

## سیاست‌گذاری نگهداری و تعمیرات پیشگویانه در مراکز فرآوری نفت و گاز

سجاد شکوه یار\*، جلال حقیقت منفرد\*\*، سامان سربی\*\*\*

### چکیده

سیاست مناسب در نگهداری و تعمیرات می‌گوید تعمیر زمانی باید انجام شود که نیاز باشد. اگرچه انجام تعمیرات پیشگیرانه می‌تواند تعمیرات ناگهانی و غیرمترقبه را کاهش دهد اما همچنان باعث کاهش در دسترس بودن و افزایش هزینه‌های تعمیرات می‌گردد. شرکت‌ها می‌بایست استراتژی‌های نگهداری آنلاین و پیشگویانه را گسترش دهند که بتوانند تصور کنند که هر خرابی در هر زمانی ممکن است به‌طور تصادفی رخ دهد و این نیاز را از علائم و نشانه‌هایی که تجهیزات از خود بروز می‌دهند تشخیص دهند که به آن نگهداری و تعمیرات پیشگویانه یا نگهداری مبتنی بر شرایط می‌گویند. در این مقاله سعی شده است یک مدل پشتیبان تصمیم‌گیر برای نگهداری و تعمیرات پیشگویانه مبتنی بر شرایط بر اساس تکنیک‌های داده‌کاوی طراحی شود. این پروژه در یکی از شرکت‌های بهره‌بردار نفت و گاز جنوب کشور انجام شده و تجهیز انتخابی برای این پروژه توربین‌های گازی است که یکی از اساسی‌ترین و بحرانی‌ترین تجهیزات در کارخانه‌های فرآوری نفتی است. در این پروژه تکنیک داده‌کاوی شبکه عصبی MPL برای پیش‌بینی رخداد خرابی در تجهیز مورد نظر به کار گرفته شده است. در انتها پیشنهادهایی از جمله توسعه این مدل برای سایر تجهیزات، کنترل مدت زمان مشاهده صورت وضعیت تجهیزات و تعیین زمان بهینه تعمیر و نگهداری برای آینده ارائه شده است.

کلیدواژه‌گان: نگهداری و تعمیرات، تعمیرات پیشگویانه مبتنی بر شرایط، تکنیک شبکه عصبی

MPL، پیش‌بینی

تاریخ دریافت مقاله: ۱۳۹۹/۰۷/۱۸ تاریخ پذیرش مقاله: ۱۴۰۰/۰۸/۰۶

\* استادیار، دانشگاه شهید بهشتی، تهران، ایران (نویسنده مسئول)

Email: sajad.shokouhyar@gmail.com

\*\* استادیار، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران.

\*\*\* دانش‌آموخته دکتری، دانشگاه آزاد تهران مرکز، تهران، ایران.

## ۱. مقدمه

آنچه در سال‌های اخیر توجه مدیران صنایع مختلف را در دنیای رقابتی امروز به خود جلب کرده است، کاهش هزینه‌های تولید و در نتیجه کاهش قیمت نهائی محصولات است. در این میان هزینه‌های تعمیراتی، از مهم‌ترین هزینه‌های قابل کنترل در صنایع است و طبیعی است که کاهش آن در دستور کار مدیران صنعت قرار گیرد. یکی از مهم‌ترین ابزارهایی که برای نیل به این هدف در اختیار مسئولین قرار دارد استفاده از روش‌های نوین نگهداری و تعمیرات بر اساس پایش وضعیت دستگاه‌ها است که بخصوص در صنایع تولید مداوم، نظیر نفت، گاز و پتروشیمی از اهمیت ویژه‌ای برخوردار است. فلسفه وجودی روش‌های تعمیراتی از قبیل نگهداری و تعمیرات پیشگیرانه<sup>۱</sup> و نگهداری و تعمیرات پیشگویانه<sup>۲</sup> ارائه راهکارهایی جهت کاهش هزینه‌های تعمیراتی و در نتیجه افزایش بهره‌وری واحدهای تولیدی است [۱۲].

عموماً نگهداری و تعمیرات یا در زمان‌های مشخص و از قبل تعیین شده انجام می‌شود یا اینکه هر وقت خرابی رخ داد بسته به نوع خرابی تعمیر مورد نظر انجام می‌شود. اگر چه انجام تعمیرات پیشگیرانه می‌تواند تعمیرات ناگهانی و غیرمترقبه را کاهش دهد اما همچنان باعث کاهش در دسترس بودن و افزایش هزینه‌های تعمیرات می‌گردد. گاهی تعمیرات پیشگیرانه روی تجهیز انجام می‌شود در حالیکه تجهیز به خوبی کار می‌کند و نیازی به تعمیر و توقف ندارد. با توجه به نیاز روز افزون به قابلیت اطمینان، در دسترس بودن، حفظ و ایمنی دستگاه‌ها، استراتژی‌های سنتی تعمیر و نگهداری تأثیر خود را از دست داده و منسوخ می‌شوند [۱۲].

اما چون نگهداری از قبل در بازه زمانی خاصی برنامه‌ریزی شده است بایستی طبق روال خود انجام شود. یک سیاست مناسب در نگهداری و تعمیرات می‌گوید تعمیر زمانی باید انجام شود که نیاز باشد [۱۲].

کارخانه‌های صنعتی نباید دیگر تصور کنند که خرابی‌های تجهیزات تنها پس از مدت زمان ثابتی که در حال کار هستند اتفاق می‌افتد. آن‌ها باید استراتژی‌های نگهداری آنلاین و پیشگویانه را گسترش دهند که بتوانند تصور کنند که هر خرابی در هر زمانی ممکن است به‌طور تصادفی رخ دهد. آغاز خرابی و شکست تجهیزات ممکن است خود را در داده‌های به وجود آمده از روش‌های مختلف آشکار سازد. تجهیزات اعلام و نشانه‌هایی از خود بروز می‌دهند که می‌گویند این تجهیزات باید تعمیر یا جایگزین شوند و یا رها شوند تا به کار خود ادامه دهند [۱۳]. فرضیه نگهداری شرطی یک مشاهده منظم از شرایط واقعی از تجهیزات بر اساس ویژگی‌های مهم و برجسته و مؤثر آنها و کارایی عملکرد از سیستم‌های فرایندی است که باعث اطمینان از حداکثر کردن فاصله بین تعمیرها، کاهش هزینه تعمیرات برنامه‌ریزی نشده ناشی از خرابی ماشین آلات و بهبود دسترسی جامع از عملکرد واحدهای صنعتی خواهد بود. یکی از مهم‌ترین و به صرفه‌ترین تکنیک‌های مؤثر نگهداری، نگهداری مبتنی بر شرایط<sup>۳</sup> (CBM) است [۱۹].

استفاده از نگهداری و تعمیرات پیشگویانه یا همان نگهداری مبتنی بر شرایط باعث رسیدن به پیشرفت‌های بزرگی در هزینه‌های نگهداری و تعمیرات، کاهش خرابی‌های برنامه‌ریزی نشده ماشین آلات، کاهش زمان از کار افتادگی (بیکاری) ناشی از تعمیر تجهیزات و بهبود موجودی قطعات یدکی می‌شود [۱۳]. نگهداری پیشگویانه یکی از استراتژی‌های نگهداری و تعمیرات است که بر مبنای آن در بازه‌های زمانی معین و یا به‌صورت مستمر تعدادی از پارامترهای تجهیزات اندازه‌گیری می‌شود و بر اساس این داده‌ها برای تعمیر و تعویض قطعات و تجهیزات تصمیم‌گیری می‌شود.

<sup>۱</sup> Preventive Maintenance (PM)

<sup>۲</sup> Predictive Maintenance (PDM)

<sup>۳</sup> Condition Based Maintenance

در دهه ۱۹۸۰ نت پیشگویانه یا نت متکی بر شرایط و وضعیت تجهیزات، جایگزین نت پیشگیرانه گردید. نت پیشگویانه به این دلیل که با استفاده از شیوه‌های جدید بررسی شرایط فنی تجهیزات (نظیر لرزه نگاری<sup>۱</sup>، ترموگرافی<sup>۲</sup>، صوت سنجی<sup>۳</sup>، آنالیز روغن<sup>۴</sup>)، وضعیت آنها را در زمانی که تحت بهره‌برداری هستند با تشخیص علائم استهلاک و یا امکان خرابی‌های قریب الوقوع، مشخص می‌سازد نقش مهمی در نگهداری و تعمیرات جامع ایفا می‌کند.

در سال‌های اخیر، شبکه‌های عصبی مصنوعی به‌طور موفق در کارهای تشخیص الگو و حل مسائل تشخیص خرابی مورد استفاده قرار گرفته‌اند. یکی از مزایای اصلی استفاده از شبکه‌های عصبی مصنوعی، توان تشخیص الگوهایی است که نادقیق<sup>۵</sup> هستند. این تحقیق به دنبال پیاده‌سازی شبکه‌های MPL در نت پیشگویانه است.

## ۲. مبانی نظری و پیشینه پژوهش

**مبانی نظری.** روش‌های نگهداری و تعمیرات را می‌توان به سه دسته کلی تقسیم نمود: نگهداری و تعمیرات اصلاحی<sup>۶</sup>، نگهداری و تعمیرات پیشگیرانه<sup>۷</sup> و نگهداری و تعمیرات پیشگویانه<sup>۸</sup> [۱].

نگهداری مبتنی بر شرایط که به نگهداری پیشگویانه معروف است، پیشرفته‌ترین و مدرن‌ترین تکنیک نگهداری است که در مکتوبات مختلف مورد بحث و بررسی قرار گرفته است. نگهداری مبتنی بر شرایط در سال ۱۹۷۵ برای به حداکثر رساندن تأثیر تصمیم‌سازی پیشگویانه معرفی شد. مفهوم مشاهده آنلاین در نزدیکی‌های سال ۱۹۹۰ شکل گرفت که بر اساس مشخص کردن وضعیت کارکرد و فرسایش تجهیزات باندازه‌گیری پارامترهای مهم در مدت زمانهای کارکرد باعث کاهش هزینه‌های نگهداری خواهد شد [۵].

به‌طور کلی یک استراتژی مناسب نگهداری و تعمیرات باید شرایط تجهیزات را بهبود دهد، نرخ خرابی تجهیزات را کاهش دهد و هزینه‌های نگهداری و تعمیرات را به حداقل برساند که در نهایت منجر به حداکثر رساندن عمر مفید تجهیزات شود. با توجه به این واقعیت، استراتژی نگهداری و تعمیرات پیشگویانه موضوعی است که بیشتر از سایر استراتژی‌ها به دلیل توانایی در بهینه‌سازی استفاده از تجهیزات، مورد توجه تحلیل‌گران در صنایع مختلف است [۱۰].

