



## مدل پیش‌بینی زمان کارکرد باقی‌مانده تا وضعیت بحرانی بر اساس سوابق تحلیل روغن موتور با راهکار داده‌کاوی؛ ص ۷۷-۹۶

سید کمال چهارسوقی<sup>۱</sup>، ابوالفضل نبوی<sup>۲</sup>، بابک تیمورپور<sup>۳</sup>

نوع مقاله: پژوهشی

تاریخ دریافت: ۱۳۹۸/۰۸/۰۴

تاریخ پذیرش: ۱۳۹۸/۱۰/۲۵

### چکیده

یکی از جنبه‌های مهم نگهداری و تعمیرات مبتنی بر شرایط (CBM) پیش‌بینی عمر مفید باقی‌مانده (RUL) بر اساس سوابق گذشته و وضعیت کنونی دستگاه است و تحلیل روغن روانکار یکی از روش‌های CBM است که به علت تماس مستقیم با دستگاه شرایطش بیانگر وضعیت سلامتی دستگاه است. در فرآیند CBM داده‌های زیادی تولید و انباشته می‌شود اما دانش موجود در این داده‌ها به‌طور کامل قابل‌درک نیست و باعث ضایع شدن منابعی گران‌بها می‌شود. برای استخراج اطلاعات و دانش از این داده‌ها به استفاده از روش‌هایی مانند داده‌کاوی نیاز است. در این پژوهش بر اساس تعریف RUL بهترین مدل پیش‌بینی زمان کارکرد باقی‌مانده تا وضعیت بحرانی برای یک مدل بلدوز بر اساس سوابق تحلیل روغن موتور (مجموعه داده‌ای با ۲۷۰۰ رکورد و ۱۲۹ ویژگی) با راهکار داده‌کاوی ساخته شده است. برای ساخت بهترین مدل، بعد از آماده‌سازی مجموعه داده مناسب با ۴۹ رکورد و چهار ویژگی مدل‌هایی با روش‌های رگرسیون و شبکه عصبی ساخته شده است. به علت امکان انجام شدن فعالیت تعویض روغن در فواصل نمونه‌گیری‌ها، مدل‌ها با دو روش اعمال مقادیر ویژگی‌های مستقل ساخته شده‌اند. بر اساس ارزیابی عملکرد مدل‌ها بهترین مدل با شبکه عصبی و روش دوم اعمال مقادیر ویژگی‌های مستقل که استفاده از مقادیر جدید (تجمعی) دو ویژگی مستقل (Fe, Cu) و مقدار واقعی (غیر تجمعی) یک ویژگی مستقل (Vis40) بوده با خطای پیش‌بینی  $23526.662 \pm 958559.033$  ساخته شده است.

**واژگان کلیدی:** نگهداری و تعمیرات مبتنی بر شرایط، تحلیل روغن، عمر مفید باقی‌مانده، داده‌کاوی

۱ استاد دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران (نویسنده مسئول) / skch@modares.ac.ir

۲ کارشناسی ارشد، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران / a.nabavi124@gmail.com

۳ استادیار، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران / b.teimourpour@modares.ac.ir

## مقدمه و بیان مسأله

نگهداری و تعمیرات<sup>۱</sup> همیشه بخشی جدایی‌ناپذیر از برنامه پشتیبانی هر سیستم بوده است (پرجاپاتی<sup>۲</sup> و همکاران، ۲۰۱۶). نگهداری و تعمیرات مبتنی بر شرایط<sup>۳</sup> (CBM) برنامه نگهداری و تعمیراتی است که تصمیمات را بر اساس اطلاعات جمع‌آوری شده از پایش وضعیت پیشنهاد می‌کند (جاردین<sup>۴</sup> و همکاران، ۲۰۰۶). CBM کاربردهای زیادی در کارخانه‌های تولیدی، صنعت فرایندی، نظامی، دریایی، وسایل نقلیه زمینی نیروی هوایی، زیرساخت فناوری اطلاعات، وسایل نقلیه تجاری و هواپیمایی دارد (پرجاپاتی و همکاران، ۲۰۱۶). تشخیص و پیش‌بینی دو جنبه مهم در برنامه CBM هستند (جاردین و همکاران، ۲۰۰۶). نوعی پیش‌بینی محاسبه عمر مفید باقی‌مانده<sup>۵</sup> (RUL) است که معمولاً زمان باقی‌مانده تا مشاهده خرابی نامیده می‌شود. روغن، روان‌کننده‌ای که در درون موتور یا دستگاه عملیاتی چرخش می‌کند و شیبه خون است که در بدن انسان زنده چرخش دارد (الروتیمی آکین توند<sup>۶</sup>، ۲۰۰۸). تحلیل روغن<sup>۷</sup> یکی از روش‌های CBM است. پایش وضعیت موتور با تحلیل روغن در کسب اطلاعات از وضعیت تجهیز و روغن روانکارش مفید خواهد بود (یاداو<sup>۸</sup> و همکاران، ۲۰۱۴). تحلیل متمرکز بر تحلیل عناصر فلزی موجود در روغن‌های روانکار استفاده‌شده ممکن است نیاز به نگهداری پیشگیرانه موتور را قبل از وقوع خسارت جبران‌ناپذیر نشان دهد.

دو هدف اصلی داده‌کاوی در عمل، پیش‌بینی و توصیف است (فیاد<sup>۹</sup> و همکاران، ۱۹۹۶b). داده‌کاوی یکی از توانمندسازهای CBM است. همه صنایع مانند تولید، خودرویی، نفت، گاز و ... مقادیر زیادی داده را به‌صورت دوره‌ای از منابع مختلف ذخیره می‌کنند. در کل داده‌های جمع‌آوری شده از حسگرها می‌تواند زیاد باشد و ممکن نیست تمام این داده‌ها مرتبط و معنی‌دار باشند. داده‌کاوی به استخراج داده معنی‌دار و ساخت مدل کمک می‌کند. ساخت مدل یافتن ارتباطی است که بیانگر چگونگی تغییر در یک یا مجموعه‌ای از متغیرها متأثر از متغیرهای دیگر است (پرجاپاتی و همکاران، ۲۰۱۶).

