



تخمین عمر مفید باقیمانده سیستم‌های مکانیکی با استفاده از روش ترکیبی مدل ریاضی و الگوریتم‌های فراابتکاری

فاطمه مهرگان^{*۱}

۱. گروه ریاضی، واحد آبادان، دانشگاه آزاد اسلامی، آبادان، ایران.

*نویسنده مسئول: fatimehregan5@gmail.com

تاریخ دریافت: ۱۴۰۱/۰۷/۰۹ تاریخ پذیرش: ۱۴۰۱/۰۸/۲۱

چکیده

پیش‌بینی دقیق از عمر مفید باقیمانده تجهیزات مکانیکی، برای تعمیرات و نگهداری وسایل ضروری است. تاکنون الگوریتم‌های داده‌محور زیادی ارائه شده است و نتایج خوبی در زمینه عیب‌یابی پیشگویانه حاصل شده است. در این مقاله با استفاده از الگوریتم فرا ابتکاری، بهینه‌سازی پارامترهای مربوطه انجام می‌شود، به طوری که از پنجره زمانی متحرک به همراه مدل ریاضی استفاده می‌شود. تنظیم پارامترهای مرتبط با داده‌ها در چارچوب بهینه‌سازی، اجازه استفاده از مدل‌های ساده مثل شبکه‌های عصبی با تعداد کمی لایه پنهان و تعداد کمی نورون در هر لایه را می‌دهد که در محیط‌هایی با منابع محدود نظیر سیستم‌های تعبیه‌شده قابل استفاده هستند. برای ارزیابی کارایی روش ارائه شده پیشنهادی، از شاخص امتیازدهی ریشه میانگین مربعات خطا و امتیاز سلامت عمر مفید استفاده شده است. بدین منظور مجموعه داده‌های تصادفی در نظر گرفته شده است که نتایج آن عمومیت و خاصیت مقیاس‌پذیری آن را نشان می‌دهد. با وجود استفاده از رگرسورها و الگوریتم‌های تکاملی خاص در این مطالعه، ترکیب‌های زیاد دیگری نیز امکان‌پذیر است و ممکن است برای کاربردهای متفاوت مناسب‌تر باشند. به علاوه این چارچوب عملاً برای ساخت مدل، یعنی ایجاد بهترین معماری شبکه عصبی ممکن متناسب با یک کاربرد خاص، قابل استفاده است.

کلمات کلیدی: شبکه‌های عصبی مصنوعی، پنجره زمانی متحرک، تخمین عمر مفید، الگوریتم‌های تکاملی.

مقدمه

به‌طور سنتی، تعمیر و نگهداری سیستم‌های مکانیکی بر اساس استراتژی‌های زمان‌بندی انجام می‌شود. این قبیل استراتژی‌ها اغلب پرهزینه هستند و چندان قادر به پاسخگویی به تقاضای فزاینده کارایی و قابلیت اطمینان نیستند. تعمیر و نگهداری مبتنی بر شرایط (CBM) که از آن به‌عنوان عیب‌یابی پیشگویانه هوشمند و مدیریت سلامت (RHM) نیز یاد می‌شود، امکان تعمیر و نگهداری بر اساس سلامت فعلی سیستم را فراهم می‌سازد [۱]. بدین ترتیب هزینه‌ها را کاهش و قابلیت اطمینان سیستم را افزایش می‌دهد [۲]. در این مقاله، از عیب‌یابی پیشگویانه به‌عنوان تخمین عمر مفید باقیمانده سیستم یاد می‌شود. عمر مفید باقیمانده سیستم را می‌توان بر اساس داده‌های تاریخی تخمین زد. این رویکرد داده‌محور می‌تواند به بهینه‌سازی برنامه‌های تعمیر و نگهداری به‌منظور جلوگیری از خرابی‌های مهندسی و صرفه‌جویی در هزینه‌ها کمک کند [۳].

روش‌های مدیریت سلامت موجود را می‌توان به سه دسته رویکردهای مبتنی بر مدل، داده‌محور و ترکیبی تقسیم‌بندی نمود. رویکردهای مبتنی بر مدل سعی دارند مدل‌های فیزیکی سیستم را در تخمین عمر مفید بگنجانند. این نوع رویکردها، مشروط به مدل‌سازی دقیق زوال سیستم، معمولاً در مقایسه با رویکردهای داده‌محور عملکرد بهتری از خود نشان می‌دهند [۴]. این امر به قیمت برخورداری از دانش قبلی گسترده درباره سیستم اصلی و همچنین داشتن مدل دقیق سیستم حاصل می‌شود که می‌تواند شامل محاسبات پرهزینه باشد. از سوی دیگر، رویکردهای داده‌محور برای تشخیص تغییر در حالات سیستم از تشخیص الگو

