

پیش بینی زمان از کارافتادگی ماشین آلات دوار با استفاده از سیستم هوشمند

فاطمه فرهادی^۱، محمدرضا امین ناصری^{۲*}

۱. کارشناس ارشد مهندسی صنایع، سیستم های اقتصادی اجتماعی، دانشگاه تربیت مدرس تهران

۲. استاد مهندسی صنایع، دانشگاه تربیت مدرس تهران

(تاریخ دریافت: ۹۴/۱۲/۱۷، تاریخ دریافت روایت اصلاح شده: ۹۵/۰۲/۰۹، تاریخ تصویب: ۹۵/۰۸/۲۵)

چکیده

خرابی ماشین آلات در کارخانه ها گاه به توقف خط تولید منجر می شود و ضرر مالی زیادی را به دنبال دارد. عملیات پیشگیرانه به منظور جلوگیری از وقوع خرابی، نقشی مهم در افزایش طول عمر ماشین آلات و کاهش هزینه ها دارد. همچنین، پیش بینی زمان از کارافتادگی تجهیزات، مهندسان تعمیرات و نگهداری (نت) را قادر می سازد تا قبل از توقف کامل دستگاه برای تعمیر یا جایگزینی تجهیزات اقدام کنند و از این رو از هزینه تعمیرات اساسی جلوگیری شود (سیستم نت بر مبنای وضعیت) (CBM). اهمیت این امر در ماشین آلات دوار از جمله پمپ ها، توربین ها بخار، کمپرسورها و... به دلیل ماهیت عملکرد آن ها بیشتر است. از این رو، در این تحقیق عمر مفید باقیمانده (RUL) پمپ های توربینی واحد الفین شرکت پتروشیمی پارس براساس وضعیت سلامت یاتاقان ها با روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان (SVM) پیش بینی می شود. ابتدا براساس مقدار مؤثر (RMS)، مقدار متوسط، مقدار پیک و کرسر فاکتور یکی از یاتاقان های پمپ مدل پیش بینی ایجاد شده و در ادامه براساس مدل ایجاد شده و روش های مذکور RUL چهار یاتاقان دیگر پمپ با دقت بالایی پیش بینی شده است. نتایج نشان می دهد دقت پیش بینی با روش SVM نسبت به روش شبکه عصبی تک لایه بیشتر است.

واژه های کلیدی: پمپ توربینی، پیش بینی، شبکه عصبی مصنوعی، عمر مفید باقیمانده (RUL)، ماشین بردار پشتیبان، یاتاقان.

مقدمه

امروزه با رشد صنایع و افزایش تعداد کارخانه ها، نیاز به دستگاه های پیشرفته نیز افزایش یافته است. بخش شایان توجهی از هزینه های کارخانه ها صرف تهیه تجهیزات و تعمیرات آن ها می شود؛ بنابراین، حفاظت و نگهداری از این تجهیزات و در نتیجه وجود یک سیستم نگهداری و تعمیرات بسیار ضروری است. عملیات تعمیرات و نگهداری در حالت کلی به دو دسته سیستم واکنشی (غیر برنامه ای) و سیستم برنامه ای تقسیم بندی می شود. در بیشتر تحقیقات منظور از تعمیرات و نگهداری، سیستم برنامه ای است. یکی از انواع سیستم های برنامه ای نت، سیستم پیشگیرانه است که خود به دو دسته تقسیم می شود: ۱. سیستم نت سیستماتیک که طبق آن عملیات پیشگیرانه تعمیرات و نگهداری در دوره های زمانی مشخص انجام می گیرد، ۲. سیستم نت بر مبنای موقعیت (CBM) که در آن عملیات پیشگیرانه براساس وضعیت تجهیزات، قبل از وقوع خرابی و تعمیرات اساسی انجام می گیرد که در این تحقیق این سیستم مد نظر است.

در سیستم CBM عمر مفید باقیمانده (RUL)^۲ تجهیزات پیش بینی می شود و به عنوان ابزاری مؤثر در اختیار مهندسان بخش پایش قرار می گیرد تا قبل از وقوع کامل خرابی برنامه ریزی ها و عملیات پیشگیرانه صورت پذیرد. برای پیش بینی دقیق، تجزیه و تحلیل روند تخریب سیستم، الگوهای خرابی، رویدادهای گذشته ماشین و به دست آوردن داده از وضعیت کیفی ماشین ضروری است. پیش بینی عمر مفید باقیمانده و توانایی ارائه پیش بینی بلندمدت یکی از چالش های اجرای راهبردهای نگهداری و تعمیرات پیش بینانه در کاربردهای واقعی است [۱].