1 Maintenance

2 Prajapati

3 Condition Based Maintenance (CBM)

4 Jardine

5 Remaining Useful Life (RUL)

6 Olurotimi Akintunde

7 Oil Analysis

8 Yadav

9 Fayyad

در این پژوهش بر اساس تعریف RUL بهترین مدل برای پیش‌بینی زمان کارکرد باقی‌مانده تا وضعیت بحرانی یک مدل بولدوزر بر اساس سوابق تحلیل روغن موتور دیزل با راهکار داده‌کاوی ساخته شده است. برای ساخت بهترین مدل بعد از آماده‌سازی مجموعه داده مناسب مدل‌هایی با روش‌های رگرسیون و شبکه عصبی ساخته شده است. به علت امکان انجام شدن فعالیت تعویض روغن در فواصل نمونه‌گیری‌ها مدل‌های رگرسیون و شبکه عصبی با دو روش اعمال مقادیر ویژگی‌های مستقل بدین شرح ساخته شده‌اند:

روش اول: مدل با مقادیر واقعی (غیر تجمعی) سه ویژگی مستقل (Fe, Cu, Vis40) ساخته شده است. روش دوم: مدل بر اساس روش منگ<sup>۱</sup> و همکاران (۲۰۱۲) با مقادیر جدید (تجمعی) دو ویژگی مستقل (Fe, Cu) که عناصر فرسایشی بوده‌اند و مقادیر واقعی (غیر تجمعی) یک ویژگی مستقل (Vis40) که گرانبوی بوده، ساخته شده است.

بر اساس ارزیابی عملکرد مدل‌ها بهترین مدل پیش‌بینی زمان کارکرد باقی‌مانده تا وضعیت بحرانی با شبکه عصبی و روش دوم اعمال مقادیر ویژگی‌های مستقل ساخته شده است.

## مبانی نظری

### نگهداری و تعمیرات

رقابت سازمان‌ها به برنامه‌ریزی نگهداری و تعمیرات خوب نیاز دارد. مدیریت مناسب قابلیت اطمینان و زمان عملیاتی بیشتری را که به‌طور چشمگیر باعث کاهش ضایعات فرایندهای تولید می‌شود، فراهم می‌سازد (روش<sup>۲</sup> و همکاران، ۲۰۱۷). نگهداری و تعمیرات برای حفظ بهره‌وری، کیفیت بالا و سازمان‌های رقابتی بسیار نیاز است. این راهبردی است که دستگاه‌ها، تجهیزات و امکانات را به انجام وظایفشان در زمان موردنیاز قادر می‌سازد (موانزا و مباوه<sup>۳</sup>، ۲۰۱۷). در کل نگهداری و تعمیرات به‌عنوان تمام اقدامات مدیریتی و فنی انجام‌شده در مدت‌زمان استفاده برای حفظ یا بازگردانی عملکرد موردنیاز محصول یا دارایی تعریف می‌شود (شین و جون<sup>۴</sup>، ۲۰۱۵).

1 Meng

2 Ruschel

3 Mwanzaa & Mbohwa

4 Shin & Jun

### نگهداری و تعمیرات مبتنی بر شرایط

مفهوم نگهداری و تعمیرات مبتنی بر شرایط (CBM) را اولین بار در اواخر سال ۱۹۴۰ شرکت راه‌آهن ریو گرانده<sup>۱</sup> معرفی کرد و در ابتدا نگهداری و تعمیرات پیش‌گویانه<sup>۲</sup> نامیده شد. شرکت راه‌آهن از روش‌های CBM برای تشخیص نشت خنک‌کننده، روغن و سوخت در موتور با کمک تغییرات روند دما و فشار خوانده‌شده، استفاده می‌کرد (پرجاپاتی و همکاران، ۲۰۱۶). مفاهیم و کاربردهای CBM در صنایع مختلف طی سالیان ۱۹۵۰، ۱۹۶۰ و اوایل ۱۹۷۰ ظهور کرده است.

تعاریف مختلفی برای CBM وجود دارد (شین و جون، ۲۰۱۵). CBM برنامه نگهداری و تعمیراتی است که تصمیمات نگهداری و تعمیرات را بر اساس اطلاعات جمع‌آوری شده از پایش وضعیت پیشنهاد می‌کند (جاردین و همکاران، ۲۰۰۶). بازرسی‌های منظم (پایش وضعیت) می‌تواند برای درک بهتری از شرایط دستگاه استفاده شود و فعالیت‌های ناسازگار قبل از وقوع خرابی انجام شود (وونگ<sup>۳</sup> و همکاران، ۲۰۱۰). CBM تلاش می‌کند با انجام اقدامات نگهداری و تعمیرات تنها با وجود شواهد رفتار غیرطبیعی دارایی فیزیکی از اقدامات غیرضروری اجتناب کند (جاردین و همکاران، ۲۰۰۶) و می‌تواند به پیشینه‌سازی عمر مفید دارایی فیزیکی منجر شود (وونگ و همکاران، ۲۰۱۰).

روش‌های مختلفی برای پایش وضعیت مانند بازرسی دیداری تجهیزات، تحلیل ارتعاشات و تحلیل روغن وجود دارد (همان). دسته‌بندی رویکردهای مختلف پایش وضعیت توسط سازمان بین‌المللی استاندارد<sup>۴</sup> (ISO) در جدول شماره یک بیان شده است.

1 Rio Grande Railway

2 Predictive Maintenance

3 Wong

4 International Organization for Standardization

جدول ۱: روش‌های پایش وضعیت در استانداردهای ISO (ج. گویلن<sup>۱</sup> و همکاران، ۲۰۱۶)

13373-:2002 ISO 13373-:2005 ISO ISO 16587 ISO 18436-2	ارتعاش <sup>۲</sup>
ISO 18434-1:2008 ISO 18436-7	دمانگاری <sup>۳</sup>
ISO 22906:2007 ISO 29821-1:2011 ISO 18436-6	انتشار صوتی <sup>۴</sup> و فراصوت <sup>۵</sup>
ISO 14830-1 ISO 18436-5	سوده شناسی <sup>۶</sup> و روان کننده <sup>۷</sup>

نگهداری و تعمیرات مبتنی بر شرایط شامل سه مرحله زیر است: (جاردین و همکاران، ۲۰۰۶)  
 ۱- جمع‌آوری داده ۲- پردازش داده ۳- تصمیم‌گیری نگهداری و تعمیرات