¹ Condition based maintenance

² prognostics and health management



استفاده می‌کنند. رویکردهای داده‌محور زمانی مناسب هستند که درک جامعی از اصول اولیه دینامیک سیستم موجود نباشد یا اینکه سیستم به حدی پیچیده باشد که ساخت مدل دقیق برای آنها بسیار دشوار باشد مانند موتورهای جت، موتورهای خودرو و ماشین‌آلات پیچیده [۵۶]. ایرادات معمول رویکردهای داده‌محور این است که معمولاً در مقایسه با رویکردهای مبتنی بر مدل فواصل اطمینان بیشتری را ارائه می‌دهند و برای آموزش به مقدار نسبتاً زیادی داده، احتیاج دارند. از جمله متداول‌ترین الگوریتم‌ها می‌توان به شبکه‌های عصبی مصنوعی (ANNs) ماشین بردار پشتیبان (SVM)، زنجیره پنهان مارکوف (MHC) و نظایر آنها اشاره کرد. در چند سال گذشته، رویکردهای داده‌محور بیشتر مورد توجه جامعه مدیریت سلامت قرار گرفته است [۷-۹].

تعدادی از تکنیک‌های یادگیری ماشین، به‌ویژه شبکه‌های عصبی، با موفقیت برای تخمین عمر مفید سیستم‌های مکانیکی گوناگون به کار گرفته شده‌اند. شبکه‌های عصبی مصنوعی عملکرد خوبی در مدل‌سازی سیستم‌های بسیار غیرخطی، پیچیده و چندبعدی بدون هیچ‌گونه دانش قبلی در مورد رفتار سیستم از خود نشان داده‌اند [۱۰]. هرچند حدود اطمینان پیش‌بینی‌های عمر مفید به روش تحلیلی قابل ارائه نیست، رویکردهای شبکه عصبی برای مسائل عیب‌یابی پیشگویانه امیدبخش هستند [۱۱]. لیم، گوه و تان [۱۲] برای تخمین عمر مفید موتورهای جت شبکه‌های عصبی را بررسی کرده‌اند. آنها بدین منظور یک پرسپترون چند لایه (MLP) همراه با یک روش استخراج ویژگی (FE) و یک پنجره زمانی برای تولید ویژگی‌های پرسپترون پیشنهاد داده‌اند. همچنین نشان داده‌اند با ترکیب پنجره متحرک با استخراج‌کننده مناسب ویژگی می‌توان پیش‌بینی عمر مفید را در مقایسه با مطالعات انجام‌شده با سایر روش‌های مشابه بهبود بخشید. لیو همکاران [۱۴ و ۱۳] با بررسی یک معماری ANN یادگیری عمیق موسوم به شبکه‌های عصبی پیچشی (CNN) نشان داده‌اند، که با استفاده از شبکه‌های عصبی پیچشی بدون لایه ادغام همراه با پنجره زمانی، عمر مفید پیش‌بینی‌شده بهبود بیشتری می‌یابد.

در این مقاله چارچوب جدیدی برای تخمین عمر مفید سیستم‌های مکانیکی پیچیده ارائه می‌گردد. این چارچوب شامل یک پرسپترون برای تخمین عمر مفید سیستم، همراه با یک الگوریتم تکاملی برای تنظیم دقیق پارامترهای مرتبط با داده است. هرچند این چارچوب خاص از یک پرسپترون استفاده می‌کند، چارچوب پیشنهادی در اصل می‌تواند از چندین الگوریتم یادگیری دیگر استفاده کند. هدف اصلی تحقیق، پردازش داده‌ها است و برای ارزیابی کارایی و قابلیت اطمینان چارچوب پیشنهادی از مجموعه داده که به صورت تصادفی از C-MAPSS تولید شده‌اند، استفاده گردیده است [۱۵].

مبانی نظری

معیارهای کارایی

برای ارزیابی کارایی روش ارائه شده پیشنهادی، از دو شاخص امتیازدهی ریشه میانگین مربعات خطا که به صورت $e_{rms}(d)$ نشان داده شده است و یک معیار دیگر که توسط ساکسنا و همکاران [۱۶] به نام امتیاز سلامت عمر مفید و به صورت $S_{rh}(d)$ نشان داده شده است، استفاده می‌گردد. این دو امتیاز به صورت زیر تعریف می‌شوند:

$$e_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N d_i^2} \quad (1)$$

$$S_{rh} = \frac{1}{N} \sum_{i=1}^N S_i \quad (2)$$
$$S_i = \begin{cases} e^{-\frac{d_i}{13}} - 1, & d_i < 0 \\ \frac{d_i}{e^{10}} - 1, & d_i \geq 0 \end{cases}$$

