

# پیش‌بینی روند زوال و عمر مفید باقیمانده‌ی باتاقان غلتشی با کمک شبکه‌ی عصبی بازگشتی حافظه‌ی طولانی کوتاه‌مدت

مهدی بهزاد\* (استاد)

سیدعلی حسین لی (کارشناس ارشد)

دانشکده‌ی مهندسی مکانیک، دانشگاه صنعتی شریف

حسام‌الدین ارغند (استادیار)

گروه مهندسی مکانیک، دانشکده‌ی مهندسی، دانشگاه زنجان

افشین بنازاده (دانشیار)

دانشکده‌ی مهندسی هوافضا، دانشگاه صنعتی شریف

مهندسی مکانیک شریف، بهار ۱۴۰۱ (پژوهشی)  
دوری ۳-۲، شماره ۱، ص. ۶۳-۷۱ (پژوهشی)

در این مقاله، پیشینه‌ی دامنه‌ی سیگنال زمانی شتاب به‌عنوان مشخصه‌ی ارتعاشی مناسب که نمایش‌گر خوبی از روند زوال باتاقان غلتشی است انتخاب شده و به منظور پیش‌بینی روند زوال و عمر مفید باقیمانده به کار رفته است. در گام نخست با به کار بردن یک انتقال لگاریتمی، این مشخصه‌ی ارتعاشی به یک سری زمانی پایدار تبدیل شده است. سپس با کمک شبکه‌ی عصبی بازگشتی حافظه‌ی طولانی کوتاه‌مدت، نحوه‌ی رشد این مشخصه‌ی ارتعاشی پیش‌بینی شده است. این پیش‌بینی روی داده‌های دو نمونه از باتاقان‌های آزمایشی پروتستیا که در ادبیات فن شناخته شده بوده و مورد استفاده محققین بسیاری قرار گرفته، اعمال شده است. با توجه به نتایج پیش‌بینی مدل، مدت زمان باقیمانده تا رسیدن این مشخصه‌ی ارتعاشی به یک آستانه‌ی معین ارائه شده است. همچنین اگر آستانه‌ی تعیین شده به معنی پایان عمر مفید باتاقان باشد، می‌توان از الگوریتم پیشنهاد شده به منظور تخمین عمر مفید باقیمانده نیز بهره جست. نحوه‌ی عملکرد الگوریتم در راستای این هدف نیز ارائه و ارزیابی شده است. نتایج حاکی از مطابقت خوب پیش‌بینی مدل با داده‌های تجربی است.

واژگان کلیدی: شبکه‌ی عصبی بازگشتی، شبکه‌ی عصبی حافظه‌ی طولانی

کوتاه‌مدت، پیش‌بینی عمر باتاقان غلتشی، پیش‌بینی ادامه‌ی سری زمانی، تست عمر پرشتاب باتاقان.

m\_behzad@Sharif.ir  
seyedalhosseinli@mech.sharif.edu  
arghand@znu.ac.ir  
banazadeh@sharif.edu

## ۱. مقدمه

پیش‌بینی‌ها معمولاً به دو روش عمده صورت می‌پذیرد: روش مبتنی بر مدل و روش داده‌محور.<sup>[۱]</sup>

در روش‌های مبتنی بر مدل، یک مدل ریاضی برای توصیف نحوه‌ی رشد عیوب یا فرایند زوال باتاقان ارائه می‌شود. توانمندی این مدل‌ها در نحوه‌ی توصیف پدیده‌ی زوال است؛ معمولاً این مدل‌های ریاضی نمی‌توانند عملکرد دقیقی را ارائه کنند. چرا که بسیاری از پارامترهای مؤثر در زوال باتاقان مانند حضور آلودگی، مونتاژ ناصحیح، نقایص هندسی و دیگر عوامل، معمولاً ناشناس هستند و مدل‌سازی آنها در عمل با چالش‌های جدی مواجه خواهد بود.<sup>[۲]</sup> در روش‌های آماری (که به عنوان زیرمجموعه‌ی روش‌های داده‌محور در نظر گرفته می‌شود) نیز با ارائه‌ی یک مدل سعی می‌شود الگوهای زوال باتاقان شناخته شود و پارامترهای آن که هر کدام دارای یک توزیع احتمال هستند از طریق مشاهدات و اندازه‌گیری‌ها به‌روزرسانی شوند. این رویکرد در زمینه‌ی پیش‌بینی عمر باتاقان‌ها بسیار مورد توجه است و می‌تواند عدم

از عیب‌یابی و پیش‌بینی عمر مفید باقیمانده می‌توان به‌عنوان یکی از کلیدی‌ترین مباحث فنی در نگهداری و تعمیرات (نت) مبتنی بر وضعیت اشاره کرد. در عیب‌یابی سعی می‌شود تا نوع و شدت عیب و حتی علت وقوع عیب شناسایی شود، در صورتی که در پیش‌بینی عمر سعی می‌شود مدت زمانی که به‌صورت ایمن می‌توان از یک قطعه یا ماشین (معمولاً در وضعیت معیوب) بهره‌برداری کرد تخمین زده شود.<sup>[۱]</sup> از آنجا که باتاقان‌های غلتشی جزو اجزای پرکاربرد و همچنین پایش‌پذیر در تجهیزات دوار هستند و ضمناً بخش عمده‌ی آمار از کار افتادگی تجهیزات دوار مربوط به خرابی باتاقان‌های غلتشی است، عیب‌یابی و تخمین عمر مفید باقیمانده‌ی این اجزا مورد توجه بسیاری از محققین بوده است.<sup>[۲]</sup> این

\* نویسنده مسئول

تاریخ: دریافت ۱۴۰۰/۰۶/۲۰، اصلاحیه ۱۴۰۰/۱۰/۰۴، پذیرش ۱۴۰۰/۱۰/۱۴.

DOI:10.24200/J40.2022.58619.1610

قطعیتهای مسئله‌ی پیش‌بینی عمر را نیز مدل‌سازی کند.<sup>[۴]</sup> علاوه بر این، با استفاده از روش‌های هوش مصنوعی از جمله شبکه‌ی عصبی (دسته‌ی دیگری از روش‌های داده‌محور)، با به کار بردن داده‌هایی که از گذشته‌ی یک باتاقان در دسترس است می‌توان الگوهای زوال را مدل‌سازی کرد و در این صورت نیازی به داشتن مدل‌های ریاضی نخواهد بود. این شبکه‌ها در ابتدا به آموزش توسط یک یا چند سری داده از ماشین‌های مشابه یا تاریخچه‌ی قبلی همان ماشین نیازمندند؛ پس از آموزش شبکه، از آن برای پیاده‌سازی روی باتاقان‌های مشابه استفاده می‌شود تا عمر باقیمانده‌شان پیش‌بینی شود.<sup>[۵]</sup>

در بین شبکه‌های عصبی رایج، شبکه‌ی عصبی پیشخور<sup>۱</sup> توسط بسیاری از محققان برای پیش‌بینی عمر مفید باقیمانده باتاقان‌های غلته‌ی به کار گرفته شده است.<sup>[۴]</sup> به منظور استفاده از این ابزار در ابتدا نیاز است تا یک سری مشخصه‌ی مناسب از سیگنال‌های تاریخچه‌ی ارتعاشی باتاقان‌ها استخراج شود. سپس یک عملیات نگاشت توسط شبکه‌ی عصبی از فضای مشخصه‌های ارتعاشی به فضای عمر مفید باقی مانده صورت می‌گیرد. نحوه‌ی معماری شبکه‌ی عصبی و تهیه‌ی مشخصه‌های ارتعاشی مناسب می‌تواند فضایی باز به منظور ارائه‌ی ایده‌های مختلف باشد. کدیرو همکاران<sup>[۶]</sup> با استفاده از مشخصه‌ی مقدار مؤثر<sup>۲</sup> و چولگی<sup>۳</sup> سیگنال‌های تاریخچه‌ی ارتعاشات به عنوان ورودی‌های شبکه‌ی عصبی پیشخور، روش داده‌محور پیش‌بینی عمر مفید باقی مانده‌ی باتاقان را روی یک سری داده‌ی آزمایشگاهی پیاده‌سازی کردند.

بهراد و همکاران<sup>[۵]</sup> به منظور تهیه‌ی مشخصه‌های ارتعاشی مناسب، مقدار مؤثر سیگنال ارتعاشی را در بازه‌های فرکانسی بالا و پایین تفکیک کرده و به عنوان ورودی شبکه‌ی عصبی پیش‌خور در نظر گرفتند؛ آنها نشان دادند که این کار موجب بهبود دقت نسبت به مدل‌های پیشین شده است.

ژیاچوان و همکاران<sup>[۷]</sup> نیز با ترکیب یک مسئله‌ی رگرسیون و شبکه‌ی عصبی، عمر مفید باقیمانده‌ی باتاقان‌ها را با دقت خوبی پیش‌بینی کردند. آن‌ها ابتدا مشخصه‌های ارتعاشی چولگی و مقدار مؤثر سیگنال را با یک رابطه‌ی ریاضی برازش کرده و سپس با استفاده از آن‌ها - به عنوان ورودی شبکه‌ی عصبی پیشخور - عمر باتاقان‌ها را تخمین زدند. پنگ و همکاران<sup>[۸]</sup> با انتقاد از ایرادهای شبکه‌های عصبی سنتی که با روش‌های رایج صرفاً به استخراج یک مشخصه می‌پردازند، با ترکیب یک شبکه‌ی عصبی عمیق پیچشی<sup>۴</sup> و یک شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت<sup>۵</sup> به دقت بهتری در پیش‌بینی عمر باقی مانده دست یافتند.

ژای و همکاران<sup>[۹]</sup> به منظور استفاده از شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت، مشخصه‌های زیادی را از سیگنال‌های ارتعاشی استخراج کردند و بهترین آن‌ها را که همبستگی بیشتری با زوال باتاقان داشت، به عنوان ورودی به شبکه دادند و در نهایت نسبت به دو مدل تخمین‌گر بردار پشتیبان<sup>۶</sup> و تقویت گرادیان آرام<sup>۷</sup> به دقت بهتری دست یافتند.

مائو و همکاران<sup>[۱۰]</sup> با کمک شبکه‌ی عصبی پیچشی مشخصه‌های عمیق را از سیگنال ارتعاشی خام استخراج کرده و به عنوان ورودی شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت استفاده کردند. در این مقاله، پیش‌بینی عمر فقط در مرحله‌ی نهایی زوال باتاقان که به زوال سریع<sup>۸</sup> مشهور است، پیاده‌سازی شده است.

در سال‌های اخیر، با توجه به عملکرد خوب شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت در امر پیش‌بینی داده‌ها و سری‌های زمانی، محققین حوزه‌های مختلف از این شبکه در زمینه‌های مختلفی استفاده می‌کنند که برخی از آن‌ها عبارت‌اند از: پیش‌بینی روند بیماری‌هایی مانند آنفلوآنزا،<sup>[۱۱]</sup> پیش‌بینی روند قیمت در بازارهای مالی<sup>[۱۲]</sup> و پیش‌بینی روند تولید چاه‌های نفت.<sup>[۱۳]</sup>

در اکثر مقاله‌های محققین در زمینه‌ی پیش‌بینی عمر مفید باقیمانده‌ی باتاقان، از فضای مشخصه‌های مناسب ارتعاشی به فضای عمر باقیمانده یک نگاشت صورت گرفته است. اما در کنار مطالعاتی که برای پیش‌بینی عمر مفید باتاقان‌های غلته‌ی انجام شده است، برخی از محققین نیز به پیش‌بینی روند رشد مشخصه‌ی ارتعاشی (به عنوان معیاری برای زوال) پرداخته‌اند. در این حالت دیگر نگاشتی توسط شبکه‌ی عصبی صورت نمی‌گیرد، بلکه در ادامه‌ی روند یک مشخصه‌ی ارتعاشی پیش‌بینی می‌شود و با این پیش‌بینی، مدت زمان باقیمانده تا رسیدن به آستانه‌ی از پیش تعیین شده محاسبه می‌شود. این آستانه می‌تواند معیاری برای پایان عمر نیز باشد که در این صورت عمر مفید باقیمانده پیش‌بینی خواهد شد.

روبن و امبا به کمک نوعی از فیلتر کالمن<sup>۹</sup> مدلی را برای دستیابی به هدف یاد شده پیاده‌سازی کردند.<sup>[۱۴]</sup> اما استفاده از شبکه‌ی عصبی بازگشتی در این زمینه محدود بوده است.


در این مقاله از شبکه‌ی عصبی بازگشتی حافظه‌ی طولانی کوتاه‌مدت که یکی از توانمندترین شبکه‌ها در مدل‌سازی رفتارهای غیرخطی است، استفاده می‌شود تا الگوهای پیچیده‌ی که در فرایند زوال باتاقان وجود دارد تا حد ممکن شبیه‌سازی شود. این شبکه جزو شبکه‌های عصبی عمیق<sup>۱۰</sup> دسته‌بندی می‌شود و نقطه‌ی قوت آن، برخورداری از یک قوه‌ی حافظه است که در یادگیری پدیده‌های دینامیکی می‌تواند توانمندی بیشتری از خود نشان دهد؛ در واقع از داده‌های گذشته برای تحلیل داده‌های فعلی نیز کمک می‌گیرد که این امری مهم در پیش‌بینی عمر باتاقان‌هاست.<sup>[۱۵]</sup> همچنین بر اساس کارهای محققین پیشین<sup>[۱۶، ۱۷]</sup> مشخصه‌ی دامنه‌ی بیشینه‌ی سیگنال شتاب ارتعاشات به عنوان مشخصه‌ی ارتعاشی مناسب توصیف‌کننده‌ی زوال باتاقان انتخاب می‌شود و این مشخصه‌ی ارتعاشی به یک سری زمانی پایدار<sup>۱۱</sup> تبدیل می‌شود. سپس آینده‌ی این سری زمانی توسط شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت پیش‌بینی می‌شود؛ با این پیش‌بینی‌ها مدت زمان رسیدن به آستانه‌ی معین نیز محاسبه می‌شود.

## ۲. انتخاب و آماده‌سازی مشخصه‌ی ارتعاشی


از سیگنال‌های زمانی یا طیف فرکانسی<sup>۱۲</sup> شتاب باتاقان می‌توان مشخصه‌های ارتعاشی متفاوتی را محاسبه کرد که این مشخصه‌ها به طور عمده مرتبط با انرژی سیگنال هستند.<sup>[۱۸]</sup> از میان این مشخصه‌ها، مشخصه‌ی مناسب است که بهترین توصیف‌گر زوال باتاقان باشد.

بهراد و همکاران<sup>[۱۸]</sup> نشان دادند که مشخصه‌ی دامنه‌ی بیشینه‌ی سیگنال شتاب ارتعاشات یا پیک<sup>۱۳</sup> در پیش‌بینی عمر روی داده‌های آزمایشگاهی و صنعتی بهترین همبستگی را با اندازه‌ی عیب و زوال باتاقان دارد. بنابراین در نوشتار حاضر نیز از همین مشخصه‌ی ارتعاشی برای توصیف فرایند زوال باتاقان غلته‌ی استفاده خواهد شد.


روش ارائه شده برای پیش‌بینی عمر در این نوشتار، روشی وابسته به روند رشد مشخصه‌ی زوال است و این موضوع می‌طلبد که بخشی از فرایند زوال باتاقان دارای افزایش تدریجی باشد؛ در غیر این صورت خطای پیش‌بینی ممکن است افزایش یابد. الگوریتم پیشنهادی با هر بار مشاهده یا اندازه‌گیری جدید، پیش‌بینی جدیدی از وضعیت رشد آینده‌ی روند مشخصه‌ی زوال ارائه خواهد کرد. به طور کلی، فرایند زوال باتاقان را می‌توان به سه بخش تقسیم کرد: بخش عادی و سالم، بخش شکل‌گیری و رشد آهسته‌ی عیب، بخش رشد سریع




نمودار ۱. نمودار ستونی مشخصه‌ی پیک ارتعاشات یاتاقان شماره ۱، آزمایش پرونوستیا.



نمودار ۲. نمودار ستونی مشخصه‌ی پیک ارتعاشات یاتاقان شماره ۳، آزمایش پرونوستیا.



نمودار ۳. نمودار ستونی مشخصه‌ی پیک ارتعاشات یاتاقان شماره ۴، آزمایش پرونوستیا.



شکل ۱. معماری سلول شبکه‌ی عصبی حافظه‌ی طولانی مدت.

عیب و از کار افتادگی یاتاقان.<sup>[۲۰]</sup> در بعضی مطالعات نیز این سه بخش را به ترتیب، بخش کارکرد عادی، بخش زوال آهسته<sup>۱۴</sup> و بخش زوال سخت<sup>۱۵</sup> نامیده‌اند.<sup>[۵]</sup>

معمولاً یاتاقان در مرحله‌ی شکل‌گیری و رشد عیوب، دارای یک روند نرم و آهسته در رشد مشخصه‌های ارتعاشی به‌خصوص پیک و مقدار مؤثر سیگنال ارتعاشات است. در این مرحله از زوال، می‌توان تکنیک معرفی شده در این مقاله را پیاده‌سازی کرد. ضمن این‌که برای کاهش نویز و نوسانات، نمودار مشخصه‌ی ارتعاشی پیک با روش میانگین متحرک<sup>۱۶</sup> فیلتر می‌شود و ادامه‌ی تحلیل‌ها روی نمودار فیلتر شده صورت می‌گیرد.

اما از آن‌جا که این مشخصه‌ی ارتعاشی به‌عنوان یک سری زمانی ناپایدار است، چرا که روند زوال همیشه به‌صورت اکیداً صعودی است و میانگین و انحراف معیار این سری زمانی با گذر زمان تغییر می‌کند. بنابراین بهتر است ابتدا تبدیل به یک سری زمانی پایدار شود زیرا سری‌های زمانی پایدار قابلیت بهتری در پیش‌بینی با استفاده از شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت دارند. سپس این سری زمانی پایدار وارد مرحله‌ی پیش‌بینی خواهد شد.

به منظور تبدیل این مشخصه‌ها به یک سری زمانی پایدار، باید به نحوه‌ی توزیع داده‌های مشخصه‌ی پیک توجه کرد. در نمودار ۱ تا ۳، نمودار ستونی<sup>۱۷</sup> مشخصه‌ی پیک دو نمونه یاتاقان از آزمایش عمر پرشتاب پرونوستیا<sup>۱۸</sup> (که در پژوهش حاضر استفاده خواهد شد) آورده شده است. چنان‌که مشاهده می‌شود، این نوع توزیع داده مربوط به توزیع نرمال لگاریتمی<sup>۱۹</sup> است.

چنین سری‌های زمانی، ابتدا باید توسط رابطه‌ی ۱ به فضای نیمه‌لگاریتم منتقل شوند و سپس برای پایدار شدن لازم است یک مرتبه مشتق‌گیری انجام شود. به این ترتیب یک سری زمانی پایدار به دست خواهد آمد که توزیع داده‌های آن به‌صورت نرمال خواهد بود و مشخصه‌های آماری آن مانند میانگین و انحراف معیار نسبت به زمان ثابت است.<sup>[۲۰،۲۱]</sup>


$$P_S = \log(P_{i+1}) - \log(P_i) \quad (1)$$

که در آن  $P$  مقدار مشخصه‌ی ارتعاشی پیک و  $P_S$  سری زمانی پایدار شده‌ی پیک است.


### ۳. معرفی شبکه‌ی عصبی

در شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت، صراحتاً یک واحد حافظه تعریف می‌شود که داده‌های گذشته‌ی دور را نیز می‌تواند در خود جای دهد. این امر موجب می‌شود که دینامیک سیستم به نحو بهتری شناسایی شود. در شکل ۱ جزئیات یکی از سلول‌های این نوع شبکه‌ی عصبی آورده شده است. هر سلول از این شبکه دارای ۳ ورودی است که شامل ورودی فعلی  $x_t$ ، ورودی از سلول قبل  $h_{t-1}$  و ورودی از حافظه‌ی سلول قبل  $c_{t-1}$  (مهم‌ترین بخش این شبکه) است. خروجی‌ها نیز دو بخش دارد:  $h_t$  و  $c_t$ . بنابراین خروجی نهایی در این سلول با توجه به ورودی‌هایی که دارد می‌تواند از گذشته نیز تأثیر پذیرد.


مهم‌ترین ویژگی این شبکه داشتن یک خط حافظه است که از میان همه‌ی سلول‌ها گذر می‌کند. دروازه‌های مختلفی هم در این سلول وجود دارد که هرکدام عهده‌دار وظیفه‌ی است. اولین دروازه مربوط به فراموشی داده‌های گذشته است و تعیین می‌کند که چه مقدار از داده‌های قبلی باید فراموش شود. دروازه بعدی مربوط



شکل ۲. نمایی از دستگاه تست در آزمایش پرونوستیا. [۲۳]



نمودار ۴. نمودار روند تغییرات مشخصه ارتعاشی پیک در طول عمر یاتاقان ۱ پرونوستیا.



نمودار ۵. نمودار روند تغییرات مشخصه ارتعاشی پیک در طول عمر یاتاقان ۳ پرونوستیا.

از میان داده‌های آزمایش پرونوستیا، یاتاقان شماره‌ی ۱، ۳ و ۴ از شرایط کاری اول (سرعت ۱۸۰۰ دور بر دقیقه و بار شعاعی ۴۰۰۰ کیلو نیوتن)، شامل شروط گفته شده در بخش ۲ می‌شوند و فرایند زوال آن‌ها از دو یا سه مرحله تشکیل شده است و مرحله‌ی شکل‌گیری و رشد عیوب دارای یک روند آهسته است. روند تغییرات مشخصه‌ی پیک ارتعاشات یاتاقان‌های ۱، ۳ و ۴ در مدت عمر آن‌ها به ترتیب در نمودار ۴، ۵ و ۶ نشان داده شده است.

به به‌روزرسانی خط حافظه است. در این حین مقدار  $c_{t-1}$  با  $c_t$  تعویض می‌شود. هم‌زمان، در طرف دیگری از سلول مقدار  $h_{t-1}$  که از سلول قبلی آورده شده است با کمک خط حافظه‌ی به‌روزرسانی شده به مقدار  $h_t$  تبدیل می‌شود. در روابط ۲ و ۳، روابط حاکم بر پارامترهای یک سلول شبکه‌ی عصبی حافظه‌ی طولانی مدت آورده شده است.

$$c_t = \sigma(X_t.U_f + h_{t-1}.W_f).c_{t-1} + \sigma(X_t.U_i + h_{t-1}.W_i).tanh(X_t.U_c + h_{t-1}.W_c) \quad (2)$$

$$h_t = \sigma(X_t.U_o + h_{t-1}.W_o).tanh(c_t) \quad (3)$$


در این روابط مقادیر  $U$  و  $W$  وزن‌هایی هستند که در مرحله‌ی آموزش مقداردهی شده‌اند و نماد  $\sigma$  مربوط به تابع فعال‌سازی سیگموئید<sup>۲۰</sup> است. پس از این که محاسبات در درون سلول‌ها پایان یافت، خروجی  $h_t$  وارد یک لایه‌ی کاملاً متصل<sup>۲۱</sup> می‌شود و در انتها خروجی نهایی محاسبه خواهد شد. برای طراحی و آموزش شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت، از نرم‌افزار متلب<sup>۲۲</sup> استفاده شده است.

در این نوع کاربرد از شبکه، داده‌یی به منظور اعتبارسنجی<sup>۲۳</sup> نخواهیم داشت زیرا داده‌های آموزش دارای ترتیب زمانی هستند و به هیچ عنوان نباید از میان آن‌ها داده‌یی به منظور اعتبارسنجی خارج شود؛ چون این کار باعث به هم ریخته شدن ترتیب زمانی بین داده‌های آموزش و همچنین بین داده‌های اعتبارسنجی می‌شود.


#### ۴. معرفی داده‌های تجربی

داده‌هایی که در این مقاله استفاده می‌شود، مربوط به آزمایش پرونوستیاست که نخستین بار در قالب یک مسابقه در سال ۲۰۱۲ منتشر شد<sup>[۴]</sup> و پس از آن به‌صورت آزاد در اختیار محققین قرار گرفت. در این مجموعه، آزمون عمر پرشتاب روی ۱۷ یاتاقان مشابه در سه شرط کاری متفاوت از لحاظ سرعت و بار انجام شده است. تصویری از چیدمان آزمایش مورد نظر در شکل ۲ نشان داده شده است.<sup>[۲۳]</sup>


ارتعاشات یاتاقان مورد آزمایش در این مجموعه در دو راستای افقی و عمودی توسط دو حسگر شتاب‌سنج از ابتدا تا انتهای عمر ثبت شده است. نرخ نمونه‌برداری این حسگرها برابر با ۲۵/۶ کیلوهرتز است و هر ۱۰ ثانیه یک‌بار، نمونه‌یی به طول ۸/۱ ثانیه ثبت شده است.




نمودار ۷. نمودار پیک یاتاقان ۱ پس از پایدار شدن.




نمودار ۸. نمودار پیک یاتاقان ۳ پس از پایدار شدن.



نمودار ۹. نمودار پیک یاتاقان ۴ پس از پایدار شدن.



نمودار ۱۰. نمودار ستونی داده‌های پیک پایدار شده یاتاقان ۱.



نمودار ۶. نمودار روند تغییرات مشخصه‌ی ارتعاشی پیک در طول عمر یاتاقان ۴ پرونوستیا.

جدول ۱. پارامترهای مهم در طراحی شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت.

|                                    |                            |
|------------------------------------|----------------------------|
| ۸۰                                 | تعداد واحدهای پنهان        |
| ۱                                  | تعداد لایه‌های کاملاً متصل |
| سری زمانی پایدار شده در زمان t     | ورودی                      |
| سری زمانی پایدار شده در زمان t + ۱ | خروجی                      |
| Adam                               | الگوریتم آموزش شبکه        |
| ۰/۰۱۵                              | نرخ یادگیری                |
| RMSE                               | تابع هزینه                 |

## ۵. نتایج پیش‌بینی روند

### ۱.۵. طراحی شبکه‌ی عصبی



ابتدا معماری شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت صورت می‌گیرد که جزئیات آن در جدول ۱ ارائه شده است. چون قرار است دینامیک و روند مشخصه‌ی پیک توسط شبکه یاد گرفته شود، باید در معماری شبکه، قوه‌ی حافظه را قدرتمند طراحی کرد. به این منظور در جدول ۱ تعداد واحدهای پنهان موجود در شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت باید بسیار بیشتر از تعداد لایه‌های کاملاً متصل باشد.

### ۲.۵. آماده‌سازی داده‌ها

در ابتدا مشخصه‌ی پیک یاتاقان ۱، ۳ و ۴ از شرایط کاری اول آزمون پرونوستیا که نمودار مشخصه‌ی پیک آن‌ها در نمودارهای ۴ تا ۶ آورده شد، توسط رابطه‌ی ۱ تبدیل به یک سری زمانی پایدار می‌شود. در نمودارهای ۷ تا ۹ داده‌های پایدار شده آورده شده است. توزیع داده‌های پیک ارتعاشات این دو یاتاقان قبل از پایدار شدن در نمودارهای ۱ تا ۳ آورده شده است. اما چنان‌که از نمودارهای ۱۰ تا ۱۲ مشخص است، توزیع داده‌ها پس از پایدار شدن نرمال هم شده است.



چنان‌که در بخش ۲ اشاره شد، مرحله شکل‌گیری و رشد عیوب، دارای روند رشد آهسته بوده و پیش‌بینی‌ها فقط در همین مرحله صورت خواهد گرفت. بنابراین از داده‌های پایدار شده، فقط بخشی که متناظر با این مراحل است جدا می‌شود و پیش‌بینی روی آن‌ها صورت می‌گیرد. سپس پیش‌بینی‌های صورت گرفته، باید توسط رابطه‌ی ۴ به فضای قبل از پایدار شدن بازگردد.

$$P_{i+1} = P_i \times 10^{P_S} \quad (4)$$




نمودار ۱۱. نمودار ستونی داده‌های پیک پایدار شده یاتاقان ۳.

نمودار ۱۳. پیش‌بینی ادامه‌ی سری زمانی پایدار یاتاقان ۱.



نمودار ۱۲. نمودار ستونی داده‌های پیک پایدار شده یاتاقان ۴.

نمودار ۱۴. پیش‌بینی ادامه‌ی سری زمانی پایدار یاتاقان ۳.

 $P_S$  مقدار پیش‌بینی شده‌ی سری زمانی پیک در فضای پایدار است.

### ۳.۵. پیش‌بینی عمر

برای شروع پیش‌بینی، تقریباً سه‌چهارم ابتدایی از مرحله‌ی دوم زوال یاتاقان به‌عنوان داده‌های آموزش در نظر گرفته می‌شود و سپس یک‌چهارم انتهایی مرحله‌ی دوم زوال پیش‌بینی و با مقادیر واقعی آن مقایسه می‌شود. در انتخاب این که چه تناسبی از داده‌ها به‌عنوان آموزش و آزمایش قرار بگیرد، مهم این است که شبکه بتواند الگوی زوال یاتاقان را از داده‌های آموزش فراگیرد، طبیعتاً اگر بتوان با داده‌های کم‌تری به این هدف رسید، پیش‌بینی‌ها در بازه وسیع‌تری صورت خواهد گرفت و این یک نکته‌ی مثبت است؛ در غیر این صورت خطاها افزایش می‌یابند. این موضوع از یک یاتاقان به یاتاقان دیگر متفاوت است. با این حال در نوشتار حاضر با حفظ وسعت بازه پیش‌بینی، دقت پیش‌بینی‌ها نیز حفظ شده است.


پیش‌بینی‌های صورت گرفته توسط شبکه در نمودارهای ۱۳ تا ۱۵ آورده شده است. وضوح ظاهری این پیش‌بینی‌ها هنگامی بهتر خواهد شد که مشخصه‌ی پیک مورد نظر به فضای اصلی و ناپایدار بازگردانده شود.

نکته‌ی که در پیش‌بینی‌ها وجود دارد این است که این پیش‌بینی‌ها می‌توانند با به دست آمدن مشاهدات یا اندازه‌گیری‌های جدید، به‌روزرسانی شوند. به این صورت که هر مشاهده‌ی جدید می‌تواند به‌عنوان ورودی به شبکه داده شود و سپس ادامه‌ی


نمودار ۱۵. پیش‌بینی ادامه‌ی سری زمانی پایدار یاتاقان ۴.

روند از شبکه خواسته شود. به عبارت دیگر، به ازای هر مشاهده یک پیش‌بینی جدید برای روند وجود خواهد داشت.

داده‌های آموزش در نمودارهای ۱۳ تا ۱۵ به‌طور کامل نمایش داده نشده است. بنابراین در این نمودارها، علاوه بر روند قرمز رنگ، روندهای دیگری هم به‌عنوان  $\Pi$  امنین




نمودار ۱۹. زمان باقیمانده رسیدن به آستانه‌ی ۱۰ متر بر مجذور ثانیه در یاتاقان ۱.




نمودار ۲۰. زمان باقیمانده رسیدن به آستانه‌ی ۱۴ متر بر مجذور ثانیه در یاتاقان ۳.

به یک آستانه معین می‌رسد. این آستانه می‌تواند معیاری بر پایان عمر نیز باشد ولی به طور کل ساز و کار پیشنهاد شده در این مقاله این امکان را فراهم می‌کند که زمان باقیمانده تا رسیدن به هر آستانه‌ی دلخواهی را بتوان تعیین کرد. اگر این آستانه معیاری برای پایان عمر باشد، پیش‌بینی مورد نظر به معنای پیش‌بینی عمر مفید باقی مانده خواهد بود. استانداردهای مختلفی در زمینه‌ی پایش وضعیت وجود دارد که معمولاً به وسیله‌ی آن‌ها این آستانه‌ها را برای مشخصه‌ی پیک یا مقدار مؤثر سیگنال تعیین می‌کنند.


در نمودار ۱۹ پیش‌بینی شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت از مدت زمان باقیمانده تا رسیدن مشخصه‌ی پیک شتاب یاتاقان ۱ به آستانه‌ی ۱۰ متر بر مجذور ثانیه آورده شده است. این آستانه صرفاً یک مثال از توانمندی سازوکار پیشنهاد شده در این مقاله است که لزوماً معیاری بر پایان عمر نیست. همچنین در نمودار ۲۰ نیز مدت زمان رسیدن مشخصه‌ی پیک شتاب یاتاقان ۳ به آستانه‌ی ۱۴ متر بر مجذور ثانیه آورده شده است و در نمودار ۲۱ نیز مدت زمان باقی مانده برای یاتاقان ۴ تا رسیدن مشخصه‌ی پیک به ۴۲ متر بر مجذور ثانیه پیش‌بینی شده است. همانطور که مشخص است با نزدیک شدن به انتهای زمان باقیمانده، دقت پیش‌بینی شبکه افزایش می‌یابد و این بدان معناست که روندهای پیش‌بینی شده قابلیت پیش‌بینی بهتری از آینده نزدیک خود دارند و در پیش‌بینی‌های بلندمدت توانایی آن‌ها کاهش می‌یابد.



نمودار ۱۶. پیش‌بینی‌های انجام شده روی روند پیک یاتاقان ۱.




نمودار ۱۷. پیش‌بینی‌های انجام شده روی روند پیک یاتاقان ۳.



نمودار ۱۸. پیش‌بینی‌های انجام شده روی روند پیک یاتاقان ۴.

پیش‌بینی وجود خواهد داشت که برای اجتناب از آشفته شدن نمودارها آورده نشده است. اما در نمودارهای ۱۶ تا ۱۸، تعدادی از پیش‌بینی‌ها با کمک رابطه‌ی ۴ به فضای اصلی بازگردانده شده است.

پس از پیش‌بینی روند به ازای هر نقطه، نوبت به پیش‌بینی زمان رسیدن روندها



نمودار ۲۱. زمان باقیمانده رسیدن به آستانه‌ی ۴۲ متر بر مجذور ثانیه در یاتاقان ۴.

جدول ۲. محاسبه‌ی خطای پیش‌بینی‌ها از طریق رابطه‌ی ۵ و ۶.

| یاتاقان ۱    | یاتاقان ۳ | یاتاقان ۴ |
|--------------|-----------|-----------|
| ۲۱/۷         | ۱۴/۳      | ۹/۳       |
| خطای کلی (%) |           |           |

از میان روندهایی که در نمودارهای ۱۶ تا ۱۸ وجود دارد، تعدادی از آنها ممکن است هرگز به آستانه‌ی تعیین شده نرسند و در این حالت مقدار زمان باقیمانده پیش‌بینی شده در روند مورد نظر برابر بی‌نهایت است. با توجه به این که فرایند زوال یاتاقان معمولاً به سمت بدتر شدن پیش می‌رود (در صورت عدم دخالت انسان مانند گریس‌کاری) و عمر باقی مانده بی‌نهایت معنای حقیقی ندارد، پس این روندهای پیش‌بینی شده خطای محض است و حذف خواهند شد. به همین دلیل است که نقاط سیاه رنگ در نمودارهای ۱۹ تا ۲۱ پیوسته نیستند زیرا تعدادی از پیش‌بینی‌ها حذف شده است.

در جدول ۲ دقت پیش‌بینی‌ها با کمک روندهای پیش‌بینی شده در نمودارهای ۱۶ تا ۱۸ توسط رابطه‌ی ۵ و ۶ آورده شده است:

$$Error_n = \frac{\sum_{i=1}^{N_n} \left| \frac{PR_i - P_i}{P_i} \right|}{N_n} \quad (5)$$

$i$  شمارنده‌ی نقطه‌ی حاضر در  $n$ امین روند پیش‌بینی شده است و  $N_n$  تعداد کل داده‌های پیش‌بینی شده در  $n$ امین روند است و  $PR_i$  و  $P_i$  به ترتیب نمادی از مقدار پیش‌بینی شده پیک و مقدار واقعی پیک در آن روند هستند. سپس برای مشخص شدن خطای کلی در پیش‌بینی‌ها از رابطه‌ی ۶ استفاده شده است.

$$Error_{Overall} = \frac{\sum_{i=1}^{N_{total}} Error_n}{N_{total}} \quad (6)$$

که در این رابطه منظور از  $N_{total}$  تعداد روندهای پیش‌بینی شده قابل قبول در هر یاتاقان است. در نمودارهای ۱۶ تا ۱۸ تعداد روندهای پیش‌بینی شده قابل قبول (پس از حذف روندهای باطل) به ترتیب برابر ۶۴، ۴۲ و ۱۲ عدد است.

## ۶. نتیجه‌گیری

در این مقاله سازوکاری معرفی شد تا با استفاده از آن بتوان به پیش‌بینی خوبی از عمر مفید باقیمانده‌ی یاتاقان یا زمان رسیدن به یک آستانه‌ی معین رسید. نتایج خوب این سازوکار نشان‌دهنده‌ی قدرت شبکه‌ی عصبی حافظه‌ی طولانی کوتاه‌مدت در پیش‌بینی سری‌های زمانی است که در صورت پایدار بودن این سری‌های زمانی نتایج بسیار مطلوب‌تر خواهد بود. در این مقاله روش مناسبی به منظور تبدیل مشخصه‌های ارتعاشی مانند پیک سیگنال شتاب ارتعاشات به یک سری زمانی پایدار نیز معرفی شد.

سازوکار پیشنهادی در یاتاقان‌هایی که روند زوال‌شان آهسته است، بسیار کارآمد خواهد بود و قابلیت انعطاف خوبی در پیش‌بینی مدت زمان رسیدن به آستانه‌ی دلخواه دارد؛ این آستانه می‌تواند معیاری بر پایان عمر نیز باشد و معمولاً برگرفته از تجربه با استانداردهای موجود است.

یکی از مزایای قابل توجه این روش، عدم نیاز آن به داده‌های دیگر یاتاقان‌ها برای آموزش است. زیرا شبکه فقط بر اساس داده‌های گذشته‌ی یک یاتاقان آموزش داده می‌شود و ادامه‌ی روند همان یاتاقان را پیش‌بینی می‌کند. با این حال این امکان وجود دارد که از تمام عمر یک یاتاقان برای آموزش استفاده کرد و روی یاتاقان‌های دیگر پیاده کرد، اما از آن‌جا که یاتاقان‌ها ممکن است الگوهای زوال متفاوتی داشته باشند ممکن است در این حالت خطاها افزایش یابند.

## پانوشته‌ها

1. feed forward neural network
2. root mean square (RMS)
3. kurtosis
4. convolutional neural network
5. long short-term memory (LSTM)
6. support vector regression (SVR)
7. light gradient boosting machine (LGBM)
8. fast degradation
9. kalman filter
10. deep neural network
11. stationary

12. spectrum
13. peak
14. slow degradation
15. hard degradation
16. moving average
17. histogram
18. PRONOSTIA
19. log-normal distribution
20. sigmoid
21. fully connected layer
22. MATLAB
23. validation



## منابع (References)

- Jardine, A., Lin, D. and Banjevic, D. "A review on machinery diagnostics and prognostics implementing condition-based maintenance", *Mechanical Systems and Signal Processing*, **20**(7), pp. 1483-1510 (2006).
- Singleton, R., Strangas, E. and Aviyente, S. "Extended kalman filtering for remaining-useful-life estimation of bearings", *IEEE Transactions on Industrial Electronics*, **62**(3), pp. 1781-1790 (2015).
- Lei, Y., Li, N., Guo, L. and et al. "Machinery health prognostics: a systematic review from data acquisition to RUL prediction", *Mechanical Systems and Signal Processing*, **104**, pp. 799-834 (2018).
- Cubillo, A., Perinpanayagam, S. and Esperon-Miguez, M. "A review of physics-based models in prognostics: application to gears and bearings of rotating machinery", *Advances in Mechanical Engineering*, **8**(8), p. 168781401666466 (2016).
- Behzad, M., Arghand, H. and Rohani Bastami, A. "Remaining useful life prediction of ball-bearings based on high-frequency vibration features", *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, **232** (18), pp. 3224-3234 (2017).
- Mahamad, A., Saon, S. and Hiyama, T. "Predicting remaining useful life of rotating machinery based artificial neural network", *Computers & Mathematics With Applications*, **60**(4), pp. 1078-1087 (2010).
- Li, X., Elasha, F., Shanbr, S. and et al. "Remaining useful life prediction of rolling element bearings using supervised machine learning", *Energies*, **12**(14), p. 2705 (2019).
- Peng, C., Chen, Y., Chen, Q. and et al. "A Remaining useful life prognosis of turbofan engine using temporal and spatial feature fusion", *Sensors*, **21**(2), p. 418 (2021).
- Zhai, Y., Deng, A., Li, J. and et al. "Remaining useful life prediction of rolling bearings based on recurrent neural network", *Journal on Artificial Intelligence*, **1**(1), pp. 19-27 (2019).
- Mao, W., He, J., Tang, J. and et al. "Predicting remaining useful life of rolling bearings based on deep feature representation and long short-term memory neural network", *Advances in Mechanical Engineering*, **10**(12), p. 168781401881718 (2018).
- Yang, C., Chen, Y., Chan, Y. and et al. "Influenza-like illness prediction using a long short-term memory deep learning model with multiple open data sources", *The Journal of Supercomputing*, **76**(12), pp. 9303-9329 (2020).
- Yıldırım, D., Toroslu, I. and Fiore, U. "Forecasting directional movement of forex data using LSTM with technical and macroeconomic indicators", *Financial Innovation*, **7**(1) (2021).
- Song, X., Liu, Y., Xue, L. and et al. "Time-series well performance prediction based on long short-term memory (LSTM) neural network model", *Journal of Petroleum Science and Engineering*, **186**, p. 106682 (2020).
- Reuben, L. and Mba, D. "Diagnostics and prognostics using switching Kalman filters", *Structural Health Monitoring*, **13**(3), pp. 296-306 (2014).
- Heimes, F. "Recurrent neural networks for remaining useful life estimation", *International Conference on Prognostics and Health Management* (2008).
- Zhai, Y., Deng, A., Li, J. and et al. "Remaining useful life prediction of rolling bearings based on recurrent neural network", *Journal on Artificial Intelligence*, **1** (1), pp. 19-27 (2019).
- Kulkarni, S. and Wadkar, S. "Experimental investigation for distributed defects in ball bearing using vibration signature analysis", *Procedia Engineering*, **144**, pp. 781-789 (2016).
- Behzad, M., Feizhoseini, S., Arghand, H. and et al. "Failure threshold determination of rolling element bearings using vibration fluctuation and failure modes", *Applied Sciences*, **11**(1), p. 160 (2020).
- Hamadache, M., Jung, J., Park, J. and et al. "A comprehensive review of artificial intelligence-based approaches for rolling element bearing PHM: shallow and deep learning", *JMST Advances*, **1**(1-2), pp. 125-151 (2019).
- Medjaher, K., Tobon-Mejia, D. and Zerhouni, N. "Remaining useful life estimation of critical components with application to bearings", *IEEE Transactions on Reliability*, *Institute of Electrical and Electronics Engineers*, **61**(2), pp. 292-302 10.1109/TR.2012.2194175. hal-00737596 (2012).
- Feng, C., Wang, H., Lu, N. and et al. "Log-transformation and its implications for data analysis", *Shanghai Arch. Psychiatry*, **26**(2), pp.105-109 (2014). DOI: 10.3969/j.issn.1002-0829.2014.02.
- Jebb, A.T., Tay, L. Wang, W. and et al. "Time series analysis for psychological research: examining and forecasting change", *Front Psychol*, **6**:727 (2015). DOI: 10.3389/fpsyg.2015.00727.
- Nectoux, P., Gouriveau, R., Medjaher, K. and et al. "PRONOSTIA: an experimental platform for bearings accelerated degradation tests", *In: IEEE International Conference on Prognostics and Health Management*, PHM 12, Denver, CO, USA. IEEE Catalog Number: CPF12PHM-CDR (June 2012).