برای مقدار منفی انحراف سنسور. این نگرش دو مزیت دارد، اول آنکه اطلاعات در مورد انحراف فراهم می‌شود و مزیت دیگر این است که قابلیت طبقه‌بندی شبکه عصبی در مقایسه باحالتی که هر دو انحرافات مثبت و منفی سنسور در یک کلاس ترکیب می‌شوند، بهبود می‌یابد.

در این مقاله داده‌های شبیه‌سازی به جای داده‌های عملی انتخاب شده‌اند تا شرایط بهینه‌ای به وجود آید که بتوان استفاده از روش پیشنهادی مورد ارزیابی قرار گیرد. داده‌های شبیه‌سازی را می‌توان در بازه‌های مطلوب و همچنین با دقت مناسبی برای آموزش شبکه عصبی تولید کرد و همچنین در این حالت تأثیرات ناخواسته ماشین بر روند آموزش نیز حذف می‌شود. برای آنکه شرایط کاری مختلف را شبیه‌سازی کنیم داده‌ها برای بارها و دمای محیطی مختلف تولید شدند. فشار محیط و رطوبت نسبی هر نیروگاه بطور جداگانه از مستندات تست

شود. هم چنین، همانند هر الگوریتم PCA دیگری، دادگان در فضای نگاشت یافته باید متمرکز شوند. برای این کار ماتریس هسته با رابطه زیر جایگزین می‌شود:

$$\tilde{K} = K - 1_N K - K 1_N + 1_N K 1_N \quad (9)$$

که $(1_N)_{i,j} = 1/N$ می‌باشد. (شولوخف و همکاران ۱۹۹۸)

۶. طراحی یک سیستم تشخیص خطای جامع

با توجه به اینکه توان خروجی هر توربین گاز به ارتفاع از سطح دریا و دمای محیط وابستگی زیادی دارد می‌توان استنباط کرد که هر سیستم تشخیص خطایی که برای یک نیروگاه با ارتفاع از سطح دریا مشخص طراحی می‌شود قابل استفاده برای نیروگاه‌های دیگر با ارتفاع متفاوت از همان مدل نمی‌باشد. از آنجایی که این نوع از توربین‌های گاز V94.2 در کشور به طور وسیعی مورد استفاده قرار گرفته‌اند در این مقاله سیستم تشخیص خطا برای سه نقطه شرق، غرب و مرکز کشور آموزش دیده شده که به صورت جامع و یکپارچه طراحی گردیده است تا این سیستم قابلیت استفاده برای مناطق مختلفی در کشور را داشته باشد. نیروگاه‌های مورد بررسی در این مقاله نیروگاه گازی شیروان، نیروگاه گازی اصفهان و نیروگاه گازی سنندج می‌باشد که سعی شده است نیروگاه‌هایی را مورد بررسی قرار دهیم که بیشترین اختلاف نسبت به هم از سطح دریا را دارند. در جدول ۱ خلاصه‌ای از مشخصات این سه نیروگاه مشاهده می‌شود:

جدول ۱: مشخصات ۳ نیروگاه مورد بررسی

نیروگاه	مدل و نوع توربین	تعداد واحد	ظرفیت کل
شیروان	V94.2 (3)	6×159	954 MW
اصفهان	V94.2 (3)	6×159	954 MW
سنندج	V94.2 (3)	4×159	636 MW

با توجه به اینکه توان اسمی توربینهای گاز V94.2(3) در شرایط ISO معادل 159MW می‌باشد این توان نسبت به محل نصب نیروگاه تغییر می‌کند. در جدول ۳ مشخصات توان خروجی هر سه نیروگاه در شرایط دمای ISO نشان داده شده است:

Power	±1	%0.65	MW
Turbine Outlet Press	±0.01	%0.97	Bar

کارایی (Performance Test) استخراج و بر اساس آنها مراحل نمونه برداری داده های سالم انجام گردید. در جدول شماره ۳ این مشخصات نشان داده شده است :

جدول ۳: مشخصات هر نیروگاه از مستندات Performance Test

نیروگاه	ارتفاع از سطح دریا	فشار محیط	رطوبت نسبی
شیروان	1115 m	0.8863 bar	56%
اصفهان	1748 m	0.82 bar	40%
سندج	1480 m	0.8476 bar	50.1%