¹Artificial neural networks

²Support vector machine

³Markov hidden chains

⁴Multi-layer perceptron

⁵Feature extraction

⁶convolutional neural networks



که در آن N تعداد کل نمونه‌ها در مجموعه آزمایشی است. $d = \hat{y} - y$ خطای بین مقادیر تخمینی عمر مفید (\hat{y}) و مقادیر واقعی عمر مفید (y) است. باید توجه داشت که $\text{Sth}(d)$ پیش‌بینی‌های دیرتر از موعد را بیش از پیش‌بینی‌های زودتر از موعد جریمه می‌کند، زیرا معمولاً پیش‌بینی‌های دیرتر از موعد در حوزه‌هایی نظیر هوافضا تبعات شدیدتری به دنبال دارند.

انتخاب معماری

انتخاب معماری ساده به‌جای معماری پیچیده‌تر به‌خاطر کم‌هزینه‌تر بودن آموزش شبکه‌های عصبی از نظر محاسباتی ساده‌تر است. علاوه بر این، استنتاج نیز سریع‌تر صورت می‌گیرد زیرا شامل عملیات کمتری است. برای اندازه‌گیری سادگی یا پیچیدگی شبکه عصبی از تعداد پارامترهای (وزن‌های) قابل آموزش شبکه عصبی استفاده می‌شود. معمولاً هر چه پارامترهای قابل آموزش در شبکه بیشتر باشد، محاسبات بیشتری باید انجام شود و بنابراین بار محاسباتی فرایند آموزش یا استنتاج افزایش می‌یابد.

شکل دادن به داده‌ها

در این بخش به شرح پیش‌پردازش داده اعمال شده به خوانش‌های خام حسگر در هر یک از مجموعه داده‌ها پرداخته می‌شود. حسگرها براساس مراجع انتخاب شده‌اند [۱۰-۱۲]. مجموعه داده‌های اصلی شامل ۲۱ خوانش حسگر مختلف است، که برخی حسگرها واریانس زیادی نشان نمی‌دهند یا اطلاعات تکراری ارائه می‌دهند که این حسگرها کنار گذاشته شده‌اند. همچنین برخی مقادیر حسگر در کل چرخه عمر موتور اصلاً تغییر نمی‌کنند درحالی‌که برخی دیگر بر اساس تحلیل PCA یا خوشه‌بندی تکراری هستند، بنابراین این حسگرها نیز کنار گذاشته می‌شوند. در پایان، از ۲۱ خوانش حسگر تنها ۱۴ مورد برای این مطالعه در نظر گرفته شده است. اندیس‌های آنها عبارتند از $\{۲، ۳، ۴، ۷، ۸، ۹، ۱۱، ۱۲، ۱۳، ۱۴، ۱۵، ۱۷، ۲۰، ۲۱\}$. سپس این اندازه‌گیری‌های خام برای ایجاد پنجره‌های زمانی متحرک با اندازه پنجره n_w و گام پنجره n_s استفاده می‌شوند. برای برچسب‌های آموزشی، در مراحل اولیه R_e استفاده می‌شود و سپس عمر مفید به‌صورت خطی کاهش می‌یابد. داده‌ها با استفاده از نرمال‌سازی \min - \max در بازه $[-۱، ۱]$ نرمال می‌شوند.

$$\hat{x}_i = 2 * \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} - 1 \quad (۳)$$

که در آن x_i یک بردار m بعدی را نشان می‌دهد که مؤلفه‌های آن همه خوانش‌های حسگر i است و \hat{x}_i بردار x_i نرمال شده است.

پنجره زمانی و گام

در مسائل سری زمانی چندمتغیره مانند عمر مفید، عموماً می‌توان با استفاده از ترتیب زمانی داده‌ها اطلاعات بیشتری را در مقایسه با نقطه داده چندمتغیره در یک پنجره زمانی به‌دست آورد. برای یک پنجره زمانی با اندازه n_w با گام $n_s = 1$ تمام خوانش‌های حسگر در این پنجره زمانی بردار ویژگی $\mathbf{x} \in \mathbb{R}^{s * n_w}$ را می‌سازند که در آن s تعداد حسگرهایی را نشان می‌دهد که خوانده می‌شوند. کنار هم قرار دادن تعدادی m از این پنجره زمانی بردار ویژگی $X \in \mathbb{R}^{m * s * n_w}$ را می‌سازد درحالی‌که مقادیر عمر مفید متناظر آن به‌صورت $\mathbf{y} \in \mathbb{Z}^m$ تعریف می‌گردد. لازم به ذکر است شکل X تعداد نورون‌های ورودی شبکه عصبی را مشخص می‌کند؛ بنابراین تغییر شکل X عملاً تعداد ورودی‌های شبکه عصبی را تغییر می‌دهد. لی و همکاران و لیم و همکاران [۱۰ و ۱۲] این رویکرد را با موفقیت آزمایش و استفاده از پنجره متحرک با اندازه ۲۰ تا ۳۰ را پیشنهاد نمودند. در این مقاله پیشنهاد می‌شود از پنجره زمانی متحرکی استفاده گردد که در یک لحظه بیش از یک عنصر را به‌روز می‌کند ($n_s > 1$).