**نگهداری و تعمیرات پیشگویانه.** پیش‌بینی خرابی قبل از اینکه خرابی اتفاق بیافتد. مطابق با پژوهش جاردین و همکاران [۹]، روش‌های نگهداری و تعمیرات قادر به نظارت بر شرایط تجهیزات در راستای تشخیص و پیش‌بینی هستند که به سه دسته اصلی تقسیم‌بندی می‌شوند: رویکردهای آماری<sup>۹</sup>، رویکردهای یادگیری ماشین<sup>۱۰</sup> و روش‌های مبتنی بر مدل. از آنجا که رویکردهای مبتنی بر مدل نیاز به دانش مکانیکی و تئوری تجهیزات برای نظارت دارند و رویکردهای آماری نیاز به پیش زمینه ریاضی دارند، رویکردهای هوش مصنوعی به‌طور فزاینده‌ای در برنامه‌های نگهداری و تعمیرات پیشگویانه اعمال می‌شوند.

<sup>۱</sup> Vibration Monitoring

<sup>۲</sup> Thermography

<sup>۳</sup> Sound or Acoustic Monitoring

<sup>۴</sup> Oil-Analysis or Lubricant Monitoring

<sup>۵</sup> Imprecise

<sup>۶</sup> Corrective maintenance

<sup>۷</sup> Preventive Maintenance (PvM)

<sup>۸</sup> Predictive Maintenance (PdM)

<sup>۹</sup> statistical

<sup>۱۰</sup> artificial intelligence

## روش‌های یادگیری ماشین

**شبکه عصبی مصنوعی.** شبکه‌های عصبی مصنوعی یکی از تکنیک‌های محاسباتی هوشمندی هستند که از نورون‌های بیولوژیکی الهام گرفته‌اند [۳]. شبکه عصبی از چندین واحد پردازش (گره یا نورون) تشکیل شده است که عملکرد نسبتاً ساده‌ای دارند. این واحدها معمولاً توسط کانال‌های ارتباطی که دارای وزن مرتبط هستند متصل می‌شوند. رفتار هوشمند شبکه عصبی مصنوعی از تعامل بین واحدهای پردازشی شبکه ناشی می‌شود. شبکه عصبی مصنوعی یکی از الگوریتم‌های متداول و کاربردی یادگیری ماشین است و در بسیاری از کاربردهای صنعتی از جمله کنترل پیش‌بینی مورد استفاده قرار گرفته‌اند [۱۷].

**ماشین بردار پشتیبان.** ماشین بردار پشتیبان به دلیل دقت بالایی که دارد یکی دیگر از روش‌های بسیار پرکاربرد و شناخته شده یادگیری ماشین برای انجام کارهای طبقه‌بندی و رگرسیون است [۴]. یکی از ویژگی‌های اصلی ماشین بردار پشتیبان، دقت بالای آن در تفکیک کلاس‌های مختلف داده‌ها است تا بتواند نقطه بهینه را برای تفکیک کلاس‌ها تعیین کند [۱۸]. ماشین بردار پشتیبان مجموعه‌ای از روش‌های یادگیری نظارت شده است که تجزیه و تحلیل رگرسیون و شناخت الگو را انجام می‌دهد.

### پیشینه پژوهش

با توجه به پیشرفت تکنولوژی و وجود تکنیک‌های متنوع مطالعات و بررسی‌ها مختلفی روی نگهداری و تعمیرات پیشگیرانه انجام شده است که شرحی مختصر از چند تحقیق در ادامه ذکر خواهد شد. باپتیستا و همکاران [۲] تعدادی از رویکردهای هوش مصنوعی مانند ماشین بردار پشتیبان را با مدل‌های مبتنی بر رویکرد آماری به منظور پیش‌بینی خرابی تجهیزات در آینده مقایسه کرده است. نتایج این تحقیق نشان می‌دهد که رویکرد هوش مصنوعی در تقابل با رویکردهای آماری پیش‌بینی‌های دقیق‌تری را ارائه می‌دهد. بیسوال و همکاران [۳] برای تشخیص خرابی اجزای مهم توربین بادی از شبکه عصبی مصنوعی استفاده کردند. آن‌ها داده‌های لرزش را در شرایط خوب و بعد جمع‌آوری کردند و جزء معیوب را با یک جزء سالم جایگزین کردند. در نهایت، پیش‌بینی‌های شبکه عصبی مصنوعی برای طبقه‌بندی ویژگی‌های یک وضعیت سالم و ویژگی‌های یک حالت معیوب انجام شد. نتایج حاصل از این پژوهش نشان‌دهنده دقت طبقه‌بندی ۹۲/۶٪ است. کولوکاس و همکاران [۱۵] شبکه عصبی مصنوعی را با سایر الگوریتم‌های یادگیری ماشین مقایسه کردند تا بتوانند خرابی‌های موجود در تجهیزات صنعتی را در زمان واقعی با استفاده از دوره‌های عملیاتی تشخیص دهند. آن‌ها شبکه‌های حافظه کوتاه مدت را که گونه‌ای از شبکه عصبی مصنوعی مکرر است، برای پیش‌بینی وضعیت فعلی موتور با استفاده از اسپارک موتور پردازش داده در مقیاس بزرگ، پیشنهاد کردند. در این حالت داده‌ها از سه تنظیم‌های عملیاتی و ۲۱ اندازه‌گیری حسگر دما، فشار موتور و سوخت تشکیل شده است. باید نام محققان آورده شود محققان تلاش کرده‌اند با توجه به چالش‌هایی که کارخانه‌ها برای افزایش کارایی، کاهش هزینه‌ها و بالا بردن چرخه حیات و طول عمر تجهیزاتشان با آن مواجه هستند یک استراتژی نگهداری پیشگیرانه برای برنامه‌ریزی سرویس ملاقات تجهیزات و بررسی تجهیز با توجه به شرایط واقعی آن طراحی و تدوین کنند. برای چالش‌های نامبرده در این تحقیق به استفاده از دو نظریه داده‌کاوی و قابلیت پیشگویی استفاده می‌شوند. در نتیجه این تحقیق یک روش عملی ارائه شد. این روش شامل گام‌های متفاوتی از داده‌کاوی، تکنیک‌های قابلیت اطمینان و الگوریتم‌های پیش‌بینی به منظور استخراج ویژگی‌های مرتبط و استفاده از آنها برای پیش‌بینی فعالیت نگهداری و تعمیرات متناسب است [۱۶].

باید نام محققان آورده شود روش هوشمند برای بهینه نمودن تعریف استراتژی نگهداری پیشگیرانه " که در سال ۲۰۱۲ ارائه شده است، که باعث بالا رفتن قابلیت اطمینان با تعیین استراتژی نگهداری پیشگیرانه می‌شود.

برای رسیدن به این هدف یک الگوریتم بر اساس آنالیز شود - هزینه و راهکار بهینه‌سازی کارها توسعه داده شده است. در نتیجه این مقاله یک روش هوشمند برای بهینه نمودن استراتژی نگهداری پیشگویانه شرح می‌دهد که بر اساس الگوریتم تصمیم‌گیری بهینه است [۱۳].

باید نام محققان آورده شود محدودیت‌های روش‌های نگهداری تجهیزات مبتنی بر زمان و فواید تکنیک‌های نگهداری آنلاین و یا پیشگیرانه در تشخیص تجهیزات را مورد بحث و بررسی قرار می‌دهد. و به بررسی سه تکنیک شامل تکنیک مبتنی بر سنسور موجود، تکنیک مبتنی بر تست سنسور و تکنیک مبتنی بر تست سیگنال می‌پردازد. در نتیجه این مقاله به این موضوع اشاره می‌شود که کارخانجات صنعتی نباید دیگر تصور کنند که شکست‌های تجهیزات تنها پس از مدت زمان ثابتی در سرویس اتفاق می‌افتد، آن‌ها باید استراتژی نگهداری آنلاین و پیشگیرانه را گسترش دهند که بتوانند تصور کنند که هر شکستی در هر زمانی به‌طور تصادفی می‌تواند رخ دهد [۶].

باید نام محققان آورده شود ۲۰۱۲ ارایه شده است به مرور برنامه‌ها و کاربردهای صنعتی نگهداری مبتنی بر زمان و نگهداری مبتنی بر شرط می‌پردازد. این مقاله بررسی می‌کند که چطور این دو روش نگهداری به‌سوی تصمیم‌سازی نگهداری حرکت می‌کنند. و با تحقیق و بررسی مطالعات اخیر برنامه‌های مربوط به هر روش را مرور می‌کند [۸].

### ۳. روش‌شناسی پژوهش

هدف این مقاله توسعه و ایجاد یک مدل پشتیبان تصمیم بر اساس داده است که بتواند قبل از وقوع خرابی هشدار دهد و همچنین میزان زمان مفید باقیمانده از عمر تجهیزات اساسی را تا حد زیادی پیش‌بینی نماید. در این مقاله با استفاده از روش داده‌کاوی به نام شبکه عصبی (MLP) Multilayer Perceptron یک مدل پشتیبان تصمیم‌گیری پیش‌بینی رخداد خرابی طراحی شده است.

ابتدا چگونگی انتخاب کارخانه و محیط پروژه، تجهیزات مورد نظر و تشخیص پارمترهای اساسی و بحرانی مورد بررسی دقیق قرار گرفته است. سپس چگونگی جمع‌آوری داده، پالایش و پاک‌سازی داده و استفاده از مجموعه داده‌های آموزشی و آزمایشی برای طراحی مدل بازگو شده است.

در حال حاضر در شرکت بهره‌برداری نفت و گاز - بهره‌برداری و نمک‌زدایی بی‌بی حکمیه ۲ از انواع تعمیرات مانند تعمیرات غیرمترقبه، تعمیرات پیشگیرانه و تعمیرات اصلاحی استفاده می‌شود، اما مکانیزم و سیستمی برای تعمیرات پیشگویانه وجود ندارد و این نوع تعمیرات خیلی کم و بیشتر به‌صورت تجربی و موردی انجام می‌شود.

سیستم CMMS در حال حاضر می‌تواند جوابگوی انواع تعمیرات از قبیل تعمیرات غیرمترقبه، تعمیرات اصلاحی، تعمیرات پیشگیرانه و تعمیرات اساسی باشد. این نرم‌افزار همچنین تمامی اطلاعات مربوط به تجهیزات و مشخصات آنها، جابجایی و سایر اطلاعات مورد نیاز را درون خود ذخیره می‌کند. این نرم‌افزار اطلاعات مربوط به توقفات و ساعت کارکرد تجهیزات و خرابی آنها را ثبت و نگهداری میکند. اما در این نرم‌افزار بخشی برای تعمیرات پیشگویانه وجود ندارد.

سیستم CBM این توانمندی را برای سازمان ایجاد می‌کند که ارتباط و یگپارچگی بین خود، سیستم‌های MIS سازمان و سیستم CMMS را به‌وجود آورده و بتوان مدیریت و نظارت بهتری روی هزینه‌ها، کالا و قطعات و سایر موارد مورد نیاز اعمال نمود.

برای طراحی مدل مورد نظر توجه به چند نکته ضروری است.

- چه بخش، واحد یا کارخانهای را برای شروع کار خود انتخاب نمائیم؟
- در این بخش، واحد یا کارخانه انتخابی چه تجهیزاتی برای طراحی مدل مدنظر قرار بگیرند؟

● برای تجهیزات انتخاب شده چه پارامترها و معیارهایی را مدنظر قرار دهیم؟  
 ● چگونه پارامترها و معیارهای انتخاب شده را پایش کرده و به‌طور مستمر و برنامه‌ریزی شده مشاهده نموده و ثبت نماییم؟

در انتها و با طراحی مدل می‌توانیم مدت زمان عمر باقیمانده از تجهیز یا درصد احتمال وقوع خرابی در بازه زمانی خاص را مشخص نماییم.