با در نظر گرفتن مشخصات جدول ۵ فاز استخراج داده برای هر نیروگاه جداگانه انجام شد. دمای محیط از ۲۵- درجه سانتی‌گراد تا ۲۵+ درجه سانتی‌گراد با گام‌های ۵ درجه سانتی‌گراد و در هر گام دمایی نیز، بار از صفر تا ۱۰۰ درصد تغییر یافت که در مجموع برای هر نیروگاه ۲۳۱ نقطه کاری را تشکیل دادند. چون تعداد سنسورهای مورد بررسی ۸ عدد می باشند تعداد نمونه‌هایی که برای داده‌های سالم استخراج می شوند و مربوط به کلاس سالم هستند در مجموع یک ماتریس ۸×۲۳۱ می باشد. این الگوهای داده‌ای معادل حالت سالم سنسور هستند و برای ایجاد مجموعه داده‌های آموزش شبکه عصبی مورد استفاده قرار می‌گیرند. برای شبیه‌سازی حالت واقعی نویز سفید به پارامترها اضافه شده است. نویز با یک الگوریتم تصادفی با فواصل داده‌شده تولید شده است که دارای یک توزیع نرمال است که تغییرات اعمالی برای هر کدام از پارامترها در جدول ۴ قابل مشاهده است. داده‌های فالتی (آلوده به خطا) به صورت متوالی تولید شده‌اند. و برای هر کدام از کلاس‌های انحراف سنسور ۲۳۱ الگوی داده تولید شدند. با توجه به ۱۶ کلاس انحراف سنسور برای توربین، تعداد الگوی داده‌ها به صورت قابل توجهی افزایش می‌یابند. در مجموع، داده‌های نهایی که برای یک نیروگاه در مرحله آموزش شبکه عصبی مورد استفاده قرار گرفت یک ماتریس ۸×۳۹۲۷ بود.

جدول ۴: مقادیر انحراف هر پارامتر

Parameters	Full Load	%	Unit
Ambient Temp	±0.5	%1	°C
Compressor Mass Flow	±1	%0.25	Kg/s
Compressor Outlet Press	±0.2	%1.80	Bar
Compressor Outlet Temp	±3	%0.90	°C
Exhaust Temp	±5	%1.00	°C
Fuel Mass Flow	±0.1	%0.90	Kg/s

ارزیابی این شبکه عصبی با استفاده از یک سری مجموعه داده آزمایش که به صورت موازی با داده‌های آموزش ولی برای نقاط کاری متفاوت تولید شد مورد بررسی قرار گرفت. به صورت خاص تر داده‌های آزمایش با تغییر بار از ۱۲,۵ درصد تا ۹۷,۵ درصد و گام‌های ۵ درصد و دمای محیط از ۲۲/۵- درجه سانتی‌گراد تا ۲۲/۵+ درجه سانتی‌گراد با گام ۵ درجه سانتی‌گراد تولید شد که در مجموع برای هر نیروگاه در کلاس سالم، ۲۱۰ نقطه کاری را تشکیل می‌دهند با اعمال مقادیر انحراف هر پارامتر در داده‌های آزمایش در مجموع داده‌های نهایی که برای تست شبکه عصبی مورد استفاده قرار می‌گیرد یک ماتریس ۸×۱۰۷۱۰ می‌باشد.

۱. سیستم جامع تشخیص خطا به واسطه الگوریتم KPCA و شبکه‌های عصبی

در فاز نخست فقط شبکه عصبی MLP، برای طبقه بندی داده‌ها مورد استفاده قرار گرفت تا معیاری برای مقایسه و سنجش عملکرد روش KPCA-MLP وجود داشته باشد. شبکه عصبی مورد استفاده در این بخش شبکه عصبی پرسپترون با الگوریتم پس انتشار خطا و قانون یادگیری ممتوم برای آموزش آن استفاده شده است. داده‌های تولید شده برای آموزش شبکه عصبی با در نظر گرفتن سه نیروگاه یک ماتریس ۸×۱۱۷۸۱ و برای داده‌های تست یک ماتریس ۸×۱۰۷۱۰ بودند. با توجه تست‌های مختلف بر روی شبکه عصبی انجام گرفت با توجه به تست‌های مختلف مشاهده گردید که بیشترین دقتی که می‌توان با شبکه عصبی MLP و الگوریتم پس انتشار خطا برای داده‌های تست بدست آورد دقتی معادل 87.95% است.