مدل زوال تکه‌ای خطی

برخلاف مسائل متداول رگرسیون، در مسائل عمر مفید تعیین مقدار خروجی مطلوب داده‌های ورودی دشوار است. معمولاً بدون مدل دقیق مبتنی بر فیزیک، ارزیابی وضعیت دقیق سلامت و تخمین عمر مفید سیستم در هر مرحله زمانی غیرممکن است. راماسو [۱۲] برای یک مجموعه داده، یک مدل زوال تکه‌ای خطی پیشنهاد کرده است. در این مدل فرض گردیده موتورها



در چرخه‌های اولیه یک برچسب عمر مفید ثابت دارند و سپس عمر مفید به صورت خطی شروع به کاهش می‌کند تا زمانی که به صفر برسد. در این مقاله از فرض زوال تکه‌ای خطی استفاده شده است. مقدار عمر مفید در چرخه‌های اولیه را با R_e نشان داده می‌شود. در ابتدا، R_e به طور تصادفی بین ۹۰ تا ۱۴۰ چرخه انتخاب می‌شود که محدوده معقولی از مقادیر برای این کاربرد خاص است. هنگامی که تفاوت بین تعداد چرخه در پنجره زمانی و چرخه پایانی داده‌های آموزشی کمتر از مقدار اولیه R_e باشد، R_e نزول خطی به سمت چرخه پایانی را آغاز می‌کند

پارامترهای بهینه داده

همانطور که در بخش‌های قبلی ذکر شد، انتخاب پارامترهای مرتبط با داده v تأثیر زیادی بر کارایی رگرسیون دارد. در این بخش، چارچوبی برای انتخاب ترکیب بهینه پارامترهای مرتبط با داده n_w ، n_s و R_e که در عین حال از نظر محاسباتی کارآمد است، ارائه می‌گردد. مؤلفه‌های بردار $v = (n_w, n_s, R_e)$ مربوط به مجموعه داده‌های تصادفی طوری محدود شده‌اند که $n_w \in [1, b]$ ، $n_s \in [1, 10]$ و $R_e \in [90, 140]$ می‌باشند که در همه متغیرها عدد صحیح هستند. مقدار b برای زیرمجموعه‌های مختلف داده‌ها متفاوت است. فرض می‌شود $X(v)$ مجموعه‌های آموزشی اعتبارسنجی متقابل آزمایشی باشد که با v پارامتری سازی شده‌اند و توسط پرسپترون برای تخمین عمر مفید استفاده می‌شوند. سرانجام، فرض کنید $f(v) = e_{rms}(X(v))$ با توجه به اینکه $d = \hat{y} - y$ و $X(v)$ بستگی دارد، بنابراین ارزیابی تابع $f(v)$ مستلزم آموزش پرسپترون و محاسبه نتیجه رابطه (۱) است. در اینجا پیشنهاد می‌شود v طوری بهینه شود که:

$$\min_{v \in \mathbb{Z}^3} f(v) \quad (4)$$

مسئله یافتن پارامترهای بهینه مرتبط با داده‌ها، توصیف تحلیلی ندارد [۱۴]. بنابراین، اطلاعات گرادین موجود نیست و انتخاب طبیعی برای این مسئله بهینه‌سازی یک الگوریتم تکاملی است.

