

بهینه‌سازی انتخاب ویژگی‌ها در کلان داده‌های حاصل از پایش سلامت سازه با استفاده از الگوریتم فراکاوشی

رامین قیاسی و محمدرضا قاسمی*

دانشکده مهندسی عمران، دانشگاه سیستان و بلوچستان، زاهدان

(دریافت مقاله: ۱۳۹۷/۷/۲۴ - دریافت نسخه نهایی: ۱۳۹۷/۱۲/۲۶)

چکیده - پژوهش حاضر به مبحث کلان داده‌ها در حوزه پایش سلامت سازه‌ها می‌پردازد. بدین منظور، بعد از استخراج ویژگی‌های پاسخ شتاب سازه، با استفاده از الگوریتم بهینه‌ساز ویژگی‌های کم‌اثر و اضافی حذف می‌شوند و با انتخاب ویژگی‌های تاثیرگذار و کاهش ابعاد داده‌ها دقت و سرعت روند عیب‌یابی سازه‌ها افزایش می‌یابد. انتخاب زیرمجموعه‌ای از ویژگی‌ها با استفاده از الگوریتم فراکاوشی هارمونی-پرنندگان پیشنهادی در این پژوهش صورت خواهد پذیرفت که موجب افزایش تطبیق‌پذیری روند پیشنهادی در مواجهه با کلان داده‌های ناشی از حسگرها و عدم قطعیت‌های ناشی از اختلال در داده‌های ورودی می‌شود. در روش پیشنهادی، برای استخراج ویژگی‌های پاسخ شتاب از شاخص‌های مبتنی بر خصوصیات آماری و انرژی بسته‌های موجی استفاده شده است. به‌علاوه از دو الگوریتم ماشین‌بردار پشتیبان حداقل مربعات موجی وزن‌دار و شبکه عصبی تابع پایه شعاعی به‌عنوان مدل جایگزین تحلیل اجزای محدود سازه استفاده شده و با استفاده از آنها شدت و مکان خرابی در سازه‌ها شناسایی می‌شود. به‌عنوان مسائل کاربردی، عیب‌یابی سازه پنج مارک گروه پایش سلامت سازه IASC-ASCE و سازه فضاکار ۱۲۰ عضوی مدنظر قرار گرفته است. نتایج نشان می‌دهد که انرژی بسته‌های موجی حساسیت بالاتری نسبت به وجود خرابی در سازه نسبت به خصوصیات آماری دارد. به‌علاوه مقایسه الگوریتم ترکیبی هارمونی-پرنندگان ارائه شده با چهار الگوریتم مطرح در حوزه عیب‌یابی، نشان‌دهنده سرعت و بازدهی بهتر این الگوریتم است. درنهایت استفاده از روش پیشنهادی موجب کاهش ۹۰ درصدی ابعاد داده‌ها در روند پایش سلامت سازه‌ها می‌شود.

واژه‌های کلیدی: پایش سلامت سازه، کلان داده، مدل جایگزین، الگوریتم هارمونی-پرنندگان، انرژی بسته‌های موجی.

Feature Selection in Structural Health Monitoring Big Data Using a Meta-Heuristic Optimization Algorithm

R. Ghiasi and M. R. Ghasemi*

Department of Civil Engineering, University of Sistan and Baluchestan, Zahedan, Iran.

Abstract: This paper focuses on the processing of structural health monitoring (SHM) big data. Extracted features of a

*: مسئول مکاتبات، پست الکترونیکی: mrghasemi@eng.usb.ac.ir

structure are reduced using an optimization algorithm to find a minimal subset of salient features by removing noisy, irrelevant and redundant data. The PSO-Harmony algorithm is introduced for feature selection to enhance the capability of the proposed method for processing the measured big data, which have been collected from sensors of the structure and uncertainties associated with this process. Structural response signals under ambient vibration are preprocessed according to wavelet packet decomposition (WPD) and statistical characteristics for feature extraction. It optimizes feature vectors to be used as inputs to surrogate models based on the wavelet weighted support vector machine (WWLS-SVM) and radial basis function neural network (RBFNN). Two illustrative test examples are considered, the benchmark dataset from IASC-ASCE SHM group and a 120-bar dome truss. The results indicate that the features acquired by WPT from vibrational signal have higher sensitivity to the damage of the structure. Furthermore, the proposed PSO-Harmony is compared with four well-known metaheuristic optimization algorithms. The obtained results show that the proposed method has a better performance and convergence rate. Finally, the proposed feature subset selection method has the capability of 90% data reduction.