### پیش‌بینی با نگهداری و تعمیرات مبتنی بر شرایط

مرحله پایانی برنامه CBM تصمیم‌گیری نگهداری و تعمیرات است (همان). روش‌های پشتیبانی تصمیم در برنامه CBM را می‌توان به دو دسته اصلی تشخیص و پیش‌بینی تقسیم کرد (همان). برنامه CBM می‌تواند برای تشخیص یا پیش‌بینی و یا هر دو استفاده شود. (جاردین و همکاران، ۲۰۰۶)

دو نوع مهم پیش‌بینی وجود دارد. نوع اول پیش‌بینی، زمان باقی‌مانده تا رخ دادن خرابی (یک یا عیب-های بیشتر) بر اساس سوابق عملیاتی گذشته و وضعیت کنونی دستگاه است. زمان باقی‌مانده تا مشاهده خرابی معمولاً عمر مفید باقی‌مانده (RUL) نامیده می‌شود. نوع دوم پیش‌بینی، شانس ادامه عملیات دستگاه بدون عیب یا خرابی تا چند وقت آینده (مثلاً فاصله بازرسی بعدی) بر اساس سوابق عملیاتی گذشته و وضعیت کنونی دستگاه است.

1 J. Guillén  
 2 Vibration  
 3 Thermography  
 4 Acoustic Emission  
 5 Ultrasound  
 6 Tribology  
 7 Lubricant

### عمر مفید باقی مانده

زمان باقی مانده تا مشاهده خرابی معمولاً عمر مفید باقی مانده (RUL) نامیده می شود (همان). RUL سیستم یا جزء به عنوان مدت زمان از زمان حال تا پایان عمر مفیدش تعریف می شود (ایکسونگزی<sup>۱</sup> و همکاران، ۲۰۱۱). پیش بینی درست RUL بر مبنای شرایط سلامت گذشته تا حال تجهیز در مدیریت نگهداری و تعمیرات خصوصاً با توجه به راهبرد CBM سهم اساسی دارد و برای اتخاذ تصمیم تعمیراتی به موقع با هدف پیشگیری از خرابی ضروری است (تیانل و جیانمین<sup>۲</sup>، ۲۰۱۰). سیکورس<sup>۳</sup> و همکاران (۲۰۱۱) با مرور رویکردهای مختلف ارائه شده برای دسته بندی مدل های پیش بینی RUL، دسته بندی دارای چهار گروه اصلی بانام های مدل های مبتنی بر دانش، مدل های طول عمر، شبکه های عصبی مصنوعی و مدل های فیزیکی ارائه داده اند. بسیاری از رویکردهای محاسبه RUL ماهیثاً آماری می باشند و برای استفاده به سوابق مشاهده شده مناسب نیاز دارند (هوچویوچ و کریس<sup>۴</sup>، ۲۰۱۲).

### تحلیل روغن

تحلیل روغن یکی از روش های CBM است. پایش شرایط سلامتی تجهیزات بر مبنای تحلیل روغن به عنوان ابزاری مناسب برای پیشینه سازی عمر و قابلیت دسترسی چنین تجهیزاتی با پیش بینی و جلوگیری از خرابی های پرهزینه و کاهش تعداد سرویس های نگهداری و تعمیرات غیر ضروری دیده می شود (وانگ و چنگ<sup>۵</sup>، ۲۰۰۵). برنامه نگهداری و تعمیرات خوبی که به طور منظم فلزات موجود در روغن موتور را اندازه می گیرد، نه تنها هزینه جداسازی معمول قطعات برای آزمون بصری را کاهش می دهد بلکه می تواند ذرات فرسودگی را قبل از خراب شدن قطعات نشان دهد (یاداو و همکاران، ۲۰۱۴). ذرات فلز موجود در روغن روانکار می تواند منابع مختلفی همچون فرسایش، مواد افزوده شده و آلودگی داشته باشد. فلزات فرسایشی از اصطکاک و خوردگی اجزاء موتور همچون سیلندرها، بوش ها، بلبرینگ ها و ... ناشی می شوند. مواد افزوده شده به عنوان آنتی اکسیدان ها، مواد پاک کننده و عملگرهای ضد فرسایش برای کاهش فرسایش موتور به روغن افزوده می شوند. آلودگی می تواند از ذرات فلز پسماند شده، خاک و نشتی ناشی شوند.

1 Xiongzi

2 Tianle & Jianmin

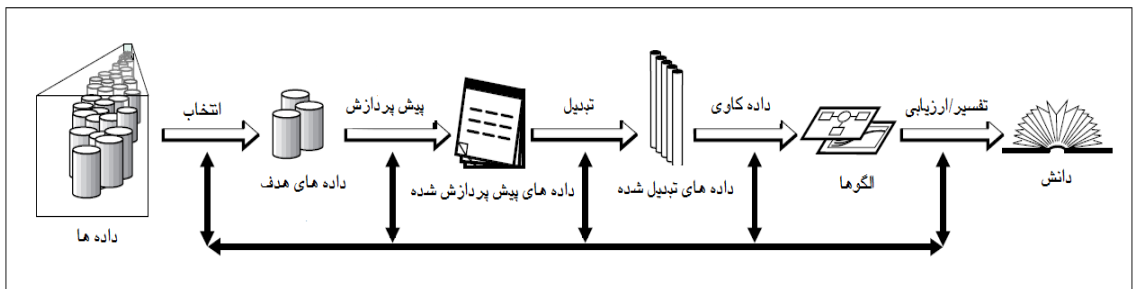
3 Sikorska

4 Hodkiewicz & Cripps

5 Wang & Zhang

## کشف دانش در پایگاه داده

اصطلاح کشف دانش در پایگاه داده<sup>۱</sup> (KDD) در اولین کارگاه آموزشی KDD در سال ۱۹۸۹ ابداع شد (فیاد و همکاران، ۱۹۹۶c، به نقل از پیاتتسکی-شاپیرو<sup>۲</sup> ۱۹۹۱) تا تأکید کند دانش محصول نهایی کشف داده محور است (فیاد و همکاران، ۱۹۹۶c). فرایند KDD (شکل یک) فرایند غیرمستقیم شناسایی الگوهای بارزش، جدید، بالقوه مؤثر و نهایتاً قابل فهم در داده‌ها است (فیاد و همکاران، ۱۹۹۶d، به نقل از فیاد و همکاران، ۱۹۹۶a). فرایند KDD تعاملی و تکراری (با بسیاری تصمیم گرفته‌شده کاربر) است (فیاد و همکاران، ۱۹۹۶d).