الگوریتم تکاملی برای پارامترهای بهینه داده

الگوریتم‌های تکاملی (EAs) خانواده‌ای از روش‌ها برای مسائل بهینه‌سازی هستند. این روش‌ها هیچ فرضی در مورد مسئله نمی‌کنند و آن را به صورت یک جعبه سیاه در نظر می‌گیرند که صرفاً با در اختیار داشتن جواب احتمالی معیاری از کیفیت آن را ارائه می‌دهند. علاوه بر این، EAها هنگام جستجوی جواب‌های بهینه احتیاجی به گرادین ندارند که آنها را برای کاربردهایی نظیر شبکه‌های عصبی بسیار مناسب می‌سازد. برای کاربرد فعلی، روش تکامل تفاضلی (DE) به عنوان الگوریتم بهینه‌سازی انتخاب شده است. هر چند سایر الگوریتم‌های فراابتکاری نیز ممکن است برای این کاربرد مناسب باشند، DE به عنوان یکی از مطمئن‌ترین، قوی‌ترین و آسان‌ترین EAها شناخته شده است [۱۵]. به علاوه، یک پیاده‌سازی آماده استفاده به زبان پایتون از طریق بسته در دسترس است [۱۶]. هر چند روش DE عملگرهای خاصی برای پردازش متغیرهای عدد صحیح ندارد، در این مقاله از یک اصلاح بسیار ساده در الگوریتم، یعنی گرد کردن هر مؤلفه جواب احتمالی به نزدیک‌ترین عدد صحیح استفاده می‌شود. الگوریتم‌های تکاملی نظیر DE هنگام جستجوی جواب‌های بهینه از چندین ارزیابی تابع استفاده می‌کنند. باید توجه داشت در این کاربرد، ارزیابی کارایی مستلزم آموزش مجدد شبکه عصبی از ابتدا است. این سناریو مطلوب نیست، زیرا دستیابی به پارامترهای بهینه مرتبط با داده مستلزم تلاش محاسباتی گسترده است. به جای اجرای DE در چندین تکرار و با اندازه جمعیت زیاد، پیشنهاد می‌گردد آن را فقط برای ۳۰ تکرار، یعنی تعداد نسل موجود در متون محاسبات تکاملی، اجرا شود. همچنین اندازه جمعیت ۱۲ در نظر گرفته شود که با توجه به اندازه فضای جستجوی v منطقی به نظر می‌رسد.

الگوریتم تخمین

پس از تشریح اجزای سازنده اصلی روش پیشنهادی، اکنون چارچوب کامل را در قالب الگوریتم (۱) معرفی می‌شود.



الگوریتم (۱): چارچوب تخمین عمر مفید ANN-EA

- ورودی:** مجموعه اولیه پارامترهای مرتبط با داده $v \in \mathbb{Z}^3$ ، داده‌های خام آموزشی آزمایشی $X \in \mathbb{R}^{m \times s * n_w}$ ، برچسب‌های آموزشی $y \in \mathbb{Z}^m$ و تعداد دوره‌های آموزشی برای هر ارزیابی $f(v)$.
- خروجی:** مجموعه بهینه پارامترهای مرتبط با داده $v^* \in \mathbb{Z}^3$.
۱. معماری رگرسور (SVM, ANN)، رگرسیون خطی لجستیک و غیره) را انتخاب کن.
 ۲. $X(v)$ مجموعه‌های آموزشی است که با v پارامتری‌سازی شده و $f(v)$ را به صورت $f(v) = \text{erms}(X(v))$ تعریف کن.
 ۳. با استفاده از الگوریتم تکاملی ترجیحی، یعنی تکامل تفاضلی، استراتژی‌های تکاملی، الگوریتم ژنتیک و $f(v)$ را بهینه کن.
 ۴. برای آموزش رگرسور به هر تعداد دوره که لازم باشد از v^* استفاده کن.

نتایج تجربی

در این بخش، کارایی روش پیشنهادی ارزیابی می‌گردد. در ابتدا داده‌ها به صورت تصادفی تولید شده‌اند و جزئیات داده‌ها در جدول (۱) نشان داده شده است. این داده‌ها از مجموعه داده‌های ناسا C-MAPSS استفاده شده است. مجموعه داده C-MAPSS شامل داده‌های شبیه‌سازی شده است که با استفاده از برنامه شبیه‌سازی مبتنی بر مدل توسعه یافته توسط ناسا تولید شده است. این مجموعه داده به ۴ زیرمجموعه شامل داده‌های زمانی چندمتغیره به دست آمده از ۲۱ حسگر تقسیم می‌شود.

جدول (۱): جزئیات مجموعه داده‌های تصادفی.

داده‌های تصادفی				مجموعه داده
A04	A03	A02	A01	
۲۴۸	۹۸	۲۶۰	۹۸	مسیرهای آموزش
۲۴۸	۹۷	۲۵۹	۹۸	مسیرهای آزمایش
۶	۱	۶	۱	شرایط عملیاتی
۲	۱	۱	۲	مدهای خطا

معماری پرسپترون در جدول (۲) تشریح شده است.

جدول (۲): معماری پیشنهادی شبکه عصبی.