پیش بینی طول عمر ماشین آلات با استفاده از وضعیت فعلی و پروفایل عملکرد گذشته دستگاه، به دو دسته تقسیم می شود: تخمین RUL و تخمین فاصله بین خرابی ها. RUL به زمان باقیمانده تا مشاهده اولین خرابی و فاصله بین خرابی ها به فاصله زمانی بین دو خرابی گفته می شود. پیش بینی طول عمر ماشین آلات مرجع خوبی برای پرسنل نگهداری و تعمیرات است تا با آگاهی از خراب نبودن

دستگاه در بین فواصل مانیتورینگ، زمان های بازرسی را تعیین کنند؛ بنابراین، در روش اول براساس خرابی متغیرهای وضعیت، که نشان دهنده سطح واقعی خرابی است و حدود از پیش تعریف شده ای دارد، طول عمر تجهیزات پیش بینی می شود و در روش دوم، با استفاده از داده های تاریخی در دسترس یک مدل برای سازوکار خرابی ایجاد می شود [۲].

در سال های اخیر، در بیشتر پژوهش ها به تخمین RUL ماشین آلات پرداخته شده است. از اولین تحقیقات موجود در این زمینه، تحقیق ژانگ و گانسن در سال ۱۹۹۷ است که از شبکه عصبی خود-سازمان یافته^۳ برای تحلیل روند توسعه عیب و به منظور برآورد عمر باقیمانده تا رخداد خرابی یاتاقان استفاده شده است [۳]. در سال ۲۰۰۱، وانگ و واچتسوانس برای پیش بینی روند انتشار خطا و برآورد RUL به عنوان زمان باقیمانده تا زمان رسیدن عیب به سطح تعیین شده ای از خرابی، از شبکه های عصبی موجی پویا استفاده کردند [۴]. شبکه عصبی بازگشتی برای پیش بینی روند وضعیت و طول عمر دستگاه در سال ۲۰۰۱ انجام گرفت [۵]. دونگ و همکاران در سال ۲۰۰۴ از مدل شبکه عصبی پس انتشار خطا و مدل Grey GM برای پیش بینی وضعیت دستگاه استفاده کردند [۶].

درخت تصمیم بهترین ویژگی از مجموعه داده ها را به منظور طبقه بندی شناسایی می کند. در سال ۲۰۰۷، در تحقیقی از درخت تصمیم و ماشین بردار پشتیبان پروکسیمال (PSVM)^۴ برای تشخیص جهت خرابی یاتاقان ها استفاده شد و نتیجه تحقیق این بود که PSVM توانایی طبقه بندی خرابی با استفاده از مشخصه های آماری را دارد [۷]. در ادامه، در سال ۲۰۱۰ سکسیول و همکاران نیز از SVM و PSVM برای دسته بندی خرابی یاتاقانی پمپ سانتریفیوژ مونوبلاک^۵ استفاده کردند [۸]. از دیگر تحقیقات در زمینه تشخیص خرابی یاتاقان ها می توان به تحقیق کیم و همکاران در سال ۲۰۱۲ اشاره کرد. آن ها با استفاده از ماشین بردار پشتیبان عمر مفید باقیمانده دو پمپ HP-LNG فرایند خرابی یاتاقان ها را پیش بینی کردند. در این تحقیق از داده های شبیه سازی شده استفاده شده است [۹]. باراکات و همکاران در سال ۲۰۱۳ از یک شبکه عصبی در حال رشد رقابتی (HC-GNN)^۶ با یادگیری

انقباضی برای شناسایی و تشخیص خرابی های کوچک در یاتاقان استفاده کردند. HC-GNN در صورت نیاز یک لایه پنهان به شبکه عصبی اضافه می کند تا ریسک دسته بندی اشتباه را کاهش دهد. این کار موجب می شود شبکه کوچک تری در مقایسه با توابع پایه شعاعی کلاسیک یا شبکه های عصبی احتمالی ایجاد شود و در نتیجه یک مجموعه داده بزرگ را با درصد صحت بالایی دسته بندی می کند [۱۰]. در سال ۲۰۱۳، در تحقیقی دیگر یک روش جدید برای استخراج ویژگی از سیگنال های ارتعاشی یاتاقان ارائه شد. در این تحقیق، تأثیر اندازه پنجره زمانی بر محاسبه دامنه ویژگی های طیفی و همچنین تأثیر آن بر صحت دسته بندی ANN بررسی شد [۱۱]. گوو و همکاران در سال ۲۰۱۷، تخمین خرابی یاتاقان ها را براساس وضعیت سلامت شاخص های آن انجام دادند. در این تحقیق، دو ضعف اساسی در تخمین خرابی در نظر گرفته شده است: ۱. رنج مشخصه های آماری به ازای هر شاخص مورد نظر متفاوت است؛ بنابراین، در نظر مشخصه های آماری برای این شاخص ها دشوار است، ۲. به علت اینکه شاخص های سلامت دستگاه های مختلف در زمان خرابی شرایط متفاوتی دارند، تخمین آستانه خرابی دشوار است. از این رو، برای غلبه بر این ضعف ها از روش شبکه عصبی بازگشتی استفاده شده است [۱۲].