به‌طور معمول معیارهای وضعیت، امنیت، محیطی و مالی برای انتخاب حائز اهمیت است. اما مهم‌ترین و اصلی‌ترین معیارها برای انتخاب محیط پایش برای مدل پیش‌بینی CBM میانگین مدت زمان توقف به ازای خرابی و همچنین تعداد خرابی به ازای واحد زمان است. سایر معیارهای عنوان شده با توجه به استراتژی و نوع و سیاست سازمان مورد بررسی قرار می‌گیرد [۱۱].

بعد از انتخاب واحد مورد نظر یکی از موارد کلیدی که باید به آن توجه داشت تعیین مدل‌های خرابی رخ داده شده در واحد مورد نظر است که آن هم با استفاده از نرم‌افزار CMMS موجود و اطلاعات گسترده و کامل ثبت شده در دسترس خواهد بود. همچنین استفاده از نظرات افراد خبره و متخصص کمک شایانی به کشف ارتباط وقوع انواع خرابی و علت آنها در واحد انتخاب شده می‌کند. همه این اطلاعات می‌تواند باعث کشف ارتباط بین مدل‌های خرابی و پارامترهای انتخاب شده منجر شود. در انتهای این مرحله می‌توان به فهرستی از واحدها و بخش‌های مختلف با در نظر گرفتن معیارهای ذکر شده دست یافت و سرانجام واحد و یا بخش مورد نظر را برای پایش و طراحی مدل انتخاب نمود.

در این مرحله باید به شناسایی پارامترهای موثر در خرابی پرداخت تا بتوان در فرایند پایش آنها رو مورد مشاهده و بررسی مستمر قرار داد. بعد از انتخاب واحد مورد نظر گام بعدی تعیین ارتباط بین مدل‌های خرابی رخ داده در واحد مورد نظر و شناسایی پارامترهای کلیدی و موثر در وقوع خرابی است. سپس باید به جمع‌آوری داده‌ها راجع به پارامترهای رو به زوال پرداخت. یک رخداد خرابی می‌تواند موثر از یک یا چند پارامتر مختلف برای وقوع آن باشد. در گام بعدی بایستی نمودار خرابی تجهیزات برای پارامترهای مختلف را ایجاد نمود و در انتها برای هر پارامتر حدود هشدار و خطر و حد آستانه پایین و بالا را تعیین کرد. همان‌طور که مشخص است به منظور ایجاد یک مدل دقیق پیش‌بینی، انتخاب و شناسایی متغیرها و پارامترهای مناسب و موثر در خرابی اهمیت فراوانی دارد. بعد از انتخاب پارامترهای مورد نظر باید به جمع‌آوری داده برای آنها پرداخت. بخش جمع‌آوری داده‌های وضعیت و همچنین داده‌های خرابی یک گام ضروری و حیاتی برای مدل طراحی شده است و کمک قابل توجهی در برآورد دقیق احتمال خرابی می‌نماید. در گام بعد ایجاد و مشاهده نمودار خرابی و زوال تجهیزات و پارامترها می‌تواند موثر و قابل توجه باشد. مشاهده رفتار و عملکرد پارامترها در بازه‌های زمانی متفاوت می‌تواند اطلاعات خوب و مناسبی را در اختیار کاربران قرار دهد.

برای افزایش در دسترس‌پذیری و همچنین کاهش توقفات برنامه‌ریزی شده و برنامه‌ریزی نشده ابزارهای پیش‌بینی می‌تواند توسعه داده شود و نقطه شروعی برای استفاده باشد. در این مقاله مدل مبتنی بر داده انباشته شده و بدون استفاده از دانش سیستمی مورد استفاده قرار گرفته است. این روش برای برآورد این توقعات مورد استفاده قرار گرفته است که آنالیز داده‌های پیشین و تاریخی تجهیزات به همراه داده‌های خرابی ارتباط بین این دو نوع داده را کشف نماید. و این نقطه شروع برای طراحی مدل پیش‌بینی خرابی بدون استفاده از دانش سیستمی دقیق است.

#### ۴. تحلیل داده‌ها و یافته‌ها

حال با توجه به انتخاب واحد مورد نظر و تجهیزات و پارامترهای موثر به چگونگی انتخاب دو کارخانه در شرکت بهره‌برداری نفت و گاز - بهره‌برداری و نمک‌زدایی بی‌بی حکمیه ۲ پرداخته می‌شود. برای این منظور یک بازه زمانی ۵ ماهه از ابتدای اردیبهشت سال ۱۳۹۲ تا انتهای شهریور همان سال در نظر گرفته شد.

در انتخاب کارخانه‌ها و واحدهای مورد نظر علاوه بر بررسی اطلاعات موجود و مرتبط راجع به رخداد خرابی در نرم‌افزار CMMS با افراد خبره و متخصص در این زمینه مشورت شد. از بین حدود ۳۰ کارخانه مختلف و همچنین بازدید از حدود ۱۰ کارخانه مختلف از نظر نوع کارکرد و همچنین با توجه به دوری مسافت دو کارخانه انتخاب شد. اطلاعات موجود در نرم‌افزار CMMS شامل موارد دقیق و کاملی جمله تعداد خرابی در مدت زمان مورد نظر، علل و چگونگی رخداد خرابی، مدت زمان توقف و کارکرد ردیف‌ها و خطوط کارخانه و چگونگی برطرف کردن ایراد و راه‌اندازی دوباره تجهیزات است.

با بررسی اطلاعات و کمک گرفتن از افراد متخصص در زمینه‌های مکانیک، برق و ابزار دقیق و با توجه به فصل گرما و فشار وارده به تجهیزات در کارخانه‌ها در نهایت دو کارخانه انتخاب شد. البته معیار قدیمی بودن این دو کارخانه و تجهیزات آنها نیز عاملی بود که باعث می‌شود احتمال وقوع خرابی در آنها را بیشتر نماید. بعد از انتخاب کارخانه‌های مورد نظر نوبت به انتخاب تجهیزات بحرانی و اساسی در آنها رسیده است. در هر کارخانه هزاران تجهیز ریز و درشت و ساده و مرکب وجود دارد که هر کدام به نوبه خود تاثیر خاصی روی روند کار کارخانه بجا می‌گذارند. این تجهیزات از خط ورودی کارخانه شروع می‌شوند و تا آخرین مکان خط خروجی ادامه دارند.

در هر دو کارخانه تجهیزاتی مانند پمپ، کمپرسور هوا، الکتروموتور، فن‌های خنک‌کننده، موتور کمپرسور، دیزل برق، تلمبه‌های متفاوت، کلیدهای مختلف الکتروکمپرسور، توربین و تجهیزات متفاوت دیگری وجود دارد. که باید از بین این همه تجهیز مهم یکی را برای ادامه پروژه انتخاب نمود. با بررسی‌های انجام شده و کمک از متخصصین امر توربین که شاید بتوان گفت اساسی‌ترین و مهم‌ترین تجهیز هر کارخانه بود انتخاب شد. در هر کارخانه ۳ یا ۴ ردیف قرار دارد که روی هر ردیف یک توربین عظیم تعبیه شده است. یک ردیف توربین خود تجهیز مرکبی است که شامل چهار تجهیز بزرگ توربین، پاورتوربین، گیربکس و کمپرسور است. توربین‌های انتخاب شده از دو نوع متفاوت به نام‌های رولزرویز و سولار می‌باشند. برای هر توربین حدود ۸۰ پارامتر مختلف در هر ساعت اندازه‌گیری و ثبت می‌شود.

اندازه‌گیری و ثبت برخی از این پارامترها با استفاده از داشبوردها و نشان دهنده‌های دیجیتالی و مکانیکی موجود در اتاق کنترل است و برخی دیگر توسط اپراتورها و با حضور در محیط فیزیکی کارخانه و مشاهده لحظه‌ای نشانگرهای مختلف تجهیزات انجام می‌شود. این پارامترها شامل دور، فشار، حرارت، لرزش، سطح روغن، جریان، ولتاژ و آمپر می‌باشند.

برای این پروژه دو نوع توربین متفاوت در دو کارخانه نفتی با شرایط و منطقه جغرافیایی مختلف مورد بررسی قرار گرفته است. در نتیجه دو مجموعه داده برای دو توربین استخراج شده است. مجموعه داده‌های متعلق به این دو نوع توربین مختلف در دو کارخانه نفتی متفاوت هستند که داده‌های آنها مربوط به مدت زمان بهار و تابستان سال ۱۳۹۶ است.

برای هر توربین حدود ۷۰ تا ۸۰ پارامتر مختلف ثبت می‌شود که با مشورت با افراد متخصص در این زمینه و بررسی علل توقف و خرابی توربین‌ها، برای توربین موجود در کارخانه فشارقوی ۳۴ پارامتر اساسی و برای توربین موجود در کارخانه بی‌بی حکمیه ۲ تعداد ۲۹ پارامتر (جدول شماره ۲) اساسی انتخاب و برای ادامه کار مورد بررسی قرار گرفتند. پارامترهای انتخاب شده در جدول ۱ قابل مشاهده است.

جدول ۱. نام پارامترهای کارخانه فشارقوی

ردیف	نام پارامتر	ردیف	نام پارامتر
۱	سرعت توربین R.P.M	۱۸	حرارت یاتاقان‌های توربین نیرو- جلو
۲	سرعت توربین نیرو R.P.M	۱۹	حرارت یاتاقان‌های توربین نیرو- ضربه گیر
۳	حرارت E.G.T	۲۰	لرزش یاتاقان‌های جعبه دنده سرعت کم افقی
۴	حرارت یاتاقان‌های توربین نیرو- جلو	۲۱	لرزش یاتاقان‌های جعبه دنده سرعت کم عمودی
۵	حرارت یاتاقان‌های توربین نیرو - افقی	۲۲	لرزش یاتاقان‌های جعبه دنده سرعت زیاد افقی
۶	حرارت یاتاقان‌های توربین نیرو - عقب	۲۳	لرزش یاتاقان‌های جعبه دنده سرعت زیاد عمودی
۷	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۱	۲۴	لرزش یاتاقان‌های کمپرسور- جلو
۸	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۲	۲۵	لرزش یاتاقان‌های کمپرسور- عقب
۹	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۳	۲۶	لرزش یاتاقان‌های کمپرسور - ضربه گیر
۱۰	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۱	۲۷	دمای ترموکوپل ۱
۱۱	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۲	۲۸	دمای ترموکوپل ۲
۱۲	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۳	۲۹	دمای ترموکوپل ۳
۱۳	حرارت یاتاقان‌های کمپرسور- جلو	۳۰	دمای ترموکوپل ۴
۱۴	حرارت یاتاقان‌های کمپرسور - عقب	۳۱	دمای ترموکوپل ۵
۱۵	حرارت یاتاقان‌های کمپرسور - تراست ۱	۳۲	دمای ترموکوپل ۶
۱۶	حرارت یاتاقان‌های کمپرسور - تراست ۲	۳۳	دمای ترموکوپل ۷
۱۷	لرزش یاتاقان‌های توربین نیرو - جلو	۳۴	دمای ترموکوپل ۸