اطلاعات بیشتر	فعال‌سازی	تعداد نورون	لایه
$L_2 = 0, 2, L_1 = 0, 1$	ReLU	۲۰	کاملاً متصل
$L_2 = 0, 2, L_1 = 0, 1$	ReLU	۲۰	کاملاً متصل
$L_2 = 0, 2, L_1 = 0, 1$	خطی	۱	کاملاً متصل

در جدول (۳)، چندین ترکیب از مقادیر بهینه اندازه پنجره n_w ، گام پنجره n_s و عمر مفید اولیه R_e ارائه شده است. برای هر زیرمجموعه داده ۱۰ آزمایش مختلف انجام می‌شود. پرسپترون با استفاده از مجموعه آموزشی برای زیرمجموعه داده مربوطه ۲۰ دوره آموزش داده می‌شود و با استفاده از مجموعه آزمایشی همان زیرمجموعه ارزیابی می‌شود. نتایج مربوط به هر زیرمجموعه مجموعه داده‌ها، میانگین‌گیری و در جدول (۴) ارائه شده است.



جدول (۳): پارامترهای مرتبط با داده برای هر زیرمجموعه به دست آمده توسط DE.


اندازه ورودی (تعداد نورون‌ها)	R_e	n_s	n_w	مجموعه داده
۳۳۶	۱۲۹	۱	۲۴	A01
۲۳۸	۱۳۹	۱	۱۷	A02
۳۳۶	۱۲۹	۱	۲۴	A03
۲۳۸	۱۳۹	۱	۱۷	A04

در جدول (۴)، نتایج به دست آمده برای $f(v)$ با استفاده از تنظیمات فوق ارائه شده است. لازم به ذکر است کارایی به دست آمده برای مجموعه داده‌های A01 و A02 بالاست که این امر ناشی از این واقعیت است که پرسپترون تعداد دوره‌های بیشتری آموزش دیده است و بنابراین نتایج بهتری به دست می‌آید.

جدول (۴): امتیازات هر مجموعه داده با استفاده از پارامترهای مرتبط با داده به دست آمده توسط DE.

RHS				RMSE				مجموعه داده
STD	avg	max	min	STD	avg	max	min	
۰,۱۱	۳,۳۷	۳,۵۸	۳,۲۵	۰,۱۱	۱۴,۳۹	۱۴,۵۷	۱۴,۲۴	A01
۲,۱۷	۵۰,۶۹	۵۳,۹۰	۴۵,۹۹	۰,۱۱	۲۹,۰۹	۲۹,۲۳	۲۸,۹۰	A02
۰,۹۵	۵,۳۳	۶,۸۵	۴,۳۶	۰,۵۰	۱۵,۴۲	۱۶,۱۸	۱۴,۷۴	A03
۵,۸۸	۷۴,۷۷	۷۸,۶۲	۵۸,۵۲	۰,۵۳	۳۴,۷۴	۳۵,۱۰	۳۳,۲۵	A04

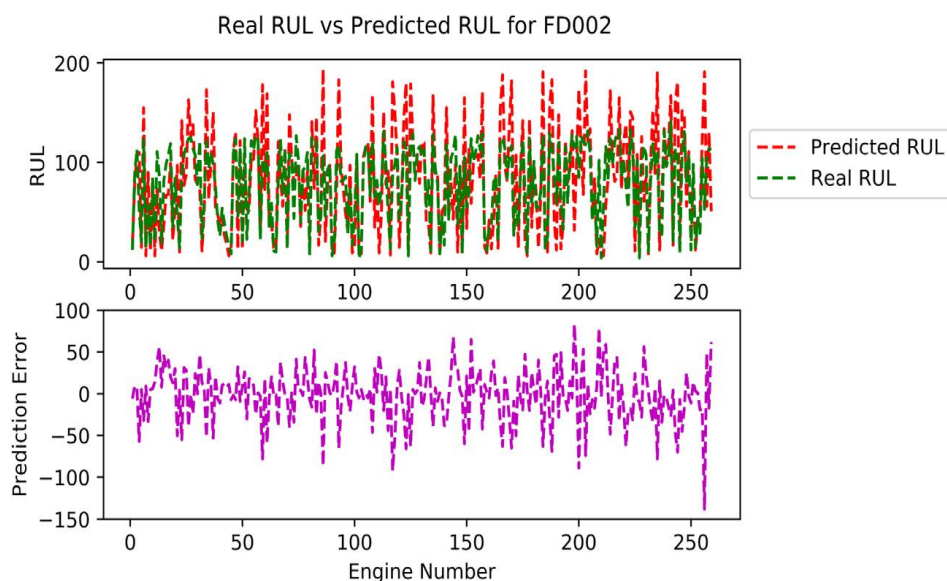
حال برای هر یک از مجموعه داده‌ها، مقادیر پیش‌بینی شده عمر مفید با مقادیر واقعی عمر مفید مقایسه می‌گردد. در قسمت بالای شکل‌های (۱) تا (۴) مقادیر پیش‌بینی شده عمر مفید (خطوط قرمز) در مقابل مقادیر واقعی عمر مفید (خطوط سبز) و در قسمت پایین این شکل‌ها خطای بین عمر مفید واقعی و عمر مفید پیش‌بینی شده رسم شده است.