از شبکه عصبی فازی برای تخمین روند خرابی و طول عمر باقیمانده تجهیزات در تحقیقات دیگر نیز استفاده شده است. در این راستا، وانگ و همکاران از شبکه های عصبی بازگشتی و سیستم های استنتاج فازی عصبی برای پیش بینی روند انتشار خرابی استفاده کردند و نتایج را با هم مقایسه کردند [۱۳]. در تحقیقی دیگر در سال ۲۰۰۳، رویکرد فازی-عصبی برای برآورد RUL به کار گرفته شد که در آن به علت دست نیافتن به داده های واقعی از دانش کارشناسان آن حوزه استفاده شد [۱۴]. چن و همکاران یک روش پیش بینی RUL یکپارچه را با استفاده از سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)^۷ و فیلتر ذرات با مرتبه بالا توسعه دادند. آن ها زمان تکامل شاخص خرابی را پیش بینی کردند و تابع چگالی احتمال RUL را تخمین زدند. نتایج این تحقیق نشان می دهد هنگامی که مدل رشد خرابی از درجه یک باشد، عملکرد این روش از دو روش

داده‌های خرابی و داده‌های تعلیق بهره گرفته شده است. نتایج تحقیق نشان می‌دهد داده‌های تعلیق در افزایش دقت تخمین طول عمر بسیار مؤثر است [۱۸]. عملیات پیشگیرانه و جلوگیری از خرابی کامل ماشین‌آلات دوار شامل موتورهای احتراق داخلی، توربین‌ها، پمپ‌ها، کمپرسورها و... بیش از سایر ماشین‌آلات اهمیت دارد. یاتاقان‌ها^۱ بخش مهمی از تجهیزات هستند که به‌طور گسترده در ماشین‌آلات دوار استفاده می‌شوند. آسیب‌پذیرترین عضو ماشین‌آلات دوار یاتاقان است و در نتیجه خرابی آن‌ها ممکن است موجب خرابی ماشین‌آلات دوار شود؛ بنابراین، تشخیص و پیش‌بینی خرابی یاتاقان با توجه به اهمیت ویژه ماشین‌آلات دوار در صنایع، ضروری است.

پیش‌بینی ANFIS و پیش‌بینی بر مبنای فیلتر ذرات بهتر است [۱۵]. در تحقیقی دیگر در سال ۲۰۱۰ از الگوریتم‌های درخت تصمیم فازی و سیستم‌های خبره فازی در دسته‌بندی خرابی پمپ‌های سانتریفیوژ مونوبلاک استفاده شد و نتایج با هم مقایسه شدند [۱۶]. در سال ۲۰۱۲، تیان یک روش شبکه عصبی مصنوعی را برای رسیدن به پیش‌بینی دقیق از RUL و تعیین درصد طول عمر دستگاه با استفاده از تابع نرخ خرابی وایبول به کار برد و درآمد مقایسه جمعی بین روش ANN پیشنهاد شده و روش ANN تطبیقی ارائه داد که نتایج نشان می‌دهد روش پیشنهادی وی برای پیش‌بینی RUL دقیق‌تر بوده است [۱۷]. در سال ۲۰۱۵، چاو و همکاران یک رویکرد داده‌محور را برای تخمین RUL توسعه دادند که در آن از

جدول ۱. دسته‌بندی مرور ادبیات

نویسندگان	سال انتشار	موضوع	روش
Zhang & Ganesan	۱۹۹۷	پیش‌بینی RUL براساس یاتاقان‌ها	شبکه عصبی خودسازمان‌یافته
Wang & Vachtsevanos	۲۰۰۱	پیش‌بینی RUL براساس سطح تعیین‌شده آستانه خرابی	شبکه عصبی موجی پویا
Yam et al.	۲۰۰۱	تعیین خرابی دستگاه‌های بحرانی در یک شرکت نیرو	شبکه عصبی بازگشتی
Dong et al.	۲۰۰۴	تشخیص خرابی سیستم تغذیه آب براساس وضعیت آن	روش شبکه عصبی پس انتشار خطا (BP NN) و مدل Grey GM
Sugumaran et al.	۲۰۰۷	تشخیص خرابی یاتاقان‌ها	ماشین بردار پشتیبان پروکسیمال (PSVM)
Sakthivel et al.	۲۰۱۰	دسته‌بندی خرابی‌های پمپ‌های سانتریفیوژ مونوبلاک	PSVM و SVM
Kim et al.	۲۰۱۲	پیش‌بینی خرابی یاتاقان‌ها براساس داده‌های شبیه‌سازی شده	SVM
Barakat et al.	۲۰۱۳	تشخیص خرابی یاتاقان‌ها با داده‌های احتمالی	شبکه عصبی در حال رشد رقابتی (HC-GNN)
Amar et al.	۲۰۱۳	دسته‌بندی خرابی یاتاقان‌ها	شبکه عصبی

ادامه جدول ۱. دسته بندی مرور ادبیات

نویسندگان	سال انتشار	موضوع	روش
et al. Guo	۲۰۱۷	تشخیص خرابی یاتاقان ها	شبکه عصبی بازگشتی
Wang et al.	۲۰۰۴	تشخیص خرابی و طول عمر تجهیزات	شبکه های عصبی بازگشتی و سیستم های استنتاج فازی عصبی
Chinnam & Baruah	۲۰۰۳	پیش بینی RUL تجهیزات براساس داده های تخمینی	شبکه عصبی فازی
Chen et al.	۲۰۱۲	پیش بینی RUL تجهیزات	ارائه روش جدید و مقایسه با سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) و روش فیلتر ذرات
Sakthivel et al.	۲۰۱۰	دسته بندی خرابی های پمپ های سانتریفیوژ مونوبلاک	سیستم های خبره فازی
Tian	۲۰۱۲	تخمین RUL براساس داده های احتمالی	ارائه روش جدید پیش بینی و مقایسه با روش ANN و روش ANN تطبیقی
Byeng & Chao	۲۰۱۵	تخمین RUL تجهیزات براساس داده های خرابی و داده های تعلیقی	یک رویکرد جدید آموزش محور