Keywords: Structural health monitoring, Big data, Surrogate model, PSO-harmony algorithm, Wavelet packet decomposition.

فهرست علائم

n_i	تعداد داده‌های یک کلاس	$C_{j,k}^i(t)$	ضرایب موجک بسته‌ای
p_i	نسبت داده‌های یک کلاس به کل داده‌ها	E_f	انرژی سیگنال
q	ضریب نرمی موجک برای هسته	E_i	انرژی نسبی در آدامین باند فرکانسی
W	پارامتر وزن	E_p^s	انرژی نسبی بسته‌های موجکی سیگنال‌های ناشی از حسگر s
x	داده آموزشی	$f(t)$	سیگنال محدوده زمان
α_i	مقدار مرز-عدد برای هسته	F	تابع هدف مسئله بهینه‌سازی
γ	ضریب جریمه برای هسته	J_c	فاصله درون یک کلاس
ρ	ضریب وزن	J_b	فاصله بین کلاس‌ها
$\psi_{j,k}^i(t)$	توابع موجک بسته‌ای	m_i	نشان‌دهنده میانگین یک کلاس

۱- مقدمه

عیب‌یابی یکی از شاخه‌های کنترل سلامت سازه‌ها بوده که در دو دهه اخیر توجه بسیاری از پژوهشگران را به‌خود جلب کرده است [۲ و ۳]. تاکنون روش‌های متعددی برای شناسایی آسیب سیستم‌های سازه‌ای مختلف از قبیل ورق‌ها، تیرها، سازه‌های فضاکار، قاب‌ها، اسکله‌های نفتی، پل‌ها و نظایر آن ارائه شده است. فان و کیو [۴] و داس و همکاران [۵] گزارش‌های جامعی از روش‌های استفاده شده توسط پژوهشگران مختلف منتشر کردند. ویژگی‌های مودی مانند فرکانس‌های اصلی و مود شکل‌ها، معمول‌ترین ویژگی‌های مورد استفاده برای پیدا کردن خرابی هستند، زیرا این ویژگی‌ها تابعی از مشخصات فیزیکی سازه (جرم، میرایی و سختی) هستند و لذا تغییر در ویژگی‌های فیزیکی مثل کاهش در سختی که می‌تواند ناشی از وجود ترک یا از بین رفتن اتصالات باشد،

تمایل برای نظارت بر سلامت سازه و تشخیص خرابی در ابتدایی‌ترین مراحل ممکن در سازه، در میان جامعه مهندسين عمران، مکانیک و هوافضا افزایش چشمگیری داشته است [۱]. سازه‌های موجود در معرض خطرات عمده‌ای همچون افت کارایی سازه و خرابی هستند. این مشکلات با خطرات طبیعی یا مصنوعی مانند زلزله و انفجار تشدید می‌شوند. امروزه بهره‌برداری بی‌وقفه از سازه‌های عمرانی از جمله پل‌ها، مراکز کنترل، بیمارستان‌های بزرگ و سایر سازه‌های مهم ضروری است. به‌خصوص پس از وقوع حوادث طبیعی مانند زلزله، استفاده از سازه‌های فوق به کاهش اثرات ثانویه ناشی از زلزله منجر می‌شود. بدین منظور تشخیص و تعیین خرابی‌های سازه‌ای ضروری است.

سبب تغییر در این ویژگی‌های مودی می‌شود [۳ و ۵].

برای سازه‌های با تعداد عضو زیاد، آسیب محلی تغییر اندکی در اطلاعات مودال کلی ایجاد می‌کند، که تشخیص آسیب محلی را دشوار می‌سازد [۶]. به‌علاوه با افزایش داده‌های ورودی به اکثر الگوریتم‌های پیشنهاد شده توسط پژوهشگران مختلف برای عیب‌یابی سازه‌ها، دقت نتایج کاهش یافته و با جمع این دو عامل در سازه‌های واقعی، دشواری‌های شناسایی خرابی افزایش پیدا می‌کند [۷]. از طرف دیگر افزایش تعداد حسگرهای نصب شده روی سازه نیز موجب افزایش تعداد داده‌های ثبت شده توسط سیستم می‌شود. فارغ از هزینه نصب حسگرهای بیشتر روی سازه، نحوه مواجهه با حجم عظیم داده‌های ارسالی از حسگرهای نصب شده روی سازه هم باید مدنظر قرار بگیرد. تحقیقات انجام شده توسط ماتارازو و همکاران [۷] نشان می‌دهد که در صورتی که در سازه‌ای ۸۰۰ حسگر نصب شده باشد و هر حسگر ۸۰۰ داده ذخیره کرده باشد زمان لازم برای تشخیص خرابی در سازه با روش‌های مرسوم عیب‌یابی $1/5 \times 10^4$ ساعت خواهد بود، که نشان‌دهنده حجم عظیم داده‌ها و زمان مورد نیاز برای تحلیل "کلان داده‌ها" است.