جدول ۲. نام پارامترهای کارخانه بی‌بی حکیمه ۲

ردیف	نام پارامتر	ردیف	نام پارامتر
۱	فشار هوای P2	۱۶	اختلاف فشار گاز نشت بند
۲	دور کمپرسور %	۱۷	لرزش کمپرسور- یاتاقان عقب
۳	دور توربین %	۱۸	لرزش کمپرسور- یاتاقان جلو
۴	دمای خروجی توربین	۱۹	اختلاف فشار و روغن نشت بند
۵	فشار روغن	۲۰	فشار گاز نشت بند (بفر)
۶	حرارت روغن	۲۱	اختلاف فشار گاز نشت بند
۷	لرزش توربین	۲۲	لرزش کمپرسور- یاتاقان عقب
۸	لرزش توربین نیرو	۲۳	لرزش کمپرسور - یاتاقان جلو
۹	حرارت جعبه دنده	۲۴	اختلاف فشار و روغن نشت بند
۱۰	روغن روغن کاری- فشار	۲۵	فشار گاز نشت بند (بفر)
۱۱	روغن روغن کاری- حرارت	۲۶	اختلاف فشار گاز نشت بند
۱۲	امیر الکتروموتور	۲۷	لرزش کمپرسور- یاتاقان عقب
۱۳	دور کمپرسور %	۲۸	لرزش کمپرسور- یاتاقان جلو
۱۴	دور P.T %	۲۹	فشار گاز نشت بند (بفر)
۱۵	اختلاف فشار و روغن نشت بند		


با مشخص شده دو توربین مورد نظر به هر دو کارخانه به‌طور جداگانه مراجعه شد تا فرم‌های ورود اطلاعات که تا قبل از این به‌طور دستی پر می‌شد از آرشیو کارخانه جدا و انتخاب شوند. همان‌طور که قبلاً عنوان شد برای



هر توربین حدود ۸۰ پارامتر به طور دستی درون ۴ فرم مختلف ثبت می‌شد. همه این فرم‌ها برای هر توربین به طور جداگانه درون آرشیو جستجو و در نهایت جدا شدند. ۳۵ پارامتر نهایی انتخاب شده هم در بین این ۸۰ پارامتر و درون این ۴ فرم بخش بودند که بایستی برای ورود اطلاعات جدا و مشخص می‌شدند. درون هر فرم ۲۴ رکورد که نشان دهنده یک ساعت از شبانه‌روز است و حدود ۲۰ تا ۳۰ ستون برای ورود اطلاعات پارامترهای مختلف وجود دارد که همگی به صورت عددی اعم از اعشاری و صحیح می‌باشند. در نهایت حدود ۱۲۰۰ برگه در قالب ۸ فرم مختلف جدا شد و برای ورود اطلاعات در قالب فرم‌های اکسل آماده شده، در اختیار اپراتورها قرار گرفت. سپس ورود اطلاعات برای ۳۴ پارامتر نهایی انتخاب شده برای دو توربین مختلف در فرم‌های آماده اکسل شروع شد.

در بین روش‌های چند متغیره، تحلیل مولفه‌های اساسی (PCA) روشی آماری است که با استفاده از آن می‌توان ابعاد مشاهدات را کاهش داده و یک شاخص ترکیبی استخراج نمود. با کمک این روش و مشخص کردن ارتباط بین پارامترها می‌توان تعداد آن را کاهش داد و با استفاده از شاخص‌های جدید ایجاد شده و با تعداد پارامتر کمتر به ایجاد و طراحی مدل دقیق‌تری پرداخت [۳]. این روش روی داده‌های هر دو فایل اکسل انجام شد و در گام اول ماتریس الگو و ماتریس همبستگی استخراج شد. در این دو ماتریس پارامترهای مرتبط و وابسته به هم مشخص شدند. با اعمال این روش روی داده‌ها هر دسته از پارامترها به ۷ گروه تقسیم شدند. یعنی تعداد ۳۵ پارامتر کارخانه فشارقوی و تعداد ۳۴ پارامتر کارخانه بی‌بی حکیمه ۲، هر کدام به ۷ دسته مرتبط به هم تقسیم شدند. بنابراین به جای استفاده از تعداد ۳۵ و ۳۴ پارامتر در مدل که به دلیل تعداد زیاد مشکلاتی به وجود می‌آورد از تعداد ۷ پارامتر در هر گروه به عناوین شاخص‌ها و پارامترهای جدید تولید شد استفاده خواهد شد. و از این به بعد از این ۷ پارامتر در طراحی مدل خود استفاده خواهیم کرد.

برای مشاهده تغییر در پارامترها، مقادیر پارامترها در نمودار شکل ۱ نشان داده شد. در مواقع وقوع خرابی مقدار پارامتر قبل و بعد از خرابی تغییر عمده‌ای داشته است. و در مواردی که تغییرات چندانی روی مقدار پارامتر نداشته و نمودار روند خطی خود را پی گرفته است خرابی و توقفی رخ نداده است. این روال تغییرات در نمودار زیر برای ۷ فاکتور جدید تولید شده مشخص است.



شکل ۱. نمودار تغییرات پارامترها در بازه زمانی

همان‌طور که در شکل ۱ مشاهده می‌شود تغییرات ۷ پارامتر جدید در قالب ۷ رنگ متفاوت در بازه زمانی ۵ ماه نشان داده شده است. و تغییرات ناگهانی هر یک از خطوط نشان دهنده وقوع یک خرابی و توقف در یک لحظه خاص است. یک خرابی به این شکل است که ابتدا یک کاهش ناگهانی روی داده و بعد از رفع خرابی دوباره یک افزایش در پارامتر مشاهده می‌شود.

در این مرحله کلیه حالت‌های خرابی بر اساس هر ۷ فاکتور جدید تولید شده برای هر توربین به‌طور جداگانه بررسی شد و تعداد حالت‌های خرابی رخ داده بر اساس نمودار تعیین شد. برای هر حالت خرابی تاریخ رخداد آن ثبت شد. و سپس این تعداد خرابی‌های استخراج شده بر اساس نمودار توزیع تغییرات با خرابی‌های اتفاق افتاده که توسط نرم‌افزار CMMS ثبت شده است مورد تطابق قرار گرفت و مشخص گردید که حدود ۹۰٪ خرابی‌های واقعی ثبت شده کاملاً درست و دقیق در نمودار مشخص و قابل مشاهده بود.

این بررسی و رخداد خرابی به‌طور جداگانه برای هر ۷ عامل جدید انجام شد و وضعیت خرابی در بازه ۵ ماه مورد نظر برای همه عوامل ۱ به‌طور جداگانه مورد بررسی قرار گرفت. در این بازه زمانی تعداد ۳۲ خرابی برای توربین موجود در کارخانه فشارقوی و تعداد ۳۶ رخداد خرابی برای توربین موجود در کارخانه بی‌بی حکیمه ۲ مشاهده و ثبت شد.

در این بخش توسعه و طراحی مدل پیش‌بینی خرابی ارائه خواهد شد. در نتیجه آماده‌سازی داده‌ها و پارامترهای ورودی برای مدل ۷ دسته FAC1 و FAC7 قرار گرفتند. ضمناً ۳۲ حالت خرابی نیز انتخاب شد که از این تعداد بخشی برای آموزش مدل و تعدادی دیگر برای آزمایش مدل استفاده خواهد شد.

### بررسی سطح آستانه پارامترها

از زمانی که روال کاهش یا افزایش در پارامترها شروع شود، خرابی در حال رخ دادن خواهد بود. سطح آستانه برای هر پارامتر باید مشخص شود تا بتوان رسیدن به حالت خرابی را پیش‌بینی نمود. سطح آستانه پایین و بالا در ۳۲ حالت خرابی مورد استفاده قرار گرفت و مقدار آن از ۱۲ تا ۹ مشخص شد. جدول ۳ مقدار پارامترها و آستانه آنها در حالت‌های خرابی در ادامه قابل مشاهده است.