مدل های اجرای برنامه

۱.۱. ماشین بردار پشتیبان

ماشین بردار پشتیبان (SVM) یکی از روش های یادگیری به همراه نظارت است که از آن برای طبقه بندی استفاده می شود. SVM درواقع یک جداگر دودویی است که داده های دو کلاس را با استفاده از یک مرز خطی یا غیرخطی از هم جدا می کند. در تقسیم خطی داده ها هدف دستیابی به تابعی است که تعیین کننده ابرصفحه ای با بیشترین حاشیه است. با حداکثر شدن حاشیه این ابرصفحه، تفکیک بین طبقات به حداکثر می رسد. مجموعه نقاط ممکن است به طور خطی یا غیرخطی قابل تفکیک باشند که در ادامه بررسی می شود [۱۹].

۱.۱.۱. تفکیک خطی


فرض کنید $S = \{x_i, y_i\}$ یک نمونه آموزشی است که از دو کلاس $y_i = \pm 1$ شامل m ویژگی $i = 1, 2, \dots, m$ تشکیل شده

براساس جمع بندی ادبیات در جدول ۱، در پژوهش های اندکی تخمین طول عمر دستگاه براساس وضعیت خرابی یاتاقان ها صورت گرفته است و در هیچ یک از این پژوهش ها روش بردار پشتیبان و شبکه عصبی به عنوان دو روش مهم در پیش بینی مقایسه نشده است. همچنین، در بیشتر این پژوهش ها از داده های شبیه سازی شده استفاده شده است؛ بنابراین، در این تحقیق تخمین RUL ماشین دوار پمپ توربینی براساس سلامت یاتاقان های آن (سیستم نگهداری CBM) براساس داده های واحد الفین شرکت پتروشیمی پارس و با روش شبکه عصبی و ماشین بردار پشتیبان صورت می گیرد و نتایج مقایسه می شود.

در ادامه، ابتدا مدل های اجرای برنامه شرح داده می شود و سپس RUL چهار یاتاقان پمپ با استفاده از شبکه عصبی مصنوعی و ماشین بردار پشتیبان با دقت بالایی پیش بینی می شود و در پایان نتایج ارائه و مقایسه می شوند.

وظیفه آن برقراری تعادل بین حداکثر کردن حاشیه و حداقل کردن خطای دسته‌بندی است و همواره بزرگ‌تر از صفر است [۲۰].

بنابراین، همان‌طور که گفته شد، در حالتی که داده‌ها جداپذیر نباشند و کلاس‌ها دارای هم‌پوشانی باشند (شکل ۲)، جداکردن کلاس‌ها از طریق مرز خطی همواره با بروز خطا همراه است. به‌منظور حل این مشکل ابتدا باید داده‌ها را با استفاده از یک تبدیل غیرخطی ϕ ، از فضای اولیه به فضایی با بعد بالاتر منتقل کرد تا تداخل کلاس‌های موجود کاهش یابد [۲۱]. سپس با استفاده از معادلات قبل و با جایگزین کردن x_i با $\phi(x_i)$ ، ابرصفحه بهینه به‌دست می‌آید [۲۲].



شکل ۲. تبدیل غیرخطی در ماشین بردار پشتیبان

یکی از راه‌های انتقال داده‌ها به بعدی بالاتر استفاده از توابع کرنل به شرح زیر است:

کرنل خطی

$$K(x_i, x_j) = x_i^T x_j + C \quad (3)$$

کرنل چندجمله‌ای

$$K(x_i, x_j) = (\alpha x_i^T x_j + C)^p \quad (4)$$

کرنل تابع پایه شعاعی

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (5)$$

در معادلات فوق، C مقدار ثابت، p درجه چندجمله‌ای و $\gamma = \frac{1}{2\sigma^2}$ پارامتر قابل تنظیم است.

هایپر پارامتر


به پارامترهای تابع کرنل، هایپر پارامتر گفته می‌شود. با تنظیم کردن هایپر پارامترها می‌توان میزان حاشیه جداساز و محدوده تصمیم را در الگوریتم‌های SVM غیرخطی

است. همان‌طور که شکل ۱ نشان می‌دهد، خط $wx + b = 0$ داده‌های موجود را در دو کلاس ± 1 طبقه‌بندی می‌کند. به این خط ابرصفحه جداکننده گفته می‌شود. دو خط $wx + b = \pm 1$ نیز به ترتیب بیانگر مرز ناحیه دسته‌های $y = -1$ و $y = +1$ است.