شکل ۱: فرایند KDD (فیاد و همکاران، ۱۹۹۶d)

## داده کاوی

داده کاوی شامل برزش مدل‌ها یا تعیین الگوها از داده‌های مشاهده‌شده، است (فیاد و همکاران، ۱۹۹۶d). داده کاوی یک مرحله در فرایند KDD است (همان). با این حال، اغلب در صنعت، در رسانه‌ها و در محدوده تحقیقات اصطلاح داده کاوی برای اشاره به کل فرایند کشف دانش استفاده می‌شود. بنابراین داده کاوی فرایند کشف دانش و الگوهای جذاب از مقادیر زیاد داده است (هان<sup>۳</sup> و همکاران، ۲۰۱۲). روش‌های مختلف داده کاوی را می‌توان در دو گروه روش‌های پیش‌بینی و روش‌های توصیفی طبقه‌بندی نمود (همان، ۲۰۱۲). در این پژوهش از دو روش پیش‌بینی زیر استفاده شده است: رگرسیون: پیش‌بینی مقدار یک متغیر پیوسته بر اساس مقادیر سایر متغیرها بر مبنای یک مدل

1 Knowledge Discovery in Databases

2 Piatetsky-Shapiro

3 Han

وابستگی خطی یا غیرخطی رگرسیون نامیده می‌شود (صنّعی آباده و همکاران، ۱۳۹۱: ۳۵). شبکه عصبی: شبکه‌های عصبی می‌توانند هم برای دسته‌بندی و هم پیش‌بینی عددی استفاده شود (هان و همکاران، ۲۰۱۲) که در آن‌ها مدل یاد گرفته شده به صورت مجموعه‌ای از گره‌های به هم متصل به همراه ارتباطات وزن دار آن‌ها نشان داده می‌شود (صنّعی آباده و همکاران، ۱۳۹۱: ۱۱۸).

### پیشینه پژوهش

تیانل و جیانمین (۲۰۱۰) روش جدیدی برای محاسبه RUL با ترکیب مدل خطرات متناسب<sup>۱</sup> (PHM) با ماشین بردار پشتیبان<sup>۲</sup> (SVM) معرفی کرده‌اند. آن‌ها از SVM برای شناسایی داده‌های غیرعادی و کاهش داده‌های خام استفاده کرده‌اند.

وانگ و همکاران (۲۰۱۰) با اشاره به کاربرد مدل‌سازی خطرات متناسب در پایش وضعیت تجهیزات و معرفی نرم‌افزار EXAKT، بنا به درخواست وزارت دفاع انگلیس از سوابق تحلیل روغن و سوابق نگهداری و تعمیرات نوع خاصی موتور دیزل که در وسایل نظامی ارتش انگلیس استفاده می‌شود برای مدل‌سازی پیش‌بینی خرابی و مدل‌سازی تصمیمات تعمیرات با هدف بهینه‌سازی تصمیمات نگهداری و تعمیرات با کمک نرم‌افزار استفاده کرده‌اند. هدف اصلی پاسخ با این سؤال بوده که آیا می‌توان تمام یا برخی از خرابی‌های موتور را بر اساس سوابق خرابی و سوابق تحلیل روغن پیش‌بینی کرد؟ آلوین<sup>۳</sup> (۲۰۱۲) بر اساس سوابق خرابی و داده‌های پایش وضعیت کامیون‌های حمل‌ونقل کاترپیلار 793D، مدلی را برای پیش‌بینی RUL ساخته و چند مدل تصمیم‌گیری را با توجه به مقادیر پیش‌بینی شده مقایسه کرده است.

هوچویویچ و کریپس (۲۰۱۲) مهم‌ترین عناصر موجود در نمونه روغن برای شناسایی خرابی‌ها را شناسایی کرده‌اند و مدلی آماری با کمک سوابق تحلیل روغن و سوابق خرابی‌ها برای پیش‌بینی RUL اجزاء ساخته‌اند.

زو<sup>۴</sup> و همکاران (۲۰۱۳) پژوهشی را با هدف پایش وضعیت آنلاین و پیش‌بینی RUL روغن با استفاده از روش صافی کردن ذرات<sup>۵</sup> و حسگرهای آنلاین انجام داده‌اند.

1 Proportional Hazards Model

2 Support Vector Machine

3 Alwyn

4 Zhu

5 Particle Filtering Technique



## روش پژوهش جمع‌آوری داده‌ها

بر اساس مصاحبه با متخصصان دو فایل از سوابق تحلیل روغن و متناسب با موضوع از واحد داده‌ورزی آزمایشگاه تحلیل روغن تهیه شد و با بررسی آن‌ها سوابق مربوط به موتور دیزل یک مدل بولدورز شامل ۲۷۰۰ رکورد با ۱۲۹ ویژگی<sup>۱</sup> انتخاب گردید که آن را مجموعه داده<sup>۲</sup> D1 می‌نامیم. با توجه به هدف این پژوهش تعدادی از ۱۲۹ ویژگی مجموعه داده D1 کم یا بی‌اهمیت بوده، لذا با مشاوره کارشناس خبره آزمایشگاه مجموعه داده D2 شامل ۲۷۰۰ رکورد با ۱۸ ویژگی (جدول دو) ساخته شد. در مجموعه داده D2 هر رکورد مربوط به یک نمونه روغن موتور دیزل بلدورز بوده و برای هر رکورد ویژگی مهم "وضعیت کلی دستگاه" که بیان‌کننده وضعیت بلدورز است بعد از تحلیل نمونه روغن تعیین و ثبت شده است.