شکل (۱): مقایسه مقادیر پیش‌بینی شده RUL با مقادیر واقعی RUL برای مجموعه داده FD001.

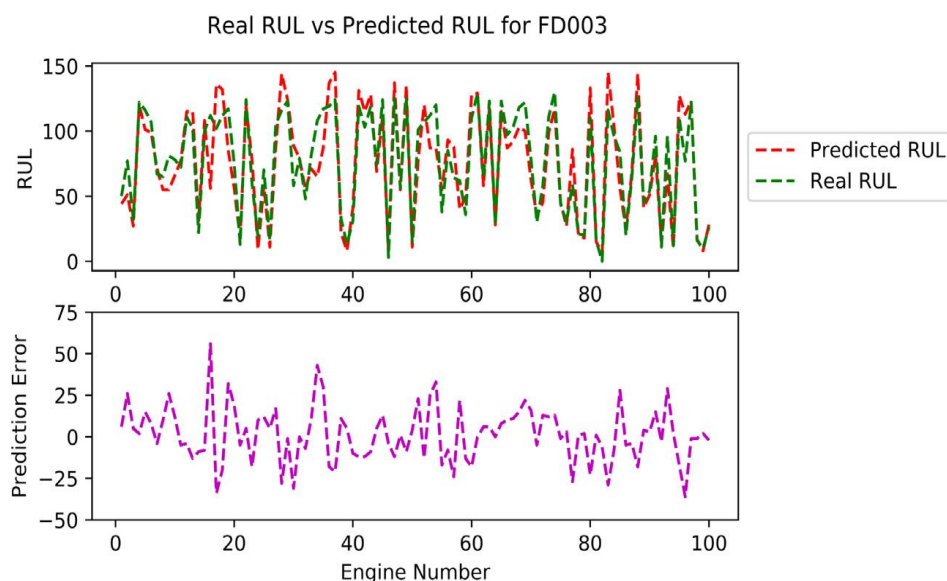


شکل (۱) مقایسه زیرمجموعه A01 را نشان می‌دهد. در این شکل، مشاهده می‌گردد که جز یک جفت موتور، مقادیر پیش‌بینی‌شده عمر مفید با مقادیر واقعی عمر مفید دقیقاً مطابقت دارند. برای اکثر موتورها خطا کوچک است. در ضمن، برای A02 در شکل (۲) مشاهده می‌شود رگرسیون از چندین پیش‌بینی عمر مفید، به ویژه در طیف مثبت، فراتر رفته است. یعنی این روش زمانی یک عمر مفید را پیش‌بینی می‌کند که در واقعیت، عمر مفید واقعی کمتر از مقدار پیش‌بینی‌شده باشد. این امر در زیر نمودار دوم مشهودتر است، که در آن حداکثر خطا در قله سرخابی در منتهی‌الیه سمت چپ نمودار برابر ۱۳۸ است.




شکل (۲): مقایسه مقادیر پیش‌بینی‌شده عمر مفید با مقادیر واقعی عمر مفید برای مجموعه داده A02

شکل (۳) نشان می‌دهد برای A03 پیش‌بینی‌ها با مقادیر واقعی عمر مفید دقیقاً مطابقت دارند. رفتار A04 مشابه A02 است که در شکل (۴) نشان داده شده است، و اکثر خطاها به گونه‌ای است که پیش‌بینی‌های عمر مفید بزرگتر از مقدار واقعی هستند.



شکل (۳): مقایسه مقادیر پیش‌بینی‌شده عمر مفید با مقادیر واقعی عمر مفید برای مجموعه داده A03



شکل (۴): مقایسه مقادیر پیش‌بینی‌شده عمر مفید با مقادیر واقعی عمر مفید برای مجموعه داده A04.