همان‌طور که ملاحظه می‌شود، دو کلاس داده‌ها به صورت خطی قابل تفکیک هستند. در حالتی که داده‌ها قابل تفکیک به صورت خطی باشند، ماشین بردار پشتیبان با در نظر گرفتن مجموعه داده‌های آموزشی، با استفاده از حل مسئله بهینه‌سازی زیر، ابرصفحه بهینه با حاشیه حداکثر را پیدا می‌کند:

$$\begin{aligned} \min & \frac{1}{2} \|w\|^2 \\ \text{s.t. } & y_i(w \cdot x_i + b) \geq 1 \quad i=1, 2, \dots, m \end{aligned} \quad (1)$$

که در آن $\|w\|$ نرم اقلیدسی است. براساس مدل ۱، کمینه‌شدن مقدار $\|w\|$ با توجه به محدودیت آن، به حداکثر شدن پهنای حاشیه صفحه منجر می‌شود.



شکل ۱. تفکیک خطی داده‌ها در ماشین بردار پشتیبان

۲.۱.۱. تفکیک غیرخطی

یک فرض بسیار مهم در SVM این است که داده‌ها به صورت خطی جداپذیر باشند، درحالی‌که در عمل بیشتر مواقع این فرض برقرار نیست. در این راستا، اولین بار کورتس و وپنیک در سال ۱۹۹۵ متغیرهای نامنفی $\varepsilon_i \geq 0$ را به عنوان مقادیر خطا برای هر بردار تعریف و به مدل اضافه کردند:

$$\begin{aligned} \min & \frac{1}{2} \|w\|^2 + C \sum_i \varepsilon_i \\ \text{s.t. } & y_i(w \cdot x_i + b) \geq 1 - \varepsilon_i, \varepsilon_i \geq 0 \quad \forall i \end{aligned} \quad (2)$$

در مدل ۲، C پارامتر تنظیم‌کننده حاشیه است که

$$\begin{aligned} \min & 1/2 \|w\|^2 + C/2 \sum_i \varepsilon_i^2 \\ \text{s.t. } & y_i(\langle w, x_i \rangle + b) \geq 1 - \varepsilon_i, \varepsilon_i \geq 0 \quad \forall i \end{aligned} \quad (6)$$


۲.۱. شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یک شبیه سازی از سیستم عصبی بدن انسان یا حیوانات است. معماری عمومی یک شبکه عصبی شامل لایه های ورودی، خروجی و میانی (پنهانی) است. داده ها به گره های (نودهای) لایه ورودی وارد می شوند و در لایه میانی پردازش می شوند. پس از عملیات محاسباتی در لایه میانی، خروجی ها از لایه نهایی خارج می شوند.

بر اساس مباحث یادشده، عملیات محاسباتی در لایه میانی انجام می گیرد. مقدار ورودی هر نود طبق رابطه ۷ به دست می آید. در این زمینه، y_i مقدار ورودی نود i ام از لایه ورودی و w_{ij} وزن کمان بین نود i و j است. v_j نیز میزان بایاس مربوط به نود j ام لایه میانی را نشان می دهد؛ بنابراین، میزان ورودی به نود j ام لایه میانی از رابطه ۷ توسط v_j به دست می آید. در مرحله بعد، پردازش در لایه میانی از طریق تابع فعال سازی انجام می گیرد. یکی از رایج ترین توابع فعال سازی، تابع سیگموئید است که از رابطه ۸ به دست می آید و خروجی این تابع به عنوان خروجی نودهای لایه میانی است. همان طور که در شکل ۳ نشان داده می شود، هنگامی که a (ضریب تابع سیگموئید) به سمت بی نهایت میل کند، خروجی تابع به یک نزدیک می شود.

$$v_j = \sum_i w_{ij} y_i + b_j \quad (7)$$

$$\varphi(v_j) = \frac{1}{1 + e^{-av_j}} \quad a > 0 \quad (8)$$



شکل ۳. تابع سیگموئید

تعیین کرد. درواقع، با تنظیم هایپر پارامترها می توان الگوریتم SVM را با توجه به نوع داده ها بهینه ساخت. دو نمونه از هایپر پارامترهای مهم به شرح زیر هستند:

پارامتر C

پارامتر C میزان اجتناب از دسته بندی اشتباه^{۱۰} را تعیین می کند. برای مقادیر بزرگ C، الگوریتم SVM حاشیه^{۱۱} کمتری در نظر می گیرد. در این حالت، فاصله حاشیه موجب می شود نقاط یادگیری بیشتری دسته بندی شوند. برای مقادیر کوچک C الگوریتم SVM حاشیه جداساز بزرگتری را در نظر می گیرد. مقدار C هنگامی اهمیت پیدا می کند که داده ها دسته بندی نشده اند. اگر دسته ها شباهت بیشتری داشته باشند، باید از مقادیر بزرگ تر C برای تفکیک آن ها استفاده کرد. اگر داده ها نویزی باشند، باید مقادیر کم را برای C در نظر گرفت تا نویزها خارج از دسته بندی قرار گیرند. مقادیر مناسب برای C در دامنه 10^{-6} تا 10^3 قرار دارند [۲۳].