جدول ۲: ویژگی‌های مجموعه داده D2

ردیف	ویژگی	نوع ویژگی	واحد اندازه‌گیری	ردیف	ویژگی	نوع ویژگی	واحد اندازه‌گیری
۱	وضعیت کلی دستگاه	کیفی	-	۱۰	Ti (تیتانیم)	کمی	ppm
۲	کارکرد دستگاه	کمی	hour	۱۱	Ag (نقره)	کمی	ppm
۳	Fe (آهن)	کمی	ppm	۱۲	Mo (مولیبدن)	کمی	ppm
۴	Cr (کروم)	کمی	ppm	۱۳	Si (سیلیسیم)	کمی	ppm
۵	Al (آلومینیوم)	کمی	ppm	۱۴	Na (سدیم)	کمی	ppm
۶	Cu (مس)	کمی	ppm	۱۵	B (بور)	کمی	ppm
۷	Pb (سرب)	کمی	ppm	۱۶	V (وانادیم)	کمی	ppm
۸	Sn (قلع)	کمی	ppm	۱۷	PQ (سنجش ذرات درشت آهن)	کمی	-
۹	Ni (نیکل)	کمی	ppm	۱۸	VIS40 (ویسکوزیته ۴۰)	کمی	cst

1 Feature  
2 Dataset

مقادیر ویژگی "وضعیت کلی دستگاه" با نظر کارشناس خبره آزمایشگاه در سه گروه A, B, C در جدول سه کدگذاری شده‌اند. افزایش اندیس در هر گروه نشان‌دهنده بدتر شدن وضعیت در آن گروه است. جدول ۳: مقادیر ویژگی "وضعیت کلی دستگاه"

کد	وضعیت	کد	وضعیت	کد	وضعیت
C1	روغن نو	B1	بدون ارزیابی	A1	عادی
		B2	مشکوک	A2	نیاز به بررسی
		B3	غیرعادی	A3	مرزی قابل قبول
				A4	مرزی
				A5	نیاز به رسیدگی
				A6	تحت مراقبت
				A7	مرزی سریع
				A8	بحرانی
				A9	بشدت بحرانی


### انتخاب زیرمجموعه‌ای از ویژگی‌ها

مجموعه داده‌ها برای تحلیل ممکن است شامل صدها صفت<sup>۱</sup> باشند و ممکن است بسیاری از این صفات غیر مرتبط با کار کاوش بوده یا اضافه باشند (هان و همکاران، ۲۰۱۲). به‌طور کلی هرچه ابعاد یا همان تعداد ویژگی‌های مسئله مورد کاوش بالاتر رود، باعث خواهد شد رکوردها در فضای جستجو پراکنده‌تر شوند (صنیعی آبا، و همکاران، ۱۳۹۱: ۶۱). انتخاب زیرمجموعه صفت سبب مجموعه داده را با حذف صفات غیر مرتبط یا اضافه کاهش می‌دهد (هان و همکاران، ۲۰۱۲). برای انتخاب زیرمجموعه‌ای از ویژگی‌ها روش‌های مختلفی وجود دارد. در این پژوهش از مجموعه داده D2 زیرمجموعه‌ای از ویژگی‌ها بر اساس مرور ادبیات، مشاوره کارشناس خبره آزمایشگاه و تحلیل همبستگی ویژگی‌ها به‌طوری انتخاب شده‌اند که دارای بالاترین تأثیر در تعیین ویژگی "وضعیت کلی دستگاه" و دارای کمترین همبستگی بین خودشان می‌باشند. در جدول چهار ویژگی‌های استفاده‌شده از تحلیل روغن در پژوهش‌های پیشین برای ساخت مدل‌های تشخیص و پیش‌بینی جمع‌بندی شده است.

جدول ۴: ویژگی‌های استفاده‌شده در پژوهش‌های پیشین

منبع	مدل	ویژگی
(وانگ و همکاران، ۲۰۱۴)	تشخیص	Fe, Al, Cu, Cr, Ag, Ti, Mg
(ونگ و همکاران، ۲۰۱۰)	پیش‌بینی	Mo, Visc40
(آلوین، ۲۰۱۲)	پیش‌بینی	Fe, Boost Pressure, Left Exhaust Temperature
(هوچویویچ و کریس، ۲۰۱۲)	پیش‌بینی	Na, Fe, ST(soot), PQI, Visc40
(تیانل و جیانمین، ۲۰۱۰)	پیش‌بینی	Fe
(منگ و همکاران، ۲۰۱۲)	پیش‌بینی	Fe

با توجه به جدول پنج که ویژگی Fe در بیشتر موارد در ساخت مدل‌ها استفاده‌شده است و نظر کارشناس خبره آزمایشگاه که ویژگی Fe را مؤثرترین ویژگی در تعیین وضعیت کلی دستگاه معرفی کرده، ویژگی Fe مبنا قرار داده شد و بر اساس شکل دو که ضریب همبستگی بین ۱۶ ویژگی مجموعه داده D2 را نشان می‌دهد مناسب‌ترین ویژگی‌هایی که دارای کمترین همبستگی با Fe می‌باشند انتخاب شدند.



شکل ۲: ضریب همبستگی بین ۱۶ ویژگی مجموعه داده D3

زیرمجموعه ویژگی منتخب شامل Fe, Cu, Vis40 بوده که ترکیبی از عناصر فرسایشی ویسکوزیته است و بر اساس آن مجموعه داده D3 شامل ۲۷۰۰ رکورد با پنج ویژگی شامل وضعیت کلی دستگاه، کارکرد دستگاه، Fe, Cu, Vis40 ساخته شد.

## مدل سازی

برای مدل سازی از زیرمجموعه‌ای از رکوردهای مجموعه داده D3 شامل سوابق تحلیل روغن تعدادی از بلدوزها که برای ویژگی "وضعیت کلی دستگاه" مقدار بحرانی (جدول دو) داشته‌اند استفاده شده که در نتیجه مجموعه داده D4 شامل ۴۹ رکورد با پنج ویژگی شامل وضعیت کلی دستگاه، کارکرد دستگاه، Fe, Cu, Vis40 ساخته شد. هدف این پژوهش بر اساس تعریف RUL ساخت بهترین مدل پیش‌بینی زمان کارکرد باقی‌مانده تا وضعیت بحرانی برای مدل بلدوز مورد مطالعه است که به عنوان مثال اگر مدل ساخته شده بر اساس مقدار ویژگی‌های مستقل یک نمونه روغن جدید مقدار ۵۰۰ ساعت را پیش‌بینی کند معنایش این است که با ۵۰۰ ساعت کارکرد جدید بلدوز، مقدار ویژگی "وضعیت کلی دستگاه" بحرانی می‌شود. با توجه به اینکه هدف ساخت مدل پیش‌بینی برای ویژگی "زمان کارکرد باقی‌مانده تا وضعیت بحرانی" است اما در مجموعه داده D4 چنین ویژگی وجود نداشته و هر رکورد سابقه تحلیل روغن فاقد این مقدار بوده، ویژگی بانام Time (زمان کارکرد باقی‌مانده تا وضعیت بحرانی) تعریف شده که می‌بایست مقدار آن بر اساس مقدار ویژگی "کارکرد دستگاه" برای ۴۹ رکورد مجموعه داده D4 محاسبه می‌شد که به دلیل عدم ثبت مقدار ویژگی "کارکرد دستگاه" برای تعدادی از ۴۹ رکورد مجموعه داده D4 به صورت تخمینی محاسبه شد. در نهایت مجموعه داده D5 شامل ۴۹ رکورد با چهار ویژگی (Time, Fe, Cu, Vis40) ساخته شده است.