کلان داده اصطلاحی است برای مجموعه داده‌های حجیم که بزرگ، متنوع، با ساختار پیچیده و با دشواری‌هایی برای ذخیره‌سازی، تحلیل و تصویرسازی (نمایش)، پردازش‌های بیشتر و یا تصمیم‌گیری بر مبنای آنها است [۸]. یکی از تعاریف کلان داده در زمینه عیب‌یابی سازه‌ها عبارت است از: یک ماتریس داده بسیار بزرگ که از نمونه‌های حاصل از تعداد فراوانی حسگر تشکیل شده است و حاصل یک سیستم پایش سلامت سازه بزرگ مقیاس است [۹].

انتخاب ویژگی‌ها یک عملیات مهم در زمینه آنالیز داده‌ها، داده‌کاوی، کلاسه‌بندی و بازیابی اطلاعات است [۱۰]. این روش‌ها موجب کاهش ابعاد ماتریس داده‌ها به‌وسیله حذف ویژگی‌های اختلال‌دار، غیرمرتبط، اضافی و به‌شدت همبسته^۱ می‌شود. وجود مجموعه بزرگی از داده‌ها یک چالش برای

کلاسه‌بندی داده‌ها ایجاد می‌کند. به‌طور مثال استفاده از تعداد زیادی ویژگی موجب می‌شود که الگوریتم به تخمین تعداد قابل توجهی از پارامترها در طی پروسه کلاسه‌بندی نیاز داشته باشد. به‌طور ایده‌آل هر ویژگی که در پروسه کلاسه‌بندی استفاده می‌شود باید یک مجموعه اطلاعات مستقل به الگوریتم اضافه کند [۱۱]. با این وجود در اکثر مواقع ویژگی‌ها به‌شدت همبسته هستند و این موجب درجه‌ای از افزونگی^۲ در داده‌های موجود می‌شود که می‌تواند تأثیر منفی بر دقت کلاسه‌بندی داشته باشد [۱۱].

برای رفع این نقص، در ادامه کارهای قبلی نویسندگان پژوهش حاضر [۲ و ۱۲] از ترکیب و بهبود روش‌های مختلفی به‌منظور کاهش حجم محاسبات مربوطه استفاده می‌شود. به‌همین منظور اصلاحاتی روی الگوریتم انتخاب زیرمجموعه‌ای از ویژگی‌ها صورت خواهد پذیرفت تا با استفاده از ترکیب آن با الگوریتم فراکاوشی قابلیت تطبیق‌پذیری آن در مواجهه با کلان داده‌ها افزایش یابد. هدف این پژوهش، ارائه راهکاری مبنی بر انتخاب مهم‌ترین ویژگی‌های پاسخ سازه با استفاده از تابع هدفی مبتنی بر بیشینه‌کردن دقت الگوریتم در شناسایی خرابی در المان‌ها است. این تابع هدف با الگوریتم بهینه‌سازی فراکاوشی هارمونی-پرندگان بهینه خواهد شد، به‌علاوه خود الگوریتم فراکاوشی مبنای نیز برای استفاده در این پروسه بهینه و اصلاح شده است.

برای این منظور، پس از برداشت داده‌های مربوط به پاسخ شتاب سازه با استفاده از حسگرهای نصب شده روی آن، در مرحله پیش‌پردازش، ویژگی‌های حساس به خرابی با استفاده از تکنیک‌های آماری و انرژی بسته‌های موجکی [۱۳] استخراج می‌شود. سپس در مرحله پس‌پردازش با استفاده از الگوریتم‌های بهینه‌ساز ویژگی‌هایی که تأثیر کمی در دقت عیب‌یابی داشته حذف می‌شوند. درنهایت به‌منظور کاهش حجم محاسبات مرتبط با شناسایی خرابی، از الگوریتم ماشین بردار پشتیبان حداقل مربعات موجکی وزن‌دار^۳ [۱۴] به‌عنوان مدل جایگزین تحلیل دقیق اجزای محدود استفاده می‌شود. به‌منظور