پارامتر گاما

پارامتر گاما محدوده تصمیم گیری در مورد داده ها را تعیین می کند. برای مقادیر کم پارامتر گاما، خط تفکیک کننده به صورت یک خط راست و دقت دسته بندی بسیار کم است و با افزایش مقدار گاما انحنای خط تفکیک کننده بیشتر می شود و دقت دسته بندی افزایش می یابد. هرچه مقدار پارامتر گاما بیشتر باشد، خط تفکیک کننده به صورت منحنی پیچیده تری درمی آید و به ازای مقادیر بالا برای پارامتر گاما محدوده تصمیم کوچک تر می شود و هم پوشانی نیز افزایش می یابد [۲۳].

۳.۱.۱. حداقل مربعات ماشین بردار پشتیبان

(LSSVM)^{۱۲}

همان طور که گفته شد، برای حل مدل ماشین بردار پشتیبان از برنامه ریزی درجه دو استفاده می شود. حل مسئله در ابعاد بزرگ ممکن است به محاسبات پرهزینه بینجامد. در این زمینه، سوپکنز و وندوال در سال ۱۹۹۹ روش حداقل مربعات را برای ماشین های بردار پشتیبان به صورت زیر طراحی کردند:

PUMP/P-1207A/POINT1/A1

PUMP/P-1208A/POINT1/V1

PUMP/P-1201A/POINT3/H3

PUMP /P-1205A/POINT2/A2

برای هر یاتاقان پمپ، در بازه زمانی مشخصی داده‌های مختلفی طبق جدول ۲ به‌دست آمد. تعدادی از داده‌ها در این بازه زمانی در دسترس نبود که از روش درون‌یابی برای به‌دست‌آوردن آن‌ها استفاده شد.

جدول ۲. مشخصات پمپ و تعداد داده موجود

تعداد داده	پمپ
۱۱۵	P-1208A/POINT1/V1
۸۰	P-1207A/POINT1/A1
۱۱۵	P-1201A/POINT3/H3
۱۱۰	P-1205A/POINT2/A2

جدول‌های ۳ و ۴ مشخصات مدل پیش‌بینی SVM و شبکه عصبی تک‌لایه را نشان می‌دهند.

پیش‌بینی RUL

خرابی دستگاه‌ها معمولاً به‌صورت مرحله‌ای و تدریجی است و این مسئله درمورد یاتاقان‌ها نیز صدق می‌کند، به‌طوری‌که ارتعاشات یاتاقان ابتدا ناچیز است و پس از گذر زمان به تدریج افزایش می‌یابد. زمانی که میزان ارتعاش به آستانه خطر برسد، باید تعویض شود.

مهندسان بخش پایش وضعیت، آستانه خطر ارتعاشات را تعیین می‌کنند و با پیش‌بینی RUL یاتاقان، زمان تعویض یا تعمیرات لازم پیش‌بینی می‌شود.

در این تحقیق، با استفاده از مدل پیش‌بینی SVM و شبکه عصبی مصنوعی میزان عمر مفید باقیمانده براساس داده‌های یاتاقان‌های پمپ توربینی شرکت پتروشیمی پارس واحد الفین پیش‌بینی می‌شود. ابتدا مدلی از روند تغییرات RUL یک یاتاقان ایجاد می‌شود و سپس این مدل روی چهار یاتاقان دیگر تست می‌شود. در این راستا، با استفاده از مقدار مؤثر (RMS)^{۱۳}، مقدار متوسط، مقدار پیک و کرسست فاکتور، یاتاقان پمپ PUMP/P-1203A/POINT3/H3 یک مدل ایجاد شد و سپس این مدل برای RUL چهار یاتاقان پمپ دیگر زیر استفاده شد.

جدول ۳. پیش‌بینی RUL با الگوریتم SVM

دقت پیش‌بینی روند	نوع پمپ	C	تابع
۰/۹۲۰ +/- ۰/۱۷۱	P-1208A/POINT1/V1	۱	دات
۰/۹۰۰ +/- ۰/۱۱۹	P-1207A/POINT1/A1		


جدول ۴. پیش‌بینی RUL با روش شبکه عصبی مصنوعی

دقت پیش‌بینی	نوع پمپ	تعداد نود لایه	تعداد لایه
۰/۸۹۰ +/- ۰/۰۰۰	P-1201A/POINT3/H3	۱۰	۱
۰/۸۶۰ +/- ۰/۸۱۴	P-1205A/POINT2/A2	۱۲	۱

۴، میزان دقت پیش‌بینی براساس روش شبکه عصبی ۸۹ و ۸۶ درصد است.

نتایج نشان می‌دهد میزان دقت پیش‌بینی در روش SVM با تابع دات نسبت به روش شبکه عصبی تک‌لایه بالاست؛ بنابراین، روش بهتری در مطالعه موردی تحقیق است.