در مجموعه داده D5 ویژگی Time به عنوان ویژگی کلاس و ویژگی‌های Fe, Cu, Vis40 به عنوان ویژگی‌های مستقل در نظر گرفته شده و بر این اساس مدل‌های پیش‌بینی ویژگی Time با دو روش داده‌کاوی (رگرسیون و شبکه عصبی) ساخته شده‌اند. به علت امکان انجام شدن فعالیت تعویض روغن در فواصل نمونه‌گیری‌ها که باعث می‌شود در نمونه‌های روغن بعد از تعویض روغن مقدار ویژگی‌هایی مانند Fe کاهش یافته و بنابراین نظم تغییر عنصر به صورت واقعی منعکس نشود (تیانل و جیانمین، ۲۰۱۰) مدل‌های رگرسیون و شبکه عصبی با دو روش اعمال مقادیر ویژگی‌های مستقل بدین شرح ساخته شده‌اند:

روش اول: مدل با مقادیر واقعی (غیر تجمعی) سه ویژگی مستقل (Fe, Cu, Vis40) ساخته شده است.  
روش دوم: مدل بر اساس روش منگ و همکاران (۲۰۱۲) با مقادیر جدید (تجمعی) دو ویژگی

مستقل (Fe, Cu) که عناصر فرسایشی بوده‌اند و مقادیر واقعی (غیر تجمعی) یک ویژگی مستقل (Vis40) که گرانروی بوده، ساخته شده است.

برای توضیح تفاوت دو روش اعمال مقادیر ویژگی‌های مستقل، از مجموعه داده D5 سوابق مربوط به بولدوزری که بعد از سه نمونه روغن به وضعیت بحرانی رسیده است برای هر دو روش در جدول پنج آورده شده است. همان‌طور که در جدول پنج دیده می‌شود مقادیر ویژگی Time برای این سه نمونه حالت نزولی داشته و در نمونه سوم به مقدار صفر رسیده که همان وقوع وضعیت بحرانی است و تفاوت دو روش اعمال مقادیر ویژگی‌های مستقل در مقادیر اعمال شده برای ویژگی‌های Fe, Cu است. در روش اول مقادیر واقعی (غیر تجمعی) این دو ویژگی اعمال شده و در روش دوم مقادیر جدید (تجمعی) این دو ویژگی اعمال شده است. مثلاً در روش دوم برای نمونه روغن مقدار Fe عدد ۲۰/۴ است که مجموع مقادیر Fe دو نمونه روغن اول و دوم روش اول یعنی اعداد ۷,۱ و ۱۳,۳ است و یا در روش دوم برای نمونه روغن سوم مقدار Cu عدد ۱۲,۵ است که مجموع مقادیر Cu سه نمونه روغن اول، دوم و سوم روش اول یعنی اعداد ۰,۹، ۲,۳ و ۹,۳ است.

جدول ۵: برشی از مجموعه داده D5

مقادیر ویژگی‌های مستقل								
روش دوم				روش اول				
	Fe	Cu	Vis40		Fe	Cu	Vis40	
Time	مقادیر جدید (تجمعی)		مقادیر واقعی (غیر تجمعی)	Time	مقادیر واقعی (غیر تجمعی)			
۹۵۰	۷,۱	۰,۹	۱۷۸	۹۵۰	۷,۱	۰,۹	۱۷۸	نمونه روغن اول
۶۵۰	۲۰,۴	۳,۲	۱۴۹	۶۵۰	۱۳,۳	۲,۳	۱۴۹	نمونه روغن دوم
۰	۳۲۸,۴	۱۲,۵	۱۴۵	۰	۳۰,۸	۹,۳	۱۴۵	نمونه روغن سوم

درنهایت، مدل‌های پیش‌بینی ساخته شده، بر اساس پیش‌بینی روند بحرانی شدن وضعیت کلی (پیش‌بینی زمان‌های کارکرد باقی‌مانده تا وضعیت بحرانی) بولدوزری که آن را دستگاه Test می‌نامیم و طی شش نمونه روغن رخ داده، ارزیابی عملکرد شده‌اند. معیار ارزیابی عملکرد مدل‌ها MSE<sup>۱</sup> بوده که بیانگر خطای پیش‌بینی است و برای رسیدن به بهترین مدل پیش‌بینی باید کاهش یابد.

<sup>1</sup> Mean squared error


### مدل سازی با روش رگرسیون

با استفاده از مجموعه داده D5 مدل های پیش بینی ویژگی Time با روش رگرسیون و دو روش اعمال مقادیر ویژگی های مستقل ساخته شده اند و بر اساس پیش بینی روند بحرانی شدن وضعیت کلی دستگاه Test ارزیابی عملکرد شده اند (جدول شماره شش). بر اساس جدول شش بهترین مدل (مدل با خطای پیش بینی کمتر) با روش دوم اعمال مقادیر ویژگی های مستقل ساخته شده است. روند واقعی بحرانی شدن وضعیت کلی دستگاه Test و بهترین مدل پیش بینی با روش رگرسیون در شکل شماره سه ترسیم شده است.