کنترل درستی روش پیشنهادی در شناسایی انواع سناریوهای خرابی، سازه پنج‌مارک گروه پایش سلامت سازه IASC-ASCE و سازه فضاکار ۱۲۰ عضوی مورد بررسی قرار گرفته است. از طرف دیگر در بخش مثال‌ها برای صحت‌سنجی الگوریتم پیشنهادی هارمونی-پرنندگان نتایج حاصل از این الگوریتم با چهار الگوریتم فراکاوشی شناخته شده مقایسه خواهد شد. همچنین کارایی الگوریتم ماشین بردار پشتیبان حداقل مربعات موجکی وزن‌دار در کلاسه‌بندی وضعیت‌های سازه در مقایسه با الگوریتم شبکه عصبی تابع پایه شعاعی^۴ (RBFNN) [۱۵] بررسی خواهد شد.

۲- تعریف کلان داده‌ها

تعریف کلان داده^۵ هنوز یک موضوع قابل بحث است. در سال ۲۰۰۱ لنی مدل 3V را معرفی کرد [۱۶] که در آن حجم^۶ (ترابایت^۷، پتابایت^۸ داده و یا بیشتر)، گوناگونی^۹ (فرمت‌های ناممکن^{۱۰} مانند متن، داده حسگر، صوت، ویدئو، گراف و...) و نرخ تولید^{۱۱} (جریان دائم از داده‌ها) به عنوان ویژگی‌های اصلی کلان داده‌ها در نظر گرفته شده است. با این حال از آن تاریخ این تعریف اصلاح شده است تا ویژگی‌های کیفی مانند تغییرپذیری^{۱۲}، صحت^{۱۳} و ارزش^{۱۴} را نیز شامل شود [۱۷].

مبحث تحلیل کلان داده‌ها دارای سابقه طولانی بوده و اصول خود را از حوزه‌های مختلف اما مرتبط گرفته است. این حوزه‌ها همگی شامل یک هسته اصلی هستند که همان پیدا کردن طرح در داده‌ها با بزرگ‌نمایی و توجه متفاوت است. [۱۸].

این حوزه‌ها شامل تکنیک‌های آماری^{۱۵}، داده کاوی^{۱۶}، تحلیل پیش‌گویانه^{۱۷}، تحلیل کسب و کار^{۱۸}، اکتشاف دانش از داده‌ها^{۱۹} (KDD)، آنالیز داده‌ها^{۲۰}، دانش داده^{۲۱}، و اکنون کلان داده می‌شود [۱۸]. شکل (۱) نشان‌دهنده این ارتباط بین رشته‌ای مبحث کلان داده‌ها است.

پژوهش حاضر به مبحث کلان داده‌ها در حوزه پایش سلامت سازه‌ها می‌پردازد. تفسیر داده‌های ناشی از ارتعاش سازه در زمینه‌های شناسایی خرابی، به‌روز رسانی مدل و ارزیابی

آسیب‌پذیری^{۲۲} سازه‌های موجود ارزشمند است [۱۵ و ۱۸]. با پیشرفت‌های روزافزون در تکنولوژی حسگرها، ابعاد مسائل پایش سلامت سازه هم از لحاظ زمان و هم حجم داده‌ها افزایش می‌یابد. به‌منظور بیان مثالی از بزرگی داده‌ها می‌توان به تحقیقات کتب و ملک‌زاده [۱۹] اشاره کرد که در آن به بررسی پل متحرک سانرایس در فلوریدا که دارای ۲۰۰ حسگر است پرداخته شده است. روزانه این پل ده مرتبه برای عبور کشتی‌ها باز می‌شود و در هر مرتبه حسگرهای شتاب‌سنج، داده‌های حاصل از این فرایند را اندازه‌گیری می‌کنند. در هر یک از این برداشت‌ها ۱۶۰۰۰ داده جمع‌آوری می‌شود. از این‌رو تعداد داده‌ها در سال برای یک حسگر برابر خواهد شد با:

$$16 \times 10^3 \times 10 \times 365 = 576 \times 10^7 \quad (1)$$

اما این امکان‌پذیر نیست و در خیلی از مواقع لازم نیست که تمام این کلان داده‌ها را به‌صورت همزمان مورد پردازش قرار داد. در این حالت کارهای ساده‌ای همچون بارگذاری تمام داده‌های اندازه‌گیری شده نیز به زمان محاسباتی قابل توجهی نیاز دارد. هزینه محاسباتی روند عیب‌یابی را به‌روش‌های مختلفی می‌توان کاهش داد، از جمله:

الف- ارائه روش‌های استخراج ویژگی‌ها از داده‌های اصلی:


در این روش‌ها، ماتریس اصلی به ماتریسی با ابعاد بسیار کمتر از ماتریس اولیه کاهش پیدا می‌کند. ماتریس ثانویه شامل خصوصیات یا ویژگی‌های ماتریس اولیه بوده که برای کاهش ابعاد آن از روش‌هایی مانند PCA^{۲۳}، POD^{۲۴} و ... استفاده می‌شود [۲۰].