جدول ۳. مقدار پارامترها در حالت خرابی

ردیف	تاریخ	Fac1	Fac2	Fac3	Fac4	Fac5	Fac6	Fac7	حداکثر	حداقل
۱۴۱	۱۳۹۶/۰۲/۲۳	-۱/۱۷۰۴	-۱/۶۵۸۹۷	۰/۵۲۴۱۳	۰/۴۰۸۴۹	-۰/۱۵۷۷۸	۰/۲۹۰۵۸	-۲/۶۰۸۰۶	-۰/۵۲۴۱۳	-۳/۱۷۰۴
۱۸۷	۱۳۹۶/۰۳/۲۰	۱/۱۴۰۳۷	۰/۰۸۵۸۷	-۰/۷۰۹۵۳	۱/۵۶۰۱۷	-۰/۰۸۵۷۴	۰/۴۷۶۳۲	-۰/۳۴۷۹۳	۱/۵۶۰۱۷	-۰/۷۰۹۵۳
۵۴	۱۳۹۶/۰۲/۰۵	-۱/۵۸۲۵۵	۱/۳۵۶۱۲	-۱/۴۰۳۷۶	۰/۹۸۸۵۸	-۰/۲۲۷۲۷	۰/۷۷۴۵۲	۱/۵۵۶۵۵	۱/۵۵۶۵۵	-۱/۵۸۲۵۵
۱۴۱	۱۳۹۶/۰۲/۲۳	-۳/۱۷۰۴	۰/۱۶۵۸۹	۰/۵۲۴۱۳	۰/۴۰۸۴۹	-۰/۱۵۷۷۸	۰/۲۹۰۵۸	-۲/۶۰۸۰۶	-۰/۵۲۴۱۳	-۳/۱۷۰۴
۲۵۱	۱۳۹۶/۰۳/۲۶	۰/۲۳۳۹۵	۰/۰۳۵۴۷	۱/۱۷۶۲۴	۲/۲۱۵۹۲	۰/۰۱۱۰۱	۰/۰۶۹۸۹	۰/۱۰۰۳۸	۲/۲۱۵۹۲	-۱/۰۰۳۸۷
۲۵۴	۱۳۹۶/۰۴/۱۹	-۰/۰۸۰۷۲	-۲/۶۷۲۰۵	۰/۵۰۸۹	-۰/۴۹۲۰۷	-۰/۱۲۲۲۳	۰/۱۴۴۶۵	۰/۳۱۸۲۸	۰/۵۰۸۹	-۳/۱۸۲۸۹
۲۶۶	۱۳۹۶/۰۴/۲۲	۰/۲۰۵۵۲	-۳/۷۳۱۹۱	۰/۶۶۵۶۹	-۱/۰۱۱۸۵	-۰/۰۸۷۳	-۰/۳۷۴۰۶	-۵/۲۴۵۸۹	۰/۶۶۵۶۹	-۵/۲۴۵۸۹
۳۰۵	۱۳۹۶/۰۴/۲۶	۰/۵۳۲۵۷	۰/۰۵۶۵۳	-۰/۴۳۵۲۲	-۰/۷۹۳۳۳	۰/۰۰۴۷۶	۰/۱۳۴۲۹	-۰/۷۳۶۲۴	۰/۵۳۲۵۷	-۰/۷۹۳۳۳
۸۲	۱۳۹۶/۰۲/۰۷	-۱/۴۲۶۹۲	۱/۰۵۳۲	-۲/۳۳۵۸۸	۰/۸۵۰۹۲	-۰/۲۰۴۶۳	-۱/۰۷۱۴۶	-۰/۸۸۱۸۸	۱/۰۵۳۲	-۲/۳۳۵۸۸
۱۴۱	۱۳۹۶/۰۲/۲۳	-۳/۱۷۰۴	-۱/۶۵۸۹۷	۰/۵۲۴۱۳	۰/۴۰۸۴۹	-۰/۱۵۷۷۸	۰/۲۹۰۵۸	-۲/۶۰۸۰۶	-۰/۵۲۴۱۳	-۳/۱۷۰۴
۲۳۷	۱۳۹۶/۰۳/۲۵	-۰/۶۹۳۹۷	-۲/۲۷۲۶۱	۱/۵۸۱۹۷	۱/۹۹۸۱۱	-۰/۱۲۵۷۷	۰/۸۵۲۴	-۰/۶۹۷۰۶	۱/۹۹۸۱۱	-۲/۲۷۲۶۱
۳۷۲	۱۳۹۶/۰۴/۲۳	۰/۲۶۲۸۸	-۳/۴۸۲۱۶	-۱/۶۷۱۱۴	-۱/۶۷۸۰۲	۰/۰۷۶۴۷	-۱/۱۶۳۵۸	-۱/۹۷۵۹۱	۰/۲۶۲۸۸	-۳/۴۸۲۱۶
۲۸۴	۱۳۹۶/۰۴/۲۴	-۰/۴۲۸	-۳/۵۳۴۴۴	۰/۸۸۶۱۱	-۱/۰۲۴۲۸	۰/۰۰۸۶۸	-۱/۲۸۳۹۸	۴/۰۶۸۲۱	۴/۰۶۸۲۱	-۳/۵۳۴۴۴
۲۹۸	۱۳۹۶/۰۴/۲۶	۱/۳۳۲۷۱	-۱/۲۰۲۳۹	-۱/۷۰۴۶۴	-۰/۳۹۱۵۵	۰/۰۴۸۹۴	۰/۵۴۷۶۵	۰/۲۹۷۸	۱/۳۳۲۷۱	-۱/۷۰۴۶۴
۳۹۹	۱۳۹۶/۰۵/۰۳	-۰/۱۶۸۷۷	-۲/۷۵۸۹۸	۱/۳۲۹۰۱	-۱/۶۲۸۶۴	-۰/۰۹۲۳۲	-۰/۴۱۲۷۶	-۲/۱۰۲۳۴	۱/۳۲۹۰۱	-۲/۷۵۸۹۸
۱۱۴	۱۳۹۶/۰۲/۱۰	-۱/۸۲۸۰۵	-۰/۱۵۸۱۲	-۱/۵۸۷۱۶	۰/۳۸۷۶۷	-۰/۱۵۹۵۳	-۰/۲۱۷۲۵	-۰/۰۰۴۰۳	۰/۳۸۷۶۷	-۱/۸۲۸۰۵

۱۸۱	۱۳۹۶/۰۲/۲۷	-۰/۵۵۱۱۵	-۱/۰۷۹۲۱	۰/۷۹۱۷۱	۴/۸۹۰۹۷	۰/۱۰۰۳	-۴/۴۳۹۴	۲/۳۹۴۲۸	۴/۸۹۰۹۷	-۴/۴۳۹۴
۲۷۱	۱۳۹۶/۰۴/۲۳	-۰/۶۸۷۴	-۳/۳۹۷۶۷	-۰/۱۶۲۰۸	-۲/۰۳۰۹۵	-۰/۰۲۱۶۳	-۰/۵۲۰۷۳	-۳/۱۱۸۰۷	-۰/۰۲۱۶	-۳/۳۹۷۶۷

تفاوت در بازه حدود آستانه نشان می‌دهد که خرابی‌های با توجه به نوع و شرایط تجهیز در مواقع مختلفی می‌تواند رخ دهد. و دیگر اینکه گاهی تا رسیدن به حد نهایت بالا و پایین آستانه توقف و تعمیراتی انجام نشده است. با توجه به مشاهده تغییرات در پارامترها می‌توان تا خرابی یک تجهیز صبر نمود یا اینکه با توقف تجهیز تعمیرات اصلاحی یا غیرمترقبه را انجام داد و یا اینکه تعمیرات پیشگیرانه را به زودتر از موعد مقرر انتقال داد. سطح آستانه بالا و پایین و یا هشدار و خاموشی برای پارامترهای اساسی و بحرانی باید تعریف شود. سطح آستانه برای پارامترهای اساسی تعریف شد (جدول ۴) تا بتوان برای پیش‌بینی مدل از آنها استفاده نمود. این سطوح آستانه در ادامه قابل مشاهده است.

جدول ۴. مقادیر آستانه پایین و بالا برای پارامترها

ردیف	نام فارسی	حد پایین	حد متوسط	حد بالا
۱	سرعت توربین R.P.M	۷۱۶۰		۷۶۰۰
۲	سرعت توربین نیرو R.P.M	۵۳۳۰		۵۶۰۰
۳	حرارت E.G.T	۵۴۶	۶۴۲	۶۷۶
۴	حرارت یاتاقان‌های توربین نیرو - جلو	۵۲	۸۵	۹۵
۵	حرارت یاتاقان‌های توربین نیرو - افقی	۵۸	۸۵	۹۵
۶	حرارت یاتاقان‌های توربین نیرو - عقب	۴۸	۸۵	۹۵
۷	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۱	۵۰	۸۵	۹۵
۸	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۲	۴۶	۸۵	۹۵
۹	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۳	۵۶	۸۵	۹۵
۱۰	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۱	۶۰	۸۵	۹۵
۱۱	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۲	۶۰	۸۵	۹۵
۱۲	حرارت یاتاقان‌های جعبه دنده - سرعت کم ۳	۵۴	۸۵	۹۵
۱۳	حرارت یاتاقان‌های کمپرسور - جلو	۶۲	۸۵	۹۵
۱۴	حرارت یاتاقان‌های کمپرسور - عقب	۶۹	۸۵	۹۵
۱۵	حرارت یاتاقان‌های کمپرسور - تراست ۱	۴۸	۱۱۰	۱۲۰
۱۶	حرارت یاتاقان‌های کمپرسور - تراست ۲	۶۷	۱۱۰	۱۲۰
۱۷	لرزش یاتاقان‌های توربین نیرو - جلو	۰/۶۹	۲	۳
۱۸	لرزش یاتاقان‌های توربین نیرو - عقب	۰/۸۳	۲	۳
۱۹	لرزش یاتاقان‌های توربین نیرو - ضربه گیر	۷/۱۲	۱۳	۱۷
۲۰	لرزش یاتاقان‌های جعبه دنده سرعت کم افقی	۰/۹۳	۲	۳
۲۱	لرزش یاتاقان‌های جعبه دنده سرعت کم عمودی	۱/۴	۲	۳
۲۲	لرزش یاتاقان‌های جعبه دنده سرعت زیاد افقی	۱/۲	۲	۳
۲۳	لرزش یاتاقان‌های جعبه دنده سرعت زیاد عمودی	۰/۵۹	۲	۳
۲۴	لرزش یاتاقان‌های کمپرسور - جلو	۱	۲	۳
۲۵	لرزش یاتاقان‌های کمپرسور - عقب	۱/۲	۲	۳
۲۶	لرزش یاتاقان‌های کمپرسور - ضربه گیر	۱/۲	۱۳	۱۷
۲۷	دمای ترموکوپل ۱	۵۶۸		۶۲۸
۲۸	دمای ترموکوپل ۲	۵۴۹		۶۰۹
۲۹	دمای ترموکوپل ۳	۵۵۸		۶۱۸
۳۰	دمای ترموکوپل ۴	۵۱۳		۵۷۳

۳۱	دمای ترموکوپل ۵	۵۴۵	۶۰۵
۳۲	دمای ترموکوپل ۶	۵۴۳	۶۰۳
۳۳	دمای ترموکوپل ۷	۵۸۲	۶۴۲
۳۴	لرزش یاتاقان‌های کمپرسور-جلو	۱	۲

### شناخت خوشه‌های خروجی

برای طراحی مدل پیش‌بینی از نرم‌افزار Rapid Miner استفاده شده است. برای طراحی مدل بدین گونه عمل شد که ابتدا داده‌های خرابی بر حسب تاریخ به صورت صعودی مرتب شدند تا فاصله بین رخداد خرابی از یک مورد تا مورد بعدی قابل تشخیص باشد. به دلیل تکراری بودن ۴ مورد خرابی تعداد داده‌های خرابی به ۲۸ مورد کاهش یافت.

با توجه به این مرتب‌سازی می‌توان برای پیش‌بینی مدت زمان خرابی سه گروه مختلف تعریف نمود.

ابتدا یک بازه زمانی در نظر گرفته می‌شود. (XX-YY)

حد پایین مقدار YY است و حد بالا مقدار XX است.

اگر مدت زمان باقیمانده تا خرابی از XX روز بزرگتر باشد خوشه A است.

در غیر این صورت اگر مدت زمان باقیمانده تا خرابی از YY روز بزرگتر باشد خوشه B است.

در غیر این صورت خوشه C خواهد بود.

به زبان دیگر خوشه‌ها به شکل زیر تعریف می‌شوند:

(A) خرابی قبل از XX روز اتفاق نخواهد افتاد، بنابراین عملیاتی نیاز هست.

(B) خرابی در XX روز آینده اتفاق افتاد، برای تعمیرات شروع به برنامه‌ریزی نمایید.

(C) خرابی در YY روز آینده اتفاق خواهد افتاد، تعمیرات به زودی مورد نیاز است.

برای یافتن حدود XX و YY در بین ۲۸ حالت خرابی مورد نظر کمترین و بیشترین زمان بین دو خرابی را

در نظر گرفته و سپس با تغییر حدود بازه سعی شده است بهترین مقادیر را برای XX و YY با تحلیل و تفسیر

مشخص نمود که ادامه این فرایند بررسی خواهد شد.

**طراحی مدل با استفاده از روش شبکه عصبی Multilayer Perceptron.** روشی که در این پروژه برای

طراحی مدل مورد استفاده قرار گرفته است یکی از متدهای شبکه عصبی به نام Multilayer Perceptron

است. MLP یک نوع شبکه عصبی Feed forward است که از back propagation برای دسته بندی

نمونه‌ها استفاده می‌کند [7].

شبکه MLP مجموعه ای از نورون‌ها است که در چند لایه مختلف پشت سر هم قرار گرفته‌اند مقادیر

ورودی پس از ضرب در وزن‌های موجود در گذرگاه‌های بین لایه‌ها به نورون بعدی رسیده و در آن جا با هم

جمع می‌شوند و پس از عبور از تابع شبکه مربوطه خروجی نورون‌ها را تشکیل می‌دهند. در پایان خروجی به

دست آمده با خروجی مورد نظر مقایسه شده و خطای به دست آمده جهت اصلاح وزن‌های شبکه به کار می‌رود

و این فرایند تکرار می‌شود تا وزن‌های بهینه بدست آیند. هدف آموزش مدل با این روش این است که با

اختصاص وزن‌های مناسب به شبکه عصبی خروجی که به واقعیت نزدیک‌تر باشد به دست آید. برای ساخت این

نوع شبکه عصبی پارامترهایی مورد استفاده قرار می‌گیرد.