جدول ۷: ارزیابی عملکرد مدل های پیش بینی ویژگی Time با روش رگرسیون و دو روش اعمال مقادیر ویژگی های مستقل

Fe	Cu	Vis40	Fe	Cu	Vis40	ویژگی کلاس
مقادیر جدید (تجمعی)		مقادیر واقعی (غیر تجمعی)	مقادیر واقعی (غیر تجمعی)			
MSE			MSE			
۹۵۸۵۵۹,۰۳۳ +/- ۲۳۵۲۶,۶۶۲			۱۴۶۱۲۶۹,۷۶۸ +/- ۸۴۶۳۵,۹۱۸			Time

شکل ۳: روند بحرانی شدن وضعیت کلی دستگاه Test و بهترین پیش بینی با روش رگرسیون




### مدل‌سازی با روش شبکه عصبی

با استفاده از مجموعه داده D5 مدل‌های پیش‌بینی ویژگی Time با روش شبکه عصبی و دو روش اعمال مقادیر ویژگی‌های مستقل ساخته شده‌اند و بر اساس پیش‌بینی روند بحرانی شدن وضعیت کلی دستگاه Test ارزیابی عملکرد شده‌اند (جدول ۷). بر اساس جدول ۷ بهترین مدل (مدل با خطای پیش‌بینی کمتر) با روش دوم اعمال مقادیر ویژگی‌های مستقل ساخته شده است. روند واقعی بحرانی شدن وضعیت کلی دستگاه Test و بهترین مدل پیش‌بینی با روش شبکه عصبی در شکل ۴ ترسیم شده است.

جدول ۷: ارزیابی عملکرد مدل‌های پیش‌بینی ویژگی Time با روش شبکه عصبی و دو روش اعمال مقادیر ویژگی‌های

مستقل

Fe	Cu	Vis40	Fe	Cu	Vis40	ویژگی کلاس
مقادیر جدید (تجمعی)		مقادیر واقعی (غیر تجمعی)	مقادیر واقعی (غیر تجمعی)			
MSE			MSE			Time
۹۵۸۵۵۹,۰۳۳ +/-۲۳۵۲۶,۶۶۲			۱۴۶۱۲۶۹,۷۶۸ +/-۸۴۶۳۵,۹۱۸			



شکل ۴: روند بحرانی شدن وضعیت کلی دستگاه Test و بهترین پیش‌بینی با روش شبکه عصبی


### بهترین مدل

در جدول شماره هشت بر اساس جدول شماره شش و هفت، بهترین مدل‌های ساخته‌شده با دو روش رگرسیون و شبکه عصبی مقایسه شده‌اند. همچنین روند واقعی بحرانی شدن وضعیت کلی دستگاه Test و بهترین مدل‌های پیش‌بینی با روش‌های رگرسیون و شبکه عصبی در شکل شماره پنج ترسیم شده است. بر اساس جدول هشت مدل ساخته‌شده با شبکه عصبی و روش دوم اعمال مقادیر ویژگی‌های مستقل دارای بهترین معیار خطا (خطای پیش‌بینی کمتر) است و به‌عنوان بهترین مدل پیش‌بینی ویژگی Time (زمان کارکرد باقی‌مانده تا وضعیت بحرانی) انتخاب می‌شود.

جدول ۸: ارزیابی عملکرد بهترین مدل‌های پیش‌بینی ویژگی Time با روش‌های رگرسیون و شبکه عصبی

Fe	Cu	Vis40	ویژگی کلاس	روش
مقادیر جدید (تجمعی)	مقادیر واقعی (غیر تجمعی)	MSE		
۱۲۶۳۶۹۰,۴۴۲			Time	رگرسیون
+/- ۷۸۲۸۱۸,۸۵۱				شبکه عصبی
۹۵۸۵۵۹,۰۳۳				
+/- ۲۳۵۲۶,۶۶۲				





شکل ۵: روند بحرانی شدن وضعیت دستگاه Test و بهترین پیش‌بینی با روش‌های رگرسیون و شبکه عصبی

### نتیجه‌گیری و پیشنهادها

استفاده از داده‌های تولید و ذخیره می‌شود که با کشف دانش موجود در آن‌ها می‌توان به بهینه‌سازی و کاهش هزینه‌های نگهداری و تعمیرات کمک کرد. هدف این پژوهش بر اساس تعریف RUL ساخت بهترین مدل پیش‌بینی زمان کارکرد باقی‌مانده تا وضعیت بحرانی برای یک مدل بولدوزر بر اساس سوابق تحلیل روغن موتور دیزل با راهکار داده‌کاوی بوده است. به عنوان مثال اگر مدل ساخته‌شده بر اساس مقدار ویژگی‌های مستقل یک نمونه روغن جدید مقدار ۵۰۰ ساعت را پیش‌بینی کند معنایش این است که با ۵۰۰ ساعت کارکرد جدید، وضعیت کلی بولدوزر بحرانی می‌شود که این پیش‌بینی در برنامه‌ریزی‌های نگهداری و تعمیرات قابل استفاده است. برای ساخت بهترین مدل بعد از آماده‌سازی مجموعه داده مناسب با ۴۹ رکورد و چهار ویژگی (بعد از حذف ویژگی‌های مستقل کم یا بی‌اهمیت از مجموعه داده اولیه با توجه به هدف این پژوهش، در بخش انتخاب زیرمجموعه‌ای از ویژگی‌ها زیرمجموعه‌ای از ویژگی‌های مستقل باقی‌مانده شامل Fe, Cu, Vis40 بر اساس مرور ادبیات، مشاوره کارشناس خبره آزمایشگاه و تحلیل همبستگی ویژگی‌ها انتخاب‌شده‌اند) مدل‌هایی با روش‌های رگرسیون و شبکه عصبی ساخته‌شده است. به علت امکان انجام شدن فعالیت تعویض روغن در فواصل نمونه‌گیری‌ها که باعث می‌شود در نمونه‌های روغن بعد از تعویض روغن مقدار ویژگی‌هایی مانند Fe کاهش یافته و بنابراین نظم تغییر عنصر به صورت واقعی منعکس نشود (تیانل و جیانمین، ۲۰۱۰) مدل‌های رگرسیون و شبکه عصبی با دو روش اعمال مقادیر

ویژگی‌های مستقل بدین شرح ساخته شده‌اند:

روش اول: مدل با مقادیر واقعی (غیر تجمعی) سه ویژگی مستقل (Fe, Cu, Vis40) ساخته شده است.  
روش دوم: مدل بر اساس روش منگ و همکاران (۲۰۱۲) با مقادیر جدید (تجمعی) دو ویژگی مستقل (Fe, Cu) که عناصر فرسایشی بوده‌اند و مقادیر واقعی (غیر تجمعی) یک ویژگی مستقل (Vis40) که گرانروی بوده، ساخته شده است.