همان‌طور که مشخص است، بالاترین دقت پیش‌بینی RUL حدود ۹۲ درصد بوده که با روش SVM با تابع دات برای پمپ P-1208A/POINT1/V1 به‌دست آمده است. همچنین، RUL به‌دست‌آمده از این روش برای پمپ P-1207A/POINT1/A1 حدود ۹۰ درصد است. طبق جدول



نمودار ۴. پیش بینی RUL یاتاقان پمپ
1205A/POINT2/A2 شبکه عصبی تک لایه


نتیجه گیری

ماشین آلات دوار به صورت گسترده در صنایع به ویژه صنایع پتروشیمی استفاده می شود. تشخیص و پیش بینی زمان از کار افتادگی این ماشین آلات برای تضمین بهره وری و ایمنی کارخانه و جلوگیری از هزینه های توقف خطوط تولید اهمیت فراوانی دارد. پیش بینی عمر مفید باقیمانده (RUL) تجهیزات به مهندسان پایش وضعیت این امکان را می دهد که قبل از خرابی کامل، به منظور تعویض یا تعمیرات برنامه ریزی کنند و بدین ترتیب از هزینه تعمیرات اساسی و هزینه توقف خط تولید جلوگیری شود.


یاتاقان ها بخشی مهم از تجهیزات هستند که به طور گسترده در ماشین آلات دوار استفاده می شوند. در این تحقیق، خرابی یاتاقان چهار پمپ توربینی واحد الفین شرکت پتروشیمی پارس براساس وضعیت سلامت یاتاقان پیش بینی شده است. با استفاده از مقدار مؤثر (RMS)، مقدار متوسط، مقدار پیک و کرسست فاکتور، یاتاقان یک پمپ توربینی، مدلی ایجاد شد. سپس این مدل برای پیش بینی RUL چهار یاتاقان پمپ دیگر استفاده شد. برای پیش بینی RUL، از روش ماشین بردار پشتیبان (SVM) با تابع دات و شبکه عصبی مصنوعی تک لایه استفاده شد و مدل پیشنهادی RUL را با دقت بالایی پیش بینی کرد. نتایج نشان می دهد روش SVM نسبت به روش شبکه عصبی تک لایه دقت بیشتری دارد و RUL پیش بینی شده با این روش به مقادیر واقعی نزدیک تر است.

تحقیق حاضر در صنایعی که ماشین آلات دوار دارند، از جمله شرکت های پتروشیمی، صنعت نفت و گاز، مینا و... قابل استفاده است. در این صنایع، پیش بینی RUL ماشین آلات یا شاخص های مؤثر در ماشین آلات دوار از


RUL واقعی و پیش بینی شده در نمودارهای ۱ تا ۴ برای هریک از چهار پمپ توربینی آورده شده است. همان طور که نمودارها نیز نشان می دهند، میزان خطا در نمودار ۱ کمتر است و خط پیش بینی به داده های واقعی نزدیک تر است. در نمودار ۲ نیز دقت بالاست و میزان خطا کمتر است. در نمودارهای ۳ و ۴ که مربوط به روش شبکه عصبی تک لایه است، میزان خطا بیشتر است و خط پیش بینی از داده های واقعی انحراف بیشتری دارد.



نمودار ۱. پیش بینی RUL یاتاقان پمپ 1208A/POINT1/V1
الگوریتم SVM تابع دات



نمودار ۲. پیش بینی RUL یاتاقان پمپ 1207A/POINT1/A1
الگوریتم SVM تابع دات



نمودار ۳. پیش بینی RUL یاتاقان پمپ
1201A/POINT3/H3

عصبی چند لایه با توابع مختلف فعال‌سازی استفاده کرد.

سیاسگزاری

از مهندسان بخش پایش وضعیت واحد الفین شرکت پتروشیمی پارس به دلیل کمک در جمع‌آوری داده، تشکر می‌شود.

جمله یاتاقان‌ها به مهندسان نت امکان انجام‌دادن تعمیرات پیشگیرانه به‌موقع را می‌دهد که این امر به افزایش طول عمر و ایمنی ماشین‌آلات منجر می‌شود و همچنین از هزینه‌های توقف خط تولید و هزینه تعمیرات اساسی یا جایگزینی جلوگیری می‌کند. در تحقیقات آتی می‌توان