پارامتر اول نرخ یادگیری (LR) نام دارد که مقدار وزن‌هایی است که برای یادگیری مدل به روز می‌شود.

پارامتر دوم (M) است که برای تغییر وزن‌های شبکه عصبی است. و پارامتر سوم تعداد لایه‌های مخفی (H) در

شبکه عصبی است [۷].

برای بدست آوردن مقادیر مطلوب و بهینه برای پارامترها ذکر شده برای یک بازه زمانی تعریف شده پارامترهای مختلف را تغییر داده و با بدست آوردن دقت پیش‌بینی مدل برای مقادیر مختلف پارامترها در نهایت آن مقادیری که دقت بالاتری داشتند انتخاب شده و مدل نهایی شبکه عصبی با آن مقادیر طراحی می‌شود. برای بازه زمانی (۳-۱۵) از مقادیر پیش فرض شبکه عصبی استفاده کرده و مقدار پارامتر M را تغییر داده تا بتوان مقدار مطلوب و بهینه را پیدا نمود. نمونه‌ای از این تغییر پارامتر را در جدول ۵ مشاهده می‌کنید. در این جدول ۵ مشخص است که مقادیر LR, H با عنوان نرخ یادگیری و تعداد لایه مخفی به‌طور پیش فرض گرفته شده است و مقدار M برای تغییر وزن‌ها در شبکه عصبی تغییر داده شده تا بتوان مقدار M بهینه با بالاترین دقت را در ادامه برای طراحی و اجرای مدل استفاده نمود.

جدول ۵. نتیجه تغییر مقادیر پارامترها در روش MLP

Inputs	M	LR	H	PRECISION (%)
FAC1...FAC7	۱/۰	۲/۰	a=۴	۶۲٪/۰۰٪+/-۳۱/۴۸
FAC1...FAC7	۲/۰	۲/۰	a=۴	۶۲٪/۰۰٪+/-۳۱/۵۰
FAC1...FAC7	۴/۰	۲/۰	a=۴	۰۰٪/۰۰٪+/-۳۵/۴۵
FAC1...FAC7	۵/۰	۲/۰	a=۴	۰۰٪/۰۰٪+/-۳۵/۴۵
FAC1...FAC7	۷/۰	۲/۰	a=۴	۰۰٪/۰۰٪+/-۳۵/۴۵

همان‌طور که مشاهده می‌نمایید تغییرات در پارامترها انجام شده و در نهایت مقداری که دارای دقت بالاتری در پیش‌بینی است به عنوان مقدار اصلی پارامتر برای طراحی مدل استفاده می‌شود با بررسی و این تغییر مقادیر پارامترها و مقایسه دقت پیش‌بینی سرانجام مقادیر بهینه و مطلوب برای هر پارامتر بدست آمد که در ادامه طراحی و ارزیابی مدل از آنها استفاده شد.

مقدار بهینه برای پارامترها عبارتند از:  $M=0/2, LR=0/2, H=4$

بعد از تعیین مقادیر بهینه با طراحی مدل بر پایه شبکه عصبی MLP پیش‌بینی زمان خرابی انجام شد. و از مجموعه داده آموزشی و آزمایشی برای مدل پیش‌بینی استفاده شد.

جدول ۶. مجموعه داده آموزشی برای بازه زمانی (۳-۱۵)

ردیف	Fac1	Fac2	Fac3	Fac4	Fac5	Fac6	Fac7	failure
۱۰۵	-۰/۸۱۴۳	-۰/۳۷۹۴	-۳/۵۲۰۵۳	-۰/۶۵۴۳۴	-۰/۲۲۶۵۲	-۰/۵۹۷۹۸	-۰/۵۶۳۹۶	C
۱۲۱	۰/۲۶۴۷۱	-۰/۳۳۵۱۱	-۲/۴۷۷۷	-۱/۰۱۷۰۱	-۲/۳۴۵۹۸	-۰/۵۹۸۷۸	۹/۹۰۶۶۳	C
۱۲۵	۰/۵۹۶۸۹	-۰/۳۷۴۳۸	-۰/۲۰۷۴۷	-۱/۳۶۴۳۸	-۰/۱۸۵۴۹	-۰/۳۴۷۱۷	-۱/۰۱۱۲۸	C
۱۴۸	۰/۸۲۱۶۶	-۰/۲۹۱۱۴	-۱/۰۸۶۴۳	-۰/۸۵۱۵۶	-۱/۰۵۱۲	-۲/۲۴۴۱۲	-۰/۰۲۲۶۳	C
۱۵۶	-۰/۵۴۴۴۱	۰/۱۷۱۸	-۱/۵۰۷۸۲	-۲/۰۸۱۷۹	-۰/۵۰۵۳۹	-۰/۵۵۷۴۵	-۰/۰۶۰۹۹	C
۱۶۹	-۰/۸۸۱۱۴	-۰/۲۴۱۹۷	-۱/۱۱۴۶۴	-۲/۴۴۳۳	-۰/۵۸۰۰۲	۲/۲۲۰۵۱	-۰/۳۴۶۷۳	b
۲۰۹	-۱/۰۰۰۶۶	-۰/۰۵۹۳۹	-۱/۹۸۱۱۴	۱/۸۴۱۰۹	-۰/۰۸۵۸۱	-۰/۱۵۵۶۲	-۰/۴۶۶۲۵	b
۲۲۱	۰/۰۴۶۴۷	۰/۳۳۱۱	-۳/۳۱۴۷۱	-۰/۲۶۳۳۷	۱/۱۸۷۵	-۰/۱۱۳۳۲	-۰/۱۳۴۰۵	C
۲۵۲	-۰/۱۷۳۳	-۰/۰۳۶۹۸	۱/۰۰۳۱۲	۱/۴۳۳۹	-۱/۱۷۷۹۳	-۰/۱۳۳۹۶	-۰/۶۳۲۹۴	C
۲۹۵	-۰/۹۵۰۴۵	-۱۲/۷۷۷۳	-۰/۴۲۸۹۵	۱/۰۴۹۸۹۱	-۰/۰۹۹۱۷	-۰/۵۸۴۷۲	-۱/۰۸۰۵۳	C
۳۰۰	۰/۳۴۶۳۷	-۰/۱۶۰۴۲	-۳/۵۱۳۵۱	۰/۷۷۴۶۴	-۰/۵۰۷۴۴	-۰/۷۸۹۱۴	-۰/۲۷۱۰۲	b
۳۶۰	-۰/۰۵۸۷۶	-۰/۲۳۵۶۶	-۰/۵۳۷۹۷	-۰/۴۹۸۳۴	-۰/۱۹۹۷۹	-۰/۳۰۱۷۴	-۰/۲۱۶۵۶	C
۳۹۳	۱/۶۵۱۲۸	-۰/۴۵۱۶۱	-۱/۹۲۲۸۳	۱/۹۴۰۷۴	۲/۴۱۲۹۸	-۱/۱۳۱۰۴	-۱/۵۶۴۵۷	C
۴۲۱	۱/۷۰۴۵۹	-۰/۳۱۵۳۸	-۱/۴۵۵۱	-۲/۳۰۷۰۶	۱/۱۳۷۷۱	-۰/۴۴۵۹	۹/۷۵۰۷۶	C
۴۵۰	۰/۵۶۴۲۶	-۰/۱۶۳۵۲	۱/۲۱۴۶۵	۲/۴۴۶۷۶	-۰/۴۴۰۶۳	-۰/۱۶۲۰۴	-۰/۶۵۱۶۵	C
۴۸۳	۰/۸۳۸۰۲	-۰/۰۳۵۴۲	-۱/۶۰۲۵	-۱/۹۳۳۵۹	۲/۹۷۱۵۷	-۰/۲۷۳۱۸	-۰/۵۵۵۸۵	a
۵۷۹	-۱/۳۹۳۶۶	-۰/۳۸۰۰۵	-۰/۷۰۶۸۳	-۰/۲۵۱۸۷	-۰/۲۸۹۴۲	-۱/۰۶۶۳۳	-۰/۰۱۱۳۷	a
۷۶۱	-۱/۵۲۵۵۶	-۰/۰۱۷۵۹	۰/۷۶۷۲۴	۰/۷۹۱۲۷	-۰/۷۶۳۰۴	-۰/۶۱۱۵۳	۳/۵۱۲۸۴	B

ردیف	Fac1	Fac2	Fac3	Fac4	Fac5	Fac6	Fac7	failure
۷۸۸	-۰/۴۰۹۱	-۰/۲۵۸۸۲	-۰/۱۹۵۷۳	-۰/۱۳۳۳۸	-۰/۴۸۱۳۷	-۰/۲۵۰۵۱	-۰/۱۹۲۳۴	<b>B</b>
۸۵۶	-۰/۶۶۵۵	-۰/۵۶۰۲۳	-۰/۶۷۰۰۴	۲/۹۵۰۱۵	۱/۱۱۷۰۶	-۰/۱۳۹۹۹	-۰/۹۷۸۸۷	<b>b</b>

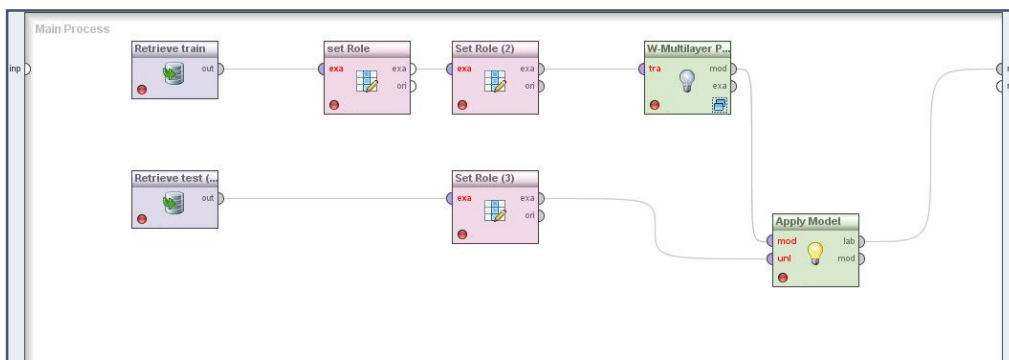
در مجموعه داده‌های آموزشی برچسب هدف به عنوان خوشه مورد نظر از بین سه خوشه A, B, C و با توجه به بازه زمانی خرابی بعدی اختصاص داده شد. سپس با یادگیری مدل مجموعه داده آزمایشی به عنوان ورودی به مدل داده شد و مدل با توجه به آموزش اقدام به پیش‌بینی و برچسب گذاری خرابی احتمالی نمود. در هر یک از بازه‌های زمانی ذکر شده مجموعه داده آموزشی و مجموعه داده آزمایشی حاوی تعدادی رکورد برای پیش‌بینی در نظر گرفته شد. در جدول ۶ از مجموعه داده آموزشی و آزمایشی را مشاهده می‌نمایید. همان‌طور که در این جدول مشخص است ستون failure نشان دهنده خوشه خرابی مورد نظر است.