در فاز بعد ابتدا داده‌ها توسط الگوریتم KPCA به فضای ویژگی با بعد بالاتر نگاشت پیدا کردند تا تفکیک پذیری داده‌ها بهتر انجام گیرد و سپس شبکه عصبی MLP برای طبقه بندی داده‌ها مورد استفاده قرار گرفت. در روش KPCA در گام نخست بایستی ماتریس کرنل داده‌های آموزش و تست رو تشکیل داده و سپس بر روی آن پردازش‌های لازم صورت گیرد. ماتریس کرنل یک ماتریسی مربعی است که در اینجا چون اندازه داده‌های آموزش یک ماتریس ۸×۱۱۷۸۱ است، ماتریس کرنل برای این داده‌ها، یک ماتریس مربعی ۱۱۷۸۱×۱۱۷۸۱ می‌باشد که در

جدول ۶: مقایسه دو روش از لحاظ دقت تشخیص برای هر کلاس

Class	KPCA-MLP	MLP
C1	% 27.46	% 50.32
C2	% 73.81	% 69.21
C3	% 74.44	% 76.67
C4	% 99.84	% 100.00
C5	% 100.00	% 100.00
C6	% 98.57	% 82.86
C7	% 98.57	% 99.84
C8	% 96.03	% 100.00
C9	% 96.19	% 99.84
C10	% 100.00	% 100.00
C11	% 100.00	% 100.00
C12	% 100.00	% 100.00
C13	% 100.00	% 100.00
C14	% 99.68	% 91.43
C15	% 99.68	% 92.06
C16	% 91.27	% 70.95
C17	% 90.00	% 62.54
Total Accuracy	% 90.92	% 87.95

همانطور که از جدول ۶ استنباط می شود الگوریتم KPCA-MLP توانسته است دقت سیستم تشخیص خطا را ۳ درصد بهبود ببخشد و این الگوریتم در کلاس های ۱۴ و ۱۵ دمای خروجی توربین و کلاس های ۱۶ و ۱۷ توان خروجی توانسته است عملکرد چشمگیری نسبت به الگوریتم MLP داشته باشد و چون این سیستم در نیروگاه هایی مورد بررسی قرار گرفته است که امکان سیکل ترکیبی شدن دارند مواردی همچون دمای خروجی توربین و توان خروجی توربین گاز از اهمیت بالایی برخوردار هستند توسط این سیستم تشخیص خطا می توان نتایج بهتری را نسبت به الگوریتم MLP برای بحث تشخیص خطای سنسور در توربین گاز V94.2 بدست آورد.

نتیجه گیری

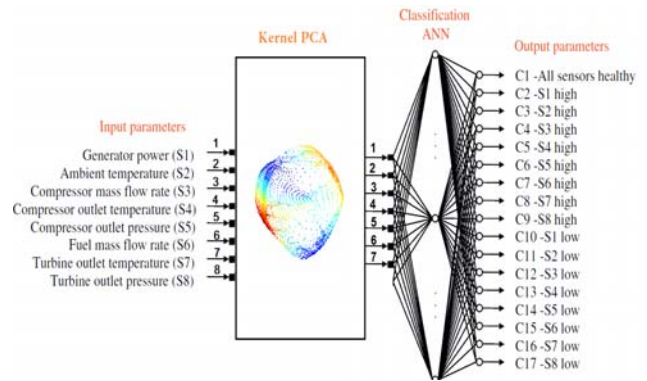
در این مقاله ابتدا اعتبارسنجی سنسورهای سه نیروگاه بصورت جامع توسط شبکه عصبی MLP مورد ارزیابی و طبقه بندی قرار گرفته اند تا معیاری برای مقایسه بین دو روش MLP و KPCA-MLP وجود داشته باشد. همانطور که از نتایج بین دو روش مشخص است، روش KPCA-MLP یک پاسخ کامل برای آشکارسازی خطای سنسور، جداسازی و تشخیص سطح انحراف را از طریق استخراج ویژگی به عنوان یک سیستم تشخیص خطای جامع برای