ب- روش‌های فشرده‌سازی اطلاعات و انتقال ویژگی‌های

فشرده شده: در این روش‌ها، برای کاهش ابعاد داده‌هایی که باید به کامپیوتر مرکزی منتقل شود، داده‌های خام حاصل از هر حسگر با هم ترکیب شده^{۲۵} و سپس داده‌ها منتقل می‌شوند [۲۱].

پ- روش‌های انتخاب زیرمجموعه^{۲۶}:

بخشی از داده‌های جمع‌آوری شده مورد پردازش و یا انتقال قرار می‌گیرند [۱۰].



شکل ۱- ذات بین رشته‌ای تحلیل کلان داده‌ها

بردار تکیه‌گاه یا همان ماشین بردار پشتیبان، به این ترتیب است که ابتدا بردارهای ورودی به شکل غیرخطی به یک فضای جدید با ابعاد بزرگ‌تر نگاشت می‌شوند. سپس در این فضای جدید سطوح خطی تصمیم‌گیر ساخته می‌شوند. خصوصیات این صفحات تصمیم‌گیر به نحوی است که قابلیت تعمیم را برای روش فراگیری ماشینی تضمین می‌کند. بنابراین به دلیل داشتن قابلیت نگاشت، می‌توان گفت SVM یک حالت کلی از ماشین‌های فراگیر است که شبکه عصبی، شبکه‌های شعاع مبنا و دسته‌بندی کننده‌های چندجمله‌ای، حالت‌های خاصی از آن هستند [۲۲].

SVM جزء الگوریتم‌های دسته‌بندی شده‌ای است که بدون دانستن مدل توزیع داده‌ها، دسته‌بندی را انجام می‌دهد. حتی فراتر از آن، این مدل نیازی به دانستن یک ساختار کلی از مساله ندارد. شبکه بردارهای پشتیبان یک ماشین آموزشی جهت دسته‌بندی داده‌های ورودی به دو گروه است، اما با استفاده از تکنیک‌هایی برای مسائل چنددسته‌ای نیز استفاده می‌شود [۲۳]. به طور کلی SVM بردارهای ورودی را با استفاده از یک هسته به یک فضای با ابعاد بزرگ‌تر می‌برد که تفکیک پذیری خطی در آن بهتر و قاطعانه‌تر انجام می‌شود. با استفاده از هسته‌های مختلف، می‌توان روش‌های فراگیری مختلفی با انواع سطوح تصمیم‌گیری دلخواه ساخت. به این ترتیب SVM به عنوان یک کلاس جدید از دسته‌بندی کننده‌ها و ماشین‌های

راهکار سوم در برخورد با کلان داده‌ها از عملکرد بهتری برخوردار است، چون در دو راهکار دیگر نیاز به دسترسی به کل ماتریس داده‌ها و بررسی و استخراج ویژگی‌های آن است در حالی که در روش سوم فقط بخش کوچکی از ماتریس مورد بررسی و تحلیل قرار می‌گیرد و اطلاعات اساسی وارد مرحله بعد می‌شود. با این حال این روش در تعدادی از مسائل به خصوص هنگام وجود اختلال زیاد در داده‌های ورودی کیفیت خود را از دست می‌دهد [۷ و ۱۹]. به همین منظور در این پژوهش اصلاحاتی روی الگوریتم انتخاب زیرمجموعه از ویژگی‌ها صورت خواهد پذیرفت تا با ترکیب آن با الگوریتم‌های فراکاوشی قابلیت تطبیق پذیری آن در مواجهه با عدم قطعیت‌های ناشی از اختلال در داده‌های ورودی افزایش یابد.

۳- ماشین بردار پشتیبان حداقل مربعات موجکی

وزن دار (WWLS-SVM)

ماشین بردار پشتیبان در سال ۱۹۹۵ توسط واپنیک بر پایه تئوری یادگیری آماری بیان شده است [۲۲]. SVM از یک ابرصفحه^{۲۷} خطی تفکیک گر بهینه، برای دسته‌بندی داده‌ها استفاده می‌کند که این ابرصفحه بهینه