لذا برای ردیف ۴۵۰ خرابی بعدی در خوشه A قرار دارد و خرابی قبل از ۱۵ روز اتفاق نخواهد افتاد. یا اینکه در ردیف ۲۹۵ خوشه بعدی B خواهد بود به این معنی که خرابی بعدی در مدت زمان ۱۵ روز آینده اتفاق خواهد افتاد. این مجموعه داده با هدف آموزش مدل و به عنوان ورودی به مدل طراحی شده و با درخت تصمیم داده خواهد شد و سپس با یادگیری مدل مجموعه داده آزمایشی برای تشخیص و پیش‌بینی به مدل داده می‌شود. در ادامه نمونه مجموعه داده آزمایشی (جدول ۷) نیز نشان داده شده است.

جدول ۷. مجموعه داده آزمایشی برای بازه زمانی (۳-۱۵)

ردیف	Fac1	Fac2	Fac3	Fac4	Fac5	Fac6	Fac7	failure
۴	-۲/۰۱۲۸۹	-۰/۱۷۹۳۷	-۲/۴۲۴۵۲	-۰/۷۷۸۶۷	-۲/۱۱۶۱۶	۱/۱۵۵۱۸	-۰/۵۳۲۰۳	
۳	-۱/۹۹۲۲۹	-۰/۲۸۵۸۴	-۲/۳۹۷۷۹	-۰/۷۸۸۵۹	-۲/۱۲۷۴	۱/۱۴۸۵۱	-۰/۵۳۲۷	
۱	-۱/۴۲۹۶۷	-۰/۲۶۲۷۹	-۴/۹۷۲۰۶	۱/۱۶۹۸۹	-۱/۹۶۲۹۳	۲/۸۱۷۰۶	-۱/۴۳۷۲۵	
۱۳	-۰/۶۳۴۵	-۰/۱۰۹۱۹	-۰/۴۷۱۹۸	-۱/۱۵۲۲۹	-۲/۳۴۹۵۱	۱/۸۵۱۷۴	-۱/۸۸۸۵۳	
۳۵	-۰/۷۰۶۰۴	-۰/۱۶۴۸۸	-۲/۱۶۷۲۷	۱/۵۹۹۶۶	-۰/۶۰۱۱	۱/۴۰۸۹	-۰/۹۷۳۳۷	
۸۵	-۰/۷۵۷۱۶	-۰/۱۷۶۲	-۰/۴۳۸۳۱	-۱/۰۳۸۸۶	-۱/۰۳۱۷۳	۱/۷۵۳۳۴	-۲/۳۶۲۱۴	
۹۳	-۲/۳۶۱۶۴	-۰/۲۵۶۰۷	-۰/۴۴۴۴۴	-۰/۷۳۱۷۱	-۱/۴۹۸۳	-۰/۴۷۴۱۷	-۰/۳۵۵۲۳	
۹۷	-۲/۵۷۱۵۶	-۰/۰۳۰۷۷	-۰/۷۴۱۸۵	۱/۵۴۳۹	-۲/۴۲۴۹۱	-۰/۰۷۹۸۹	-۰/۰۶۵۵۴	

همان‌طور که مشخص است این مجموعه داده آزمایشی است و ستون برچسب failure خالی است و مدل بایستی بتواند با توجه به یادگیری برچسب مورد نظر را پیش‌بینی نماید. در ادامه مدل طراحی شده با استفاده از شبکه عصبی MLP را مشاهده می‌نمایید.



شکل ۲. طراحی مدل پیش‌بینی با روش MLP

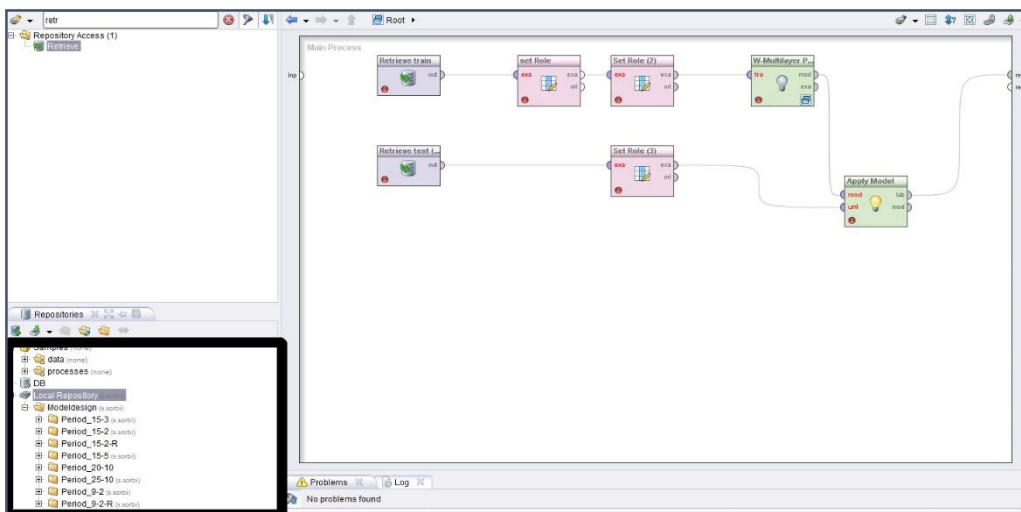
نتیجه پیش بینی مدل توسط نرم افزار RapidMiner در جدول ۸ نشان داده شده است.

جدول ۸. پیش بینی مدل بر پایه MLP با مقایسه ای داده های آموزشی و آزمایشی (۵ پارامتر خاص - ۸ پارامتر عمومی)

ردیف	سطر	حد اطمینان خوشه C	حد اطمینان خوشه D	حد اطمینان خوشه A	پیشگویی خوشه های خرابی	Fac1	Fac2	Fac3	Fac4	Fac5	Fac6	Fac7	نماد
۱	۴	۰/۰۵۰	۰/۹۳۲	۰/۰۱۸	b	-۲/۰۱۳	۰/۱۷۹	-۲/۴۲۵	۰/۷۷۹	۲/۱۱۶	۱/۱۵۵	-۰/۵۳۲	?
۲	۳	۰/۰۵۴	۰/۹۲۹	۰/۰۱۷	b	-۱/۹۹۲	۰/۲۸۶	-۲/۳۹۸	۰/۷۸۹	۲/۱۲۷	۱/۱۴۹	-۰/۵۳۳	?
۳	۱	۰/۲۳۸	۰/۷۵۸	۰/۰۰۴	c	-۱/۴۳۰	۰/۲۶۳	-۴/۹۷۲	۱/۱۷۰	۱/۹۶۳	۲/۸۱۷	-۱/۴۳۷	?
۴	۱۳	۰/۹۹۹	۰/۰۰۱	۰/۰۰۰	c	۰/۶۳۵	۰/۱۰۹	-۰/۴۷۲	۱/۱۵۲	۲/۳۵۰	۱/۸۵۲	-۱/۸۸۹	?
۵	۳۵	۰/۱۲۷	۰/۸۵۹	۰/۰۱۴	b	-۰/۷۰۶	۰/۱۶۵	-۲/۱۶۷	۱/۶۰۰	۰/۰۶۰	۱/۴۰۹	۰/۹۷۳	?
۶	۸۵	۰/۲۲۹	۰/۷۵۷	۰/۰۱۴	b	-۰/۷۵۷	۰/۱۷۶	-۰/۴۲۸	۱/۰۳۹	۱/۰۳۲	۱/۷۵۳	-۲/۳۶۲	?
۷	۹۳	۰/۰۱۵	۰/۸۹۲	۰/۰۹۳	b	-۲/۳۶۲	۰/۲۵۶	-۰/۴۴۴	۰/۷۳۲	۱/۴۹۸	-۰/۴۷۴	-۰/۳۵۵	?
۸	۹۷	۰/۰۴۷	۰/۹۳۰	۰/۰۲۴	c	-۲/۵۷۲	۰/۰۳۱	-۰/۷۴۲	۱/۵۴۴	۳/۴۲۵	۰/۰۸۰	-۰/۰۶۶	?

ستونی که با کادر مشکی رنگ مشخص شده است پیش بینی خوشه مورد نظر توسط مدل بر پایه شبکه عصبی MLP است.

این فرایند و پیش بینی برای ۵ بازه زمانی متفاوت دیگر که در بالا ذکر شده بود انجام شد. تا در نهایت بتوان تشخیص داد کدام بازه زمانی و محدوده برای متغیرهای XX و YY پیش بینی دقیق تر و مناسب تری می تواند ارائه دهد. در شکل ۳ انجام این فرایند برای بازه های زمانی متفاوت مشخص است.



شکل ۳. طراحی مدل MLP برای بازه های زمانی مختلف با نرم افزار RapidMiner

در سمت راست شکل ۳ مشخص است که این مدل برای بازه‌های زمانی مختلف اجرا شده است تا بتوان بازه زمانی بهینه که پیش‌بینی دقیق‌تری از خروجی را ارائه می‌دهد شناسایی نمود.

**ارزیابی مدل بر اساس روش MLP.** فرایند اجرا و آزمایش مدل برای بازه‌های مختلف انجام شد. در هر بازه زمانی درصد دقت و میزان درست پیش‌بینی برای سه دسته A,B,C مشخص شد. به عنوان نمونه برای بازه زمانی ۱۵ روز و ۳ روز جدول‌های ۹ تا ۱۱ قابل مشاهده است. در ادامه به ارزیابی مدل طراحی شده در بازه‌های متفاوت برای پیش‌بینی خوشه‌های A,B,C پرداخته شده است. و بررسی شده که مدل پیش‌بینی رخداد خرابی در بازه زمانی را بهتر می‌تواند انجام دهد.

جدول ۹. نتایج پیش‌بینی خروجی در روش MLP

Actual Class	Predicted Class		
	A	B	C
A	۰	۰	۲
B	۱	۱	۳
C	۲	۲	۸

همچنین درصد دقت پیش‌بینی برای این روش در بازه زمانی مذکور مطابق جدول زیر است.

جدول ۱۰. درصد دقت پیش‌بینی در روش MLP

Actual Class	TP Rate	FP Rate	Precision
A	۰	۱	۰
B	۰/۳۳۳۳۳	۰/۶۶۶۶۷	۰/۵
C	۰/۶۶۶۶۷	۰/۳۳۳۳۳	۰/۶۱۵۲۸۵
Weighted Average	۰/۳۳۳۳۳	۰/۶۶۶۶۷	۰/۳۷۱۷۹۵

این ارزیابی برای تمام بازه‌های زمانی مورد نظر انجام شد و نتایج آن در جدول ۱۱ وجود دارد.