این الگوریتم از تابع با پایه شعاعی گوسی که بصورت رابطه زیر تعریف می شود برای ساختن ماتریس کرنل استفاده می شود.

$$K(x_i, x_j) = \exp\left(\frac{-\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (10)$$

قبل از اعمال داده ها به شبکه عصبی، فاز استخراج ویژگی می باشد که این فاز به روش PCA استاندارد انجام می گیرد. با اینکار داده ها کاهش بُعد یافته و سپس به شبکه عصبی جهت آموزش و تست اعمال می گردند. با تست ها و بررسی های انجام گرفته بر روی برنامه، داده ها در فاز کاهش بُعد و انتخاب تعداد مقدار ویژه بزرگتر، بهترین نتیجه با انتخاب ۲۵۰۰ مقدار ویژه بزرگتر حاصل گردید. توسط تولباکس KPCA داده های جدید برای آموزش با ابعاد 2500×11781 حاصل می شود.

در شکل ۲ ساختار کلی شبکه مورد استفاده نشان داده شده است:



شکل ۲: ساختار کلی سیستم تشخیص خطای جامع توربین های گاز V94.2

۹. عملکرد و نتایج

پس از استخراج نتایج حاصل از دو الگوریتم MLP و KPCA-MLP در این بخش به مقایسه ی این دو روش از لحاظ تشخیص و طبقه بندی خطای پردازیم. مشخصات ساختار و دقت هر دو الگوریتم در جدول ۵ نشان داده شده است.

جدول ۵: مقایسه عملکرد دو شبکه MLP و KPCA-MLP

Methods	Structure	momen	Learning rate	Average
MLP	8-150-17	0.09	0.08	87.95%
KPCA-MLP	2500-150-17	0.08	0.01	90.92%

توربینهای مدل V94.2(3) در کشور نشان می دهد. تعداد ۲۵۰۰ مقدار ویژه با روش KPCA استخراج شده و به صورت ترکیب خطی از دیتای سنسورها بیان می شوند. در این روش شبکه عصبی MLP پس از آموزش و تست با داده های جدید، قابلیت تشخیص و جداسازی قابل قبولی را برای انحراف سنسورها از حد آستانه تعریف شده دارا بود. در این مطالعه فالت های سنسورها مورد بحث قرار گرفته است و می توان با توجه به خطای انحراف مثبت و منفی آشکار شده نسبت به اقدامات تعمیراتی از جمله کالیبره کردن هر سنسور تصمیم گیری نمود.

منابع

- [1] Manuel Valdés, José L. Rapún . Optimization of heat recovery steam generators for combined cycle gas turbine power plants. 2001 Elsevier
- [2] S. S.Tayarani-Bathaie, Z.N.Sadough Vanini, K. Khorasani .Fault detection of gas turbine engines using dynamic neural networks. 2012 25th IEEE Canadian
- [3] سعید فلاح؛ علی ربانی؛ ابوالفضل رکن رابعی " اعتبار سنجی سنسورهای توربین گاز V94.2 به وسیله طبقه بندی با شبکه های عصبی مصنوعی " ؛ بیست و نهمین کنفرانس بین المللی برق ۱۳۹۳- تهران
- [4] Sohel Anwar, Lei Chen. An Analytical Redundancy-Based Fault Detection and Isolation Algorithm for a Road-Wheel Control Subsystem in a Steer-By-Wire System. IEEE 2007
- [5] Ronald W. Kelly. Application of Analytical Redundancy to the Detection of Sensor Faults on a Turbofan Engine. Conference Sponsors: International Gas Turbine Institute, 2001
- [6] Cybenko G. Approximation by superpositions of a sigmoidal function. MathControl Signal Syst (MCSS) 1989;2:303-14.
- [7] Werbos PJ. Beyond regression: new tools for prediction and analysis in the behavioral sciences. Harvard University; 1974.
- [8] Rumelhart DE, Hinton GE, Williams RJ. Learning internal representations by error propagation. Parallel Distrib Process 1986;1:318-62.
- [9] Mania Navi, Mohammad Reza Davoodi, Nader Meskin. Sensor Fault Detection and Isolation of an Industrial Gas Turbine Using Partial Kernel PCA. ELSEVIER 2015