بر اساس ارزیابی عملکرد مدل‌ها بهترین مدل پیش‌بینی زمان کارکرد باقی‌مانده تا وضعیت بحرانی با شبکه عصبی و روش دوم اعمال مقادیر ویژگی‌های مستقل ساخته شده است. برای سازمان‌ها و به‌طور خاص سازمان‌های با گستره وسیع فعالیت ایجاد سیستم‌های آنلاین بر اساس مدل‌های پیش‌بینی ایجاد شده پیشنهاد می‌شود بطوری که هر فرد در هر مکان و در هر زمان بتواند بر اساس نتایج تحلیل نمونه روغن جدید، پیش‌بینی از زمان کارکرد باقی‌مانده تا وضعیت بحرانی را مشاهده کرده و مورد بهره‌برداری قرار دهد و برای پژوهش‌های آتی استفاده از بانک اطلاعاتی تعمیرات دستگاه و بانک اطلاعاتی سوابق تحلیل روغن برای ساخت مدل پیش‌بینی زمان باقی‌مانده تا خرابی دستگاه پیشنهاد می‌شود.

## منابع

صنعی آباده، محمد. محمودی، سینا و طاهرپور، محدثه (۱۳۹۱). *داده‌کاوی کاربردی*، تهران: انتشارات نیاز دانش

Alwyn Carstens, Wiehahn (2012). *Regression Analysis of Caterpillar 793D Haul Truck Engine Failure Data and Through-Life Diagnostic Information Using the Proportional Hazards Model*. Master's thesis of Science in Industrial Engineering, Stellenbosch University, South Africa.

Fayyad, U., Piatetsky-Shapiro, G., and Smyth, P. (1996a) *From data mining to knowledge discovery: An overview, In Advances in Knowledge Discovery and Data Mining*, U. Fayyad, G. Piatetsky-Shapiro, P. Smyth, & R. Uthurusamy, Eds. AAAI/MIT Press, Cambridge, Mass.

Fayyad, U., Piatetsky-Shapiro, G., and Smyth, P. (1996b) *From Data Mining to Knowledge Discovery in Databases*, AI Magazine, Vol. 17, pp. 1-13

Fayyad, U., Piatetsky-Shapiro, G., and Smyth, P. (1996c) *Knowledge Discovery and Data Mining: Towards a Unifying Framework*, KDD'96 Proceedings of the Second International Conference on

Knowledge Discovery and Data Mining, pp. 82-88

Fayyad, U., Piatetsky-Shapiro, G., and Smyth, P. (1996d) *The KDD Process for Extracting Useful Knowledge from Volumes of Data*, Communications of the ACM, Vol. 39, pp. 27-34

J. Guillén, A., González-Prida, V., Fco. Gómez, J., and Crespo, A. (2016) *Standards as reference to build a PHM Based solution*, 10th World Congr. Eng. Asset Manag, Springer International Publishing, pp. 207-214

Han, J., Kamber, M., & Pei, J. (2012) *Data Mining Concepts and Techniques*, 3th ed. Morgan Kaufmann Publishers, San Francisco

Hodkiewicz, M. & Cripps, E. (2012) *Remaining Useful Life Estimation of Caterpillar Vehicle Compartments*, CEED Seminar Proceedings

Jardine, A.K.S., Lin, D., & Banjevic, D. (2006) *A review on machinery diagnostics and prognostics implementing condition-based maintenance*, Journal of Mechanical Systems and Signal Processing, Vol. 20, pp. 1483-1510

Meng, X., Qu, Y., & Zhou, Y. (2012) *Linear Regression Method-Based Data Mining in Vehicle Maintenance*, International Conference on Information Engineering and Applications (IEA), pp. 625-630

Mwanza, B.G., & Mbohwa, CH. (2016) *Safety in Maintenance: An Improvement Framework*, 14<sup>th</sup> Global Conference on Sustainable Manufacturing

Olurotimi Akintunde, D. (2008) *Spectrometric Oil Analysis—An Untapped Resource for Condition Monitoring*, AU Journal of Technology, Vol. 12, pp. 107-114

Piatetsky-Shapiro, G. (1991) *Knowledge Discovery in Real Databases*, AI Magazine, Vol. 11

Prajapati, A., Bechtel, J., & Ganesan, S. (2012) *Condition based aintenance: a survey*, Journal of Quality in Maintenance Engineering, Vol. 18, pp. 384-400

Ruschel, E., Alves Portela Santos, E., & de Freitas Rocha Loures, E. (2017) *Industrial maintenance decision-making: A systematic literature review*, Journal of Manufacturing Systems, Vol. 45, pp 180-194

Shin, JH., & Jun, HB. (2015) *On condition based maintenance policy*, Journal of Computational Design and Engineering, Vol. 2, pp. 119-127

Sikorska, J.Z., Hodkiewicz, M., & Ma, L. (2011) *Prognostic modelling options for remaining useful life estimation by industry*, Journal of Mechanical Systems and Signal Processing, 25 pp 1803-1836

Tianle, Feng., & Jianmin, Z. (2010) *SVM-PHM : A Novel Method*

*for Remaining Useful Life Prediction*, International Conference of Information Science and Management Engineering, , pp. 369-372

Wang, W., & Zhang, W. (2005) *A Model To Predict the Residual Life of Aircraft Engines Based upon Oil Analysis Data*, naval research logistics, Vol. 52, pp. 276-284

Wang, J., Duan, X., Li, Y., & Bai, P. (2014) *Prediction of aero engine fault by relative vector machine and genetic algorithm model*, Journal of Advanced Materials Research, Vols. 998-999 , pp 1033-1036

Wong, EL., Jefferis, T., & Montgomery ,N. (2010) *Proportional hazards modeling of engine failures in military vehicles*, Journal of Quality in Maintenance Engineering, Vol. 16, pp. 144-155

Xiongzi, C., Jinsong, Y., Diyin, T., & Yingxun, W. (2011) *Remaining Useful Life Prognostic Estimation for Aircraft Subsystems or Components: A Review*, The Tenth International Conference on Electronic Measurement & Instruments

Yadav, G., Ganai, P., Tiwari, S., & Maheshwari, M. (2014) *An Investigation For Prior Failure Of Engine Component Through Spectroscopy Oil Analysis program*, Applied Mechanics and Materials Vols. 592-594 , pp 1362-1365

Zhu, J., Yoon, M., He, D., Qu, Y., Bechhoefer, E. (2013) *Lubrication Oil Condition Monitoring and Remaining Useful Life Prediction with Particle Filtering*. International Journal of Prognostics and Health Management, ISSN 2153-2648