جدول ۱۱. مقایسه بازه‌های زمانی مختلف با روش MLP برای پیش‌بینی بر حسب خرابی در مدل طراحی شده

XX-YY	خوشه A			خوشه B			خوشه C		
	TP	FP	Precision	TP	FP	Precision	TP	FP	Precision
۲۵-۱۰	۰	۱	۰	۰/۶۶۶۶	۰/۳۳۳۳	۰/۵	۰/۷۵	۰/۲۵	۰/۸۵
۲۰-۱۰	۰	۱	۰	۰/۶۶۶۶	۰/۳۳۳۳	۰/۵	۰/۷۵	۰/۲۵	۰/۸۵
۱۵-۵	۰	۱	۰	۰	۱	۰	۰/۶	۰/۴	۰/۶۴
۱۵-۳	۰	۱	۰	۰/۳۳۳۳	۰/۶۶۶۶	۰/۵	۰/۶۶	۰/۳۳	۰/۶۱
۱۵-۲	۰	۱	۰	۰/۶	۰/۴	۰/۵۴۵۴	۰/۱۲۵	۰/۸۷۵	۰/۱۴
۱۵-۲-r	۰	۱	۰	۰/۶۶۶۶	۰/۳۳۳۳	۰/۶	۰/۶۶	۰/۳۳	۰/۶۶
۹-۲	۰/۲	۰/۸	۰/۱۴۲۸۵۷	۰/۵۷	۰/۴۲	۰/۴۴	۰/۲۵	۰/۷۵	۰/۵
۹-۲-r	۰/۳۳۳۳	۰/۶۶۶۷	۰/۲	۰/۲۸	۰/۷۱	۰/۴	۰/۷۷۷۷	۰/۲۲۲۲	۰/۷۷

همان‌طور که در جدول ۱۱ مشخص است درصد دقت پیش‌بینی، TP و FP برای هر بازه زمانی و هر خوشه قابل مشاهده است و نتیجه اینکه مدل طراحی شده بر پایه درخت تصمیم درصد دقت بالاتری در بازه‌های زمانی (۲۵-۱۰) و (۲۵-۱۵) و در خوشه C داشته است و این نشان می‌دهد که روش MLP توانایی پیش‌بینی برای



خوشه C دارد. به این معنی که مدل طراحی شده بر پایه MLP می‌تواند خرابی که در ۱۰ روز آینده اتفاق بیفتد را از قبل با درصد احتمال ۸۵٪ پیش‌بینی نماید.

### ۵. نتیجه‌گیری و پیشنهادها

در این مقاله سعی شد با کمک روش‌های داده‌کاوی یک سیاست‌گذاری در خصوص پیش‌بینی رخداد خرابی برای تجهیز توربین طراحی و توسعه یابد. استفاده از روش‌های تجربی و دستی و فیزیکی نمی‌توانست کمک قابل توجهی به تیم نگهداری و تعمیرات نماید و هشدارهای به‌موقع و پیش‌بینی دقیقی از رخداد خرابی تجهیز در آینده داشته باشد. بنابراین قرار شد با کمک روش‌های مبتنی بر داده‌های انباشته و روش‌های داده‌کاوی مدلی طراحی شود تا بتواند به‌طور دقیق و با درصد احتمال بالا پیش‌بینی دقیقی از رخداد خرابی در آینده داشته باشد. واضح است پیش‌بینی رخداد خرابی از قبل کمک شایانی به تیم نگهداری و تعمیرات کرده و آنها را از قبل برای انجام عملیات مورد نظر برای رفع خرابی آماده می‌کند. برای تعمیرات برنامه‌ریزی کرده، کارگاه و وسایل را آماده نموده و در صورت نیاز به سفارش قطعه و کالا می‌پردازد.

همین موضوع می‌تواند اثر زیادی در کاهش هزینه‌های نگهداری و تعمیرات داشته باشد. از تعمیرات غیرمترقبه و ناگهانی که موجب توقف برنامه‌ریزی نشده تجهیز و کارخانه می‌شود جلوگیری نموده و اثر منفی روی روند تولید و بهره‌وری را کاهش می‌دهد.

به همین منظور با استفاده از مشاهده مستمر و زمان‌بندی شده و وضعیت و شرایط تجهیز و همچنین با بررسی حالات خرابی با کمک داده‌های پیشین، مجموعه داده‌های دقیق و با کیفیت بدست آمد، سپس ارتباط بین داده‌های وضعیت و داده‌های خرابی با کمک روش آنالیز داده PCA کشف شد تا بتوان از مجموعه داده‌های مرتبط به عنوان ورودی برای طراحی مدل استفاده نمود. در گام بعد با کمک روش داده‌کاوی شبکه عصبی MLP مدل طراحی شده برای پیش‌بینی رخداد خرابی در بازه‌های زمانی متفاوت و با هدف تعیین برچسب خروجی از بین سه خوشه A, B, C مورد آزمایش و اجرا قرار گرفت و سپس اطلاعات، آمار و نتایج خروجی به‌طور دقیق و کامل و جداگانه در قالب نمودار و جدول و شاخص‌های مختلف ارائه شد تا دقت اندازه‌گیری روش مورد نظر را مشخص نماید که مشاهده شد روش شبکه عصبی MLP با دقت بالایی توانایی پیش‌بینی رخداد خرابی در بازه‌های زمانی مختلف در آینده را دارد.

این مدل و پروژه برای یک تجهیز خاص به نام توربین مورد بررسی و اجرا قرار گرفت. به منظور پیش‌بینی رخداد خرابی برای کل سازمان و کارخانه‌ها باید این مدل برای همه تجهیزات اساسی و بحرانی توسعه یابد و مورد آزمایش و بررسی قرار بگیرد تا بتواند تاثیر بسزایی در بهبود شرایط نگهداری و تعمیرات سازمان ایجاد نماید. بنابراین توسعه و اجرای مدل پیش‌بینی رخداد خرابی برای تصمیم‌گیری به عنوان یک پیشنهاد برای آینده مطرح می‌شود. که نیاز به بررسی و تحلیل دقیق از پارامترها، خرابی‌ها و شرایط هر تجهیز به صورت جداگانه دارند.

مشاهده شرایط و وضعیت تجهیزات می‌تواند مستمر با زمان‌بندی شده باشد. از آنجایی که مشاهده مستمر شرایط می‌تواند گران و هزینه‌بر باشد و در برخی مواقع اطلاعات غیردقیق بدهد، روش مشاهده زمان‌بندی شده شرایط و وضعیت تجهیزات به عنوان یک روش موثر و بهینه پیشنهاد می‌شود. بنابراین تعیین مدت زمان بهینه برای مشاهده زمان‌بندی شده برای هر تجهیز با توجه به نوع و کارکرد آن و با در نظر گرفتن هزینه و نرخ خرابی می‌تواند پیشنهادی برای تحقیقات آینده باشد.

این مدل پشیمان تصمیم پیش‌بینی رخداد خرابی بر اساس سیاست اعمالی می‌تواند پیش‌بینی نماید که خرابی در آینده با چه درصد احتمال و دقتی اتفاق خواهد افتاد ولی این مهندس نگهداری و تعمیرات است که باید با توجه به مواردی از جمله وضعیت کارگاه، اولویت تعمیر، قطعات و کالای مورد نیاز در دسترس و نیاز شدید تجهیز به تعمیر تصمیم بگیرد چه زمانی برای تعمیر یک تجهیز خاص بهتر است. بنابراین یکی دیگر از پیشنهادها

تحقیق برای آینده توسعه مدلی برای تعیین زمان بهینه نگهداری و تعمیرات تجهیزات در حال خرابی با توجه به بررسی شرایط و وضعیت کلی تعمیر و نگهداری است.

### منابع

1. Baptista, M., Sankararaman, S., De Medeiros, I.P., Nascimento Jr, C., Prendinger, H., & Henriques, E.M. (2018). Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling, *Computers & Industrial Engineering*, 115, 41-53.
2. Biswal, S., & Sabareesh, G. (2015). Design and development of a wind turbine test rig for condition monitoring studies, *Proceeding of International Conference on Industrial Instrumentation and Control (ICIC)*, IEEE, 891-896.
3. Chang, C.-C., & Lin, C.-J. (2004). LIBSVM: a library for support vector machines.
4. Felix Salfner, M. L., & Mirosla, W. (2010). A survey of online failure prediction methods, *CM Computing Surveys*, 42, 42.
5. Garga, A. K., & Byington, C. S. (2011). Data fusion for developing predictive diagnostics for electromechanical systems. *Handbook of. Multisensor Data Fusion*, 10, 701 –737.
6. Giuseppe Curcur, G., & Alberto, L. (2010). A predictive maintenance policy with imperfect monitoring, *Reliability Engineering and System Safety*, 95, 9.
7. Ignat, S.S., & Stoian, I. (2012). Support/or condition based maintenance operating equipment performances monitoring, *Automation Quality and Testing Robotics (AQTR)*, 2012, IEEE International Conference on, 6.
8. Jardine, A.K., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance, *Mechanical systems and signal processing*, 20, 1483-1510.
9. Jezzini, A., Ayache, M., Elkhansa, L., Makki, B., & Zein, M. (2013). Effects of predictive maintenance (PdM), Proactive maintenace (PoM) & Preventive maintenance (PM) on minimizing the faults in medical instruments, *Proceeding of. 2013 2nd International Conference on Advances in Biomedical Engineering*, IEEE, 53-56.
10. Katakey, R. (2016) Energy giant shell says oil demand could peak in just five years, *Bloomberg*, <http://www.bloomberg.com/news/articles/2016-11-02/europe-s-biggest-oil-company-thinksdemand-may-peak-in-5-years>
11. Khoshairat, M., Khashei, M., & Molaverdi, N. (2018). A review of machine learning models in the field of predictive maintenance and repairs, *16th International Conference on Industrial Engineering*, Tehran
12. Mark Last, A. S., & Halasya Siva, S. (2010). Predictive maintenance with multi-target classification models, *Intelligent information and database systems*, 10.
13. Mustakerov, I., & Borissova, D. (2013). An intelligent approach to optimal predictive maintenance strategy defining, *Innovations in Intelligent Systems and Applications (INISTA)*, 2013 IEEE International Symposium on, 10-22.
14. Khanh T.P., & Kamal, M. (2019). A new dynamic predictive maintenance framework using deep learning for failure prognostics, *Reliability Engineering & System Safety*, 188, 251-262
15. Peres, R.S., Rocha, A.D., Leitao, P., & Barata, J. (2018). IDARTS–Towards intelligent data analysis and realtime supervision for industry 4.0, *Computers in Industry*, 101, 138-146.
16. Shannon, K. (2012). Asset life cycle management optimizes performance. *The American oil and gas reporters*. November 2012 Exclusive Story. <http://www.aogr.com/web-exclusives/exclusivestory/asset-life-cycle-management-optimizes-performance>.

17. Shin, J.-H., Jun, H.-B., & Kim, J.-G. (2018). Dynamic control of intelligent parking guidance using neural network predictive control, *Computers & Industrial Engineering*, 120, 15-30.
18. Susto, G.A., McLoone, S., Pagano, D., Schirru, A., Pampuri, S., & Beghi, A. (2013). Prediction of integral type failures in semiconductor manufacturing through classification methods, *Proceeding of. 2013 IEEE 18<sup>th</sup> Conference on Emerging Technologies & Factory Automation (ETFA)*, IEEE, 1-4.
19. Yeo, B. (2010). *Shale Gas versus CSG - Shale the New Flavour*, May/June, Aspermount Limited, 22-25.