به‌منظور مقایسه بهتر دو روش یادشده، از شبکه‌های

مراجع

1. Kim, H. E., Tan, A. C. C., Mathew, J., Kim, E. Y. H. and Choi, B. K. (2009). "Prognosis of bearing failure based on health state estimation", *Presented at the Proceedings of the 4th World Congress on Engineering Asset Management, Marriott Athens Ledra Hotel, Athens*.
2. Jardine, A. K. S., Lin, D. and Banjevic, D. (2006). "A review on machinery diagnostics and prognostics implementing condition-based maintenance", *Mechanical Systems and Signal Processing*, Vol. 20, No.7, PP. 1483- 1510.
3. Zhanj, S. and Ganesan, R. (1997). "Multivariable trend analysis using neural networks for intelligent diagnostics of rotating machinery", *Journal of Engineering for gas turbines and power*, Vol. 119, No. 2, PP. 378- 384.
4. Wang, P. and Vachtsevanos, G. (2001). "Fault prognostics using dynamic wavelet neural networks", *AI EDAM*, Vol. 15, No. 4, PP. 349- 365.
5. Yam, R. C. M., Tse, P. W., Li, L. and Tu, P. V. (2001). "Intelligent predictive decision support system for condition-based maintenance", *The International Journal of Advanced Manufacturing Technology*, Vol. 17, No. 5, PP. 383- 391.
6. Dong, Y. L., GU, Y. J., Yang, K. and Zhang, W. K. (2004). "A combining condition prediction model and its application in power plant", *Proceedings of International Conference on Machine Learning and Cybernetics IEEE*. Vol. 6 , PP. 3474- 3478.
7. Sugumaran, V., Muralidharan, V. and Ramachandran, K. I. (2007). "Feature selection using decision tree and classification through proximal support vector machine for fault diagnostics of roller bearing", *Mechanical Systems and Signal Processing*, Vol. 21 No. 2, PP. 930- 942.
8. Sakthivel, N. R., Sugumaran, V. and Nair, B. B. (2010). "Application of support vector machine (SVM) and proximal support vector machine (PSVM) for fault classification of monoblock centrifugal pump", *International Journal of Data Analysis Techniques and Strategies*, Vol. 2, No. 1, PP. 38- 61.
9. Kim, H. E., Tan, A. C. C., Mathew, J. and Choi, B. K. (2012). "Bearing fault prognosis based on health state probability estimation", *Expert Systems with Applications*, Vol. 39, No. 5, PP. 5200- 5213.
10. Barakat, M., Elbadaoui, M. and Guillet, F. (2013). "Hard competitive growing neural network for the diagnosis of small bearing faults", *Mechanical Systems and Signal Processing*, Vol. 37, No. 1-2, PP. 276- 292.
11. Amar, M., Gondal, I. and Wilson, C. (2013). "Multi-size-window spectral augmentation: Neural network bearing fault classifier", *In Industrial Electronics and Applications (ICIEA), 8th IEEE Conference on*. PP. 261- 266.
12. Guo, L., Li, N., Jia, F. and Lei, Y. (2017). "A recurrent neural network based health indicator for remaining useful life prediction of bearings", *Journal of Neurocomputing*, Vol. 240, No. 31, PP. 98- 109.
13. Wang, W. Q., Golnaraghi, M. F. and Ismail, F. (2004). "Prognosis of machine health condition using neuro-fuzzy systems", *Mechanical Systems and Signal Processing*, Vol. 18, No. 4, PP. 813- 831.

14. Chinnam, R. B. and Baruah, P. (2003). "Autonomous diagnostics and prognostics through competitive learning driven HMM-based clustering In Neural Networks", *Proceedings of the International Joint Conference on*, Vol. 4 ,PP. 2466- 2471.
15. Chen, C., Vachtsevanos, G. and Orchard, M. E. (2012). "Machine remaining useful life prediction: An integrated adaptive neuro-fuzzy and high-order particle filtering approach", *Mechanical Systems and Signal Processing*, Vol. 28, PP. 597- 607.
16. Sakthivel, N. R., Sugumaran, V. and Babudevasenapati, S. (2010). "Vibration based fault diagnosis of monoblock centrifugal pump using decision tree", *Expert Systems with Applications* Vol. 37 , No. 6, PP. 4040- 4049.
17. Tian, Z. (2012). "An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring", *Journal of Intelligent Manufacturing*, Vol. 23, No. 2, PP. 227- 237.
18. Chao, H., & Byeng D. Y., Taejin, K. and Pingfeng, W. (2015). "A co-training-based approach for prediction of remaining useful life utilizing both failure and suspension data", *Journal of Mechanical Systems and Signal Processing*, Vol. 62- 63, PP. 75- 90.
19. Engin, A. (2009). "Selecting of the optimal feature subset and kernel parameters in digital modulation classification by using hybrid genetic algorithm- support vector machines", *Expert Systems with Applications*, Vol. 36, No. 2 , PP. 1391- 1402.
20. Cristianini, N. and Shawe-Taylor, J. (2000). *An introduction to support vector machines and other kernel-based learning methods*, Cambridge University Press, Cambridge.
21. Burges, C. (1998). "Tutorial on support vector machines for pattern recognition", *Data Mining and Knowledge Discovery*, Vol. 2, No. 2, PP. 121- 167.
22. Bellotti, T. and Crook, J. (2008). "Support vector machines for credit scoring and discovery of significant features", *Expert Systems with Applications*, Vol. 36, No. 2, PP. 102- 109.
23. Ben-Hur, A. and Weston, J. (2010). *A user's guide to support vector machines*, In: Data Mining Techniques for the Life Sciences, In Carugo, O. and Eisenhaber, F. (Eds), Totowa, NJ: Humana Press, PP. 223- 239.

واژه‌های لاتین به ترتیب استفاده در متن

1. Condition Based Maintenance
2. Remaining Useful Life
3. Self-organizing Neural Network
4. Proximal Support Vector Machines
5. Monoblock Centrifugal Pump
6. Hard Competitive Growing Neural Network
7. Adaptive Neuro-Fuzzy Inference System
8. Bearings
9. Support Vector Machine
10. Misclassification
11. Margin
12. Least Square Support Vector Machine
13. Root Mean Square