باتوجه به شکل‌های ارائه شده، می‌توان دو نتیجه گرفت. اول، مشاهده می‌گردد تعداد شرایط عملیاتی در مقایسه با تعداد مدهای خطا تأثیر بیشتری بر پیچیدگی داده‌ها دارد. این امر به خاطر آن است که زیرمجموعه‌های A02 و A04 خطاهای بزرگ‌تری نسبت به زیرمجموعه‌های A01 و A03 نشان می‌دهند. هرچند روند کلی خطاهای پیش‌بینی در بین این دو گروه از مجموعه داده‌ها مشابه است. دوم، برای زیرمجموعه‌های A02 و A04، بخش عمده خطا مربوط به پیش‌بینی‌های بزرگتر از مقادیر واقعی عمر مفید است. همچنین اندازه بزرگتر پنجره معمولاً منجر به پیش‌بینی بهتر می‌شود. این امر را می‌توان به ماهیت وابسته به تاریخچه مسئله فیزیکی مربوط دانست.

نتیجه‌گیری

این تحقیق با استفاده از مدل ریاضی و الگوریتم فراابتکاری روشی برای تخمین عمر مفید اجزای مکانیکی ارائه داده است. این روش با وجود آزمایش بر روی مجموعه داده‌های تصادفی، به حد کافی عمومی است و در این روش برای تولید رکوردهای آموزشی و آزمایشی از پنجره زمانی متحرک استفاده شده است. معلوم شد برای پیش‌بینی عمر مفید مجموعه داده تصادفی یک پرسپترون کم‌عمق کفایت می‌کند. برای یافتن بهترین پارامترهای مرتبط با داده که توابع امتیازدهی را بهینه می‌کنند فقط یک بار اجرای الگوریتم تکاملی کافی است. نتایج حاصله نشان می‌دهد به کارگیری چارچوب ارائه‌شده، دقیق و از نظر محاسباتی کارآمد است، به‌ویژه زمانی که برای مجموعه داده‌های بزرگ در کاربردهای واقعی استفاده شود.

مراجع

- [1] Liu, R., Ryan, J. K. (2005). Residual-life distributions from component degradation signals: a Bayesian approach. *IEEE Transactions*, 37(6), pp 543–557.
- [2] Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L., Siegel, D. (2014). Prognostics and health management design for rotary machinery systems - Reviews, methodology and applications. *Mechanical Systems and Signal Processing*, 42(12), pp 314–334.
- [3] Lim, P., Goh, C. K., & Tan, K. C. (2016). A time window neural networks based framework for remaining useful life estimation. In *Proceedings international joint conference on neural networks*, pp 1746–1753.



- [4] Peng, Y., Wang, H., Wang, J., Liu, D., Peng, X. (2012). A modified echo state network based remaining useful life estimation approach. In IEEE conference on prognostics and health management , pp 1–7.
- [5] Qian, Y., Yan, R., Gao, R. X. (2017). A multi-time scale approach to remaining useful life prediction in rolling bearing. *Mechanical Systems and Signal Processing*, 83, pp 549–567.
- [6] Jones, E., Oliphant, T., Peterson, P. (2001). Scipy: Open source scientific tools for Python. URL <http://www.scipy.org/>. [Online; Accessed 06/2018].
- [7] Parmeshwaran, V. (2004). Residual life distributions from component degradation signals: A neural-network approach. *IEEE Transactions on Industrial Electronics*, 51(3), pp 150–172.
- [8] Benkedjouh, T., Medjaher, K., Zerhouni, N., Rechak, S. (2013). Remaining useful life estimation based on nonlinear feature reduction and support vector regression. *Engineering Applications of Artificial Intelligence*, 26(7), pp 1751–1760.
- [9] Dong, M., He, D. (2007). A segmental hidden semi-Markov model (HSMM)- based diagnostics and prognostics framework and methodology. *Mechanical Systems and Signal Processing*, 21(5), pp 2248–2266.
- [10] Li, X., Ding, Q., Sun, J. Q. (2018). Remaining useful life estimation in prognostics using deep convolution neural networks. *Reliability Engineering & System Safety*, 172, pp 1–11.
- [11] Sikorska, J. Z., Hodkiewicz, M., Ma, L. (2011). Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*, 25(5), pp 1803–1836.
- [13] Ramasso, E. (2014). Investigating computational geometry for failure prognostics. *International Journal of Prognostics and Health Management*, 5(1), pp 1–18.
- [14] Storn, R., & Price, K. (1997). Differential evolution – A simple and efficient heuristic for global optimization over continuous spaces. *Journal of Global Optimization*, 11(4), pp 341–359.
- [15] Zhang, C., Lim, P., Qin, A., Tan, K. (2016). Multiobjective deep belief networks ensemble for remaining useful life estimation in prognostics. *IEEE Transactions on Neural Networks and Learning Systems*, 99, pp 1–13.
- [16] Saxena, A., Goebel, K. (2008) challenge data set. [Online] Available at: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>.