

طراحی و ساخت سنسور ارتعاش و پیاده‌سازی یک سیستم پایش وضعیت و تشخیص عیب هوشمند با استفاده از یادگیری عمیق

مجید هادی^{۱*}، امیرحسین نخعی^۲، سجاد عباسی^۳ و سیداحسان فاطمی^۴

۱- مدیر داخلی‌سازی، شرکت کویرتایر

۲- کارشناس برق و الکترونیک، شرکت کویرتایر

۳- کارشناس داخلی‌سازی، شرکت کویرتایر

۴- کارشناس مکانیک، شرکت کویرتایر

m.hadi@kavirtire.ir

چکیده: پایش وضعیت تجهیزات دوار از طریق تحلیل ارتعاشات، یک استراتژی کلیدی در نگهداری و تعمیرات پیش‌بینانه است. این مقاله یک رویکرد جامع و دومرحله‌ای برای پیاده‌سازی یک سیستم پایش وضعیت و تشخیص عیب هوشمند با استفاده از سنسورهای شتاب‌سنج MEMS را تشریح می‌کند. در مرحله اول، یک روش جدید در راستای طراحی و ساخت یک ارتعاش‌سنج کارآمد و کم‌هزینه با استفاده از شتاب‌سنج‌های MEMS با غلبه بر تمامی چالش‌های طراحی نظیر بایاس (یا دررفت)، نویز فرکانس بالا و تداخل ناشی از مؤلفه گرانش به‌دلیل تغییرات زاویه‌ای پیشنهاد شده است. این رویکرد یک سیگنال ارتعاشی قابل‌اعتماد و مطابق با استانداردهای صنعتی و قابلیت ارسال داده به‌صورت بلادرنگ تولید می‌کند که می‌تواند برای ارزیابی سلامت ماشین‌آلات به‌کار رود. مرحله دوم، با کمک داده‌های سنسور طراحی شده، یک رویکرد یادگیری عمیق بدون ناظر برای تشخیص خودکار و هوشمند ناهنجاری و عیب تجهیزات دوار به‌کار گرفته می‌شود. در این مرحله، یک شبکه اتوانکودر کانولوشنی بر روی داده‌های حالت نرمال تجهیزات دوار آموزش داده می‌شود. این مدل با یادگیری الگوهای پیچیده رفتار سالم، قادر است هرگونه انحراف از آن را با خطای بازسازی بالا شناسایی کند. افزون‌بر این، با تحلیل خطای بازسازی، سیستم قابلیت مکان‌یابی اولیه عیب را نیز فراهم می‌آورد.

واژه‌های کلیدی: پایش وضعیت، نگهداری و تعمیرات پیش‌بینانه، شتاب‌سنج MEMS، یادگیری عمیق، شبکه اتوانکودر کانولوشنی

مقدمه

هوشمند با استفاده از سنسورهای شتاب‌سنج MEMS پیشنهاد شده است. در مرحله اول، طراحی و ساخت یک سنسور ارتعاش صنعتی چندمحوره استاندارد پیشنهاد شده است. در مرحله دوم، داده‌های ارتعاش به‌عنوان ورودی به یک اتوانکودر کانولوشنی بدون ناظر وارد می‌شود. این مدل، اثر انگشت ارتعاشی رفتار نرمال ماشین را می‌آموزد و از آن برای تشخیص ناهنجاری‌ها (رفتار غیرنرمال) و مکان‌یابی عیوب (ابتدا و انتهای موتور) به‌صورت بلادرنگ استفاده می‌کند.

ادبیات فنی در حوزه پایش ارتعاش با استفاده از سنسورهای MEMS و تکنیک‌های پردازش سیگنال و یادگیری ماشین، تحقیقات زیادی را در برمی‌گیرد. در [۳]، یک سیستم پایش ارتعاش کم‌هزینه مبتنی بر آردوینو و شتاب‌سنج MEMS و با کمک تحلیل تبدیل فوری برای موتورهای القایی پیشنهاد شده است. این سیستم اما به مشکل تداخل گرانشی و اثرات تغییرات زاویه‌ای سنسور توجه ندارد. در [۴]، بر اهمیت کالیبراسیون دقیق و استفاده از فیلتر پایین‌گذر را برای کاهش نویز سیگنال شتاب‌سنج تأکید شده است. با این حال، راهکار جامعی برای جداسازی شتاب‌های ارتعاشی از شتاب گرانش و همچنین دریافت سنسور شتاب ارائه نشده است. در مطالعه‌ای دیگر [۵]، یک سیستم پایش ارتعاش مبتنی بر شتاب‌سنج‌های MEMS را برای تشخیص عیوب یاتاقان‌ها در تجهیزات دوار پیشنهاد کردند. این سیستم از تحلیل حوزه فرکانس و شاخص‌های آماری مانند RMS و Kurtosis استفاده می‌کند. اخیراً، با رشد فناوری، استفاده از یادگیری عمیق در پایش وضعیت توجه زیادی را به خود جلب کرده است. برای مثال، در [۶]، از شبکه‌های کانولوشنی و یادگیری عمیق جهت طبقه‌بندی عیوب تجهیزات دوار استفاده شده است.

در صنایع مدرن، قابلیت اطمینان و زمان کارکرد تجهیزات مکانیکی و برقی نقشی حیاتی در بهره‌وری و سودآوری ایفا می‌کند. استراتژی‌های نگهداری و تعمیرات از رویکردهای واکنشی و پیشگیرانه مبتنی بر زمان به سمت نگهداری و تعمیرات پیش‌بینانه (PdM) و پایش وضعیت (CBM) در حال تکامل هستند [۱]. تحلیل ارتعاشات به‌عنوان یکی از مؤثرترین روش‌ها برای تشخیص عیوب در حال توسعه در ماشین‌آلات شناخته می‌شود، زیرا الگوهای ارتعاشی مستقیماً به نیروهای دینامیکی داخل ماشین وابسته هستند. به‌طور سنتی، ابزارهای ارتعاش‌سنجی حرفه‌ای مبتنی بر سنسورهای پیزوالکتریک، دقیق اما گران‌قیمت و بزرگ هستند که استفاده از آن‌ها را به کاربردهای حساس و بازرسی‌های دوره‌ای محدود می‌کند. با ظهور فناوری میکروالکترومکانیکی (MEMS)، سنسورهای شتاب‌سنج کوچک و ارزان‌قیمت، فرصت‌های جدیدی برای ساخت سیستم‌های پایش وضعیت آنلاین و مقرون‌به‌صرفه فراهم کرده‌اند [۲]. با این حال، استفاده از این سنسورها با چالش‌هایی نظیر دررفت سنسور، نویز بالا و حساسیت به گرانش همراه است که نیازمند پردازش‌های دقیق سیگنال برای استخراج اطلاعات مفید است. اما استخراج یک سیگنال تمیز تنها نیمی از راه است. سیستم‌های سنتی CBM اغلب بر پایه مقایسه شاخص‌های کلی مانند مقدار RMS سرعت با آستانه‌های ثابت تکیه می‌کنند. این روش اگرچه مفید است، اما قادر به تشخیص الگوهای پیچیده و ظریف مراحل اولیه بروز عیب نیست. رویکردهای مدرن به سمت استفاده از هوش مصنوعی و یادگیری ماشین حرکت کرده‌اند تا فرایند تشخیص را خودکار و هوشمند کرده و دقت آن را افزایش دهند. در همین راستا، در این مقاله، یک راهکار جامع و شامل دو مرحله برای پیاده‌سازی یک سیستم پایش وضعیت و تشخیص عیب

بخش تجربی

مرحله اول: طراحی و ساخت سنسور ارتعاش با استفاده از شتاب‌سنج MEMS

سیستم اندازه‌گیری این مقاله بر پایه یک شتاب‌سنج دوجوره MEMS مدل ADXL203 برای اندازه‌گیری ارتعاشات دینامیکی و یک ژيروسکوپ MEMS (ماژول MPU6050) برای اندازه‌گیری سرعت زاویه‌ای بنا شده است. این سنسور توسط میکروکنترلر STM32F4 راه‌اندازی و برنامه‌نویسی شده است. در این پژوهش، فرکانس نمونه‌برداری $f_s = 1\text{KHz}$ انتخاب شده که برای پایش اغلب تجهیزات مناسب است. داده‌های خام سنسور شتاب‌سنج دارای چالش‌هایی نظیر دریف (یا بایاس سنسور در حالت سکون)، نویز فرکانس بالا و تغییرات زاویه‌ای هستند که می‌بایست برطرف شوند تا یک سیگنال شتاب تمیز و عاری از هرگونه نویز و انباشت خطا به دست آید.

گام اول: حذف دریفت سنسور: سنسورهای MEMS دارای یک خطای آفست یا دریفت هستند که باعث می‌شود خروجی آن‌ها در حالت سکون کامل، مقداری غیر صفر داشته باشد. برای این منظور، سنسور در حالت سکون کامل و دمای پایدار قرار داده‌شده و تعداد N نمونه (برای مثال $N=1000$) از خروجی آن ثبت می‌شود. میانگین حسابی این نمونه‌ها، تخمین دقیقی از بایاس استاتیک سنسور است. بنابراین، $a_{offset} = \frac{1}{N} \sum_{i=1}^N a_{raw}[i]$ مقدار دریفت محاسبه‌شده سپس از تمام داده‌های ورودی در حین کارکرد عادی سیستم کسر می‌شود یعنی $a_{calibrated}(t) = a_{raw}(t) - a_{offset}$

گام دوم: کاهش نویز فرکانس بالا: داده‌های شتاب‌سنج معمولاً حاوی نویزهای فرکانس بالا هستند که ناشی از نویز الکتریکی، ارتعاشات محیطی، یا تداخلات الکترومغناطیسی است. این نویزها می‌توانند دقت اندازه‌گیری ارتعاش را کاهش دهند. از آنجایی که از نظر سخت‌افزاری و با قرارگیری دو خازن در پایه‌های X و Y سنسور، می‌توان نویزهای فرکانس بالا را به‌طور قابل‌توجهی کاهش داد، با این حال، همچنان استفاده از یک فیلتر پایین‌گذر دیجیتال توصیه می‌شود. برای حذف این نویزها و دستیابی به سیگنال هموارتر، از یک فیلتر پایین‌گذر دیجیتال مرتبه اول استفاده می‌شود. فرم مرسوم یک فیلتر تک‌قطبی به‌صورت $y(t) = \alpha x(t) + (1-\alpha)y(t-1)$ بیان می‌شود. در این رابطه، $y(t)$ خروجی فیلتر در گام زمانی t ، $x(t)$ ورودی کالیبره شده و $y(t-1)$ خروجی فیلترشده در گام زمانی قبلی است. ضریب هموارسازی α همواره بین صفر و یک است که براساس فرکانس قطع فیلتر به‌صورت $\alpha = \frac{2\pi f_c \Delta t}{2\pi f_c \Delta t + 1}$ محاسبه می‌شود.

گام سوم: جداسازی شتاب گرانشی و خطی با فیلتر کالمن: این مرحله، پیچیده‌ترین بخش پردازش سیگنال در این پژوهش است. چالش اساسی در اینجا آن است که شتاب‌سنج به‌تنهایی قادر به تمایز میان شتاب دینامیکی ناشی از ارتعاش واقعی ماشین و مؤلفه شتاب استاتیکی ناشی از گرانش زمین نیست. هرگونه تغییر در زاویه و جهت‌گیری سنسور، باعث می‌شود که بردار ثابت گرانش به‌صورت یک سیگنال شتاب متغیر روی محورهای سنسور تصویر شود و اندازه‌گیری را به‌کلّی بی‌اعتبار سازد. فیلتر کالمن یک الگوریتم بازگشتی بهینه است که به‌صورت هوشمندانه، اطلاعات دو سنسور شتاب‌سنج و ژيروسکوپ را با هم ترکیب می‌کند. برای پیاده‌سازی فیلتر کالمن و تخمین درست از زاویه سنسور در بلندمدت، ابتدا باید سیستم دینامیکی را در قالب معادلات استاندارد فضای حالت بیان کرد. بردار حالت را می‌توان به‌صورت $x_k = [\theta_k \ b_{\omega,k}]^T$ تعریف کرد که در آن θ_k زاویه سنسور و $b_{\omega,k}$ بایاس داخلی ژيروسکوپ است که می‌خواهیم آن‌ها را تخمین بنزیم. مدل فرایند $x_k = Ax_{(k-1)} + Bu_k + w_{(k-1)}$ نحوه تحول حالت را در زمان توصیف می‌کند. ورودی مدل u_k همان سرعت زاویه‌ای اندازه‌گیری شده توسط ژيروسکوپ (ω_k) است. همچنین، A و B به‌ترتیب ماتریس انتقال حالت و ماتریس ورودی هستند. $w_{(k-1)}$ نویز فرایند با کوواریانس Q است. حال، باید فرایند اندازه‌گیری مدل شود. این مدل، حالت سیستم را به اندازه‌گیری ما مرتبط می‌کند. اندازه‌گیری ما $z_k = Hx_k + v_k$ ، زاویه‌ای است که از روی داده‌های شتاب‌سنج محاسبه می‌شود. در این رابطه، $H = [1 \ 0]$ ماتریس اندازه‌گیری و v_k نویز اندازه‌گیری با کوواریانس R است. درنهایت، الگوریتم فیلتر کالمن در دو مرحله پیش‌بینی و به‌روزرسانی اجرا می‌شود که در جدول ۱

خلاصه شده است.

جدول ۱-

$x_k^- = A\hat{x}_{k-1} + Bu_k$ $P_k^- = AP_{k-1}A^T + Q$	پیش‌بینی حالت بعدی: پیش‌بینی کوواریانس خطا:	مرحله پیش‌بینی
$K_k = P_k H^T (HP_k H^T + R)^{-1}$ $\hat{x}_k = \hat{x}_k^- + K_k (z_k - H\hat{x}_k^-)$ $P_k = (I - K_k H)P_k^-$	محاسبه بهره کالمن: به‌روزرسانی تخمین: به‌روزرسانی کوواریانس خطا:	مرحله به‌روزرسانی

خروجی نهایی الگوریتم، θ_k است که تخمین بهینه‌ای از زاویه سنسور است. با استفاده از این زاویه، مؤلفه گرانش از سیگنال فیلتر شده کسر شده و شتاب خطی خالص به صورت $a_{y,linear} = a_{y,filtered} - g \cdot \cos(\theta_k)$ و $a_{x,linear} = a_{x,filtered} - g \cdot \sin(\theta_k)$ به دست می‌آید. در نهایت، می‌توان سرعت ارتعاش را با انتگرال‌گیری عددی از سیگنال شتاب به دست آورد. برای این کار، می‌توان از روش انتگرال‌گیری دزونقهای بهره برد. البته باید توجه داشت که انتگرال‌گیری مستقیم از شتاب منجر به خطای فزاینده می‌شود. برای جلوگیری از این پدیده، ابتدا یک فیلتر بالاگذر با فرکانس قطع بسیار پایین روی سیگنال شتاب اعمال می‌شود تا هرگونه مقدار DC باقیمانده حذف شود. سپس، می‌توان مقدار مؤثر یا RMS سرعت که معیار استاندارد برای شدت ارتعاش است را با کمک رابطه $v_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^M v_i^2}$ محاسبه کرد. در شکل ۱، تصاویر سنسور طراحی و ساخته شده نمایش داده شده است.




شکل ۱- سنسور ارتعاش ساخته شده با قابلیت شبکه کردن چندین سنسور و ارسال داده ها

مرحله دوم: طراحی شبکه یادگیری عمیق برای تشخیص هوشمند عیب در این پژوهش، از یک مدل یادگیری عمیق مبتنی بر اتوانکودر کانولوشنی برای تشخیص الگوهای رفتاری غیرنرمال تجهیزات دوار استفاده شده است. این رویکرد در دسته یادگیری بدون ناظر قرار می‌گیرد، زیرا مدل تنها با استفاده از داده‌های مربوط به رفتار نرمال ماشین آموزش می‌بیند و قادر به شناسایی هرگونه انحراف از این رفتار نرمال خواهد بود. داده‌های ارتعاشی از سنسورهای مختلف (ارتعاشات افقی و عمودی ابتدا و انتهای موتور یا هر نقطه دیگر از گیربکس) براساس برجسب زمانی با یکدیگر ادغام می‌شوند تا اطمینان حاصل شود که هر نمونه داده، نمایانگر وضعیت هم‌زمان کل سیستم است. ده دقیقه داده‌برداری از ارتعاشات به‌عنوان یک نمونه در نظر گرفته می‌شود. مقادیر تمام ماتریس‌ها در بازه [۰،۱] نرمال‌سازی می‌شوند. شبکه اتوانکودر یک شبکه عصبی است که از دو بخش اصلی تشکیل شده است: رمزگذار و رمزگشا که این دو بخش از چندین لایه کانولوشنی به همراه Batch Normalization و لایه max pooling تشکیل شده است. منطق سیستم تشخیص عیب مبتنی بر شبکه اتوانکودر پیشنهادی به این صورت است: (۱) محاسبه آستانه خطا: پس از آموزش مدل بر روی داده‌های نرمال، مدل برای پیش‌بینی همین داده‌ها استفاده می‌شود و خطای بازسازی برای تک‌تک نمونه‌ها محاسبه می‌شود. سپس، یک آستانه آماری (مثلاً صدک ۹۵ام این خطا) به‌عنوان مرز بین رفتار نرمال و ناهنجار

شکل ۳، نتایج خطای بازسازی شبکه یادگیری عمیق پیشنهادی را برای داده‌های ارتعاش محورهای افقی و عمودی ابتدا و انتهای موتور را نشان می‌دهد. این نمودارها نتایج بررسی شبکه یادگیری عمیق طراحی شده را برای ۸ روز نشان می‌دهند. در طول این مدت، ۱۱۸۱ بار شبکه یادگیری عمیق ارتعاش موتور را مورد بررسی قرار داده است. همان‌طور که مشاهده می‌شود خطای بازسازی برای اکثریت داده‌ها زیر سطح آستانه است.

بر اساس نتایج به دست آمده از خطای بازسازی، همان‌طور که در شکل ۴ نشان داده شده است، از ۱۱۸۱ دفعه آنالیز شبکه یادگیری عمیق، تعداد ۱۱۷۱ بار به عنوان وضعیت نرمال موتور و ۸ دفعه به عنوان شرایط غیرنرمال یا ناهنجار شناسایی شده است که نشان از وضعیت ۹۹ درصدی نرمال موتور دارد. همچنین، از بین ۸ آنالیز به عنوان شرایط غیرنرمال، ۷ دفعه مربوط به خطا در ابتدای موتور بوده و یک مرتبه مربوط به ابتدا و انتهای موتور بوده است. بنابراین، با کمک این رویکرد می‌توان نقطه شروع خرابی، میزان رشد خرابی در طول زمان (بر اساس خطای بازسازی) و مکان خرابی یا عیب را شناسایی کرد. سپس، با کمک سایر روش‌ها نظیر تبدیل فوری، فرکانس طبیعی و سایر روش‌های تحلیل ارتعاشات محل دقیق خرابی را تشخیص داد. به عنوان نتیجه گیری، در این مقاله، یک رویکرد دومرحله‌ای برای پیاده سازی یک سیستم پایش وضعیت و تشخیص عیب هوشمند بررسی کرد. در مرحله اول، یک سنسور ارتعاش مبتنی بر شتاب‌سنج‌های MEMS طراحی و ساخت شد. مرحله دوم، با کمک داده‌های ارتعاش یک رویکرد یادگیری عمیق بدون ناظر برای تشخیص خودکار و هوشمند ناهنجاری و عیب پیشنهاد شد.



شکل ۴- نتایج شبکه یادگیری عمیق پیشنهادی مبنی بر پیش‌بینی وضعیت موتور و مکان عیب


تعیین می‌شود. هر خطایی بالاتر از این آستانه، یک ناهنجاری محسوب می‌شود. برای هر داده جدید، خطای بازسازی محاسبه شده و با آستانه مقایسه می‌شود. اگر خطا از آستانه بیشتر بود، آن نمونه به عنوان ناهنجار یا رفتار غیرنرمال شناسایی می‌شود. (۳) مکان‌یابی عیب: به جای محاسبه یک خطای کلی، خطای بازسازی به صورت مجزا برای هر داده ارتعاش محورهای افقی و عمودی ابتدا و انتهای موتور محاسبه می‌شود. این کار مشخص می‌کند که ناهنجاری در کدام بخش از موتور (مثلاً ابتدا یا انتهای موتور) و محور (افقی و عمودی) رخ داده است.

نتیجه‌گیری

در این بخش، نتایج به دست آمده از سنسور ارتعاش ساخته شده و شبکه یادگیری عمیق مورد بررسی و بحث قرار می‌گیرد. دو سنسور در ابتدا و انتهای موتور میکسر بنجوری نصب شده و داده‌های ارتعاش به شبکه منتقل شده‌اند. در شکل ۲، مقایسه‌ای بین سنسور ارتعاش ساخته شده بر اساس MEMS با دستگاه ارتعاش‌سنج پرتابل مبتنی بر پیزوالکتریک انجام شده است. این نتایج نشان می‌دهد که سنسور ارزان قیمت ساخته شده می‌تواند دقت خوبی در مقایسه با پیزوالکتریک ارائه دهد. بنابراین، سنسورهای شتاب‌سنج کوچک و ارزان قیمت MEMS، با شناسایی و رفع چالش‌ها، فرصت‌های جدیدی برای ساخت سیستم‌های پایش وضعیت آنلاین و مقرون به صرفه فراهم کرده‌اند.



شکل ۲- مقایسه نتایج سنسور ساخته شده بر اساس MEMS با دستگاه ارتعاش‌سنج پرتابل مبتنی بر پیزوالکتریک



شکل ۳- نتایج خطای بازسازی برای داده‌های ارتعاش افقی و عمودی ابتدا و انتهای موتور میکسر در طول ۸ روز

مراجع

- [1] Mobley, R. Keith. An introduction to predictive maintenance. Elsevier, 2002.
- [2] Looney, Mark. "An introduction to MEMS vibration monitoring." Analog Dialogue 48.06 (2014): 1-3.
- [3] Jatakar, Keshav H., et al. "Vibration monitoring system based on ADXL335 accelerometer and Arduino Mega2560 interface." Journal of Algebraic Statistics 13.2 (2022): 2291-2301.
- [4] Chaudhury, Subimal Bikash, Mainak Sengupta, and Kaushik Mukherjee. "Vibration monitoring of rotating machines using MEMS accelerometer." International journal of scientific engineering and research 2.9 (2014): 5-11.
- [5] Kateris, Dimitrios, et al. "A machine learning approach for the condition monitoring of rotating machinery." Journal of Mechanical Science and Technology 28.1 (2014): 61-71.
- [6] Mostafavi, Alireza, and Ali Sadighi. "A novel online machine learning approach for real-time condition monitoring of rotating machines." 2021 9th RSI International Conference on Robotics and Mechatronics (ICRoM). IEEE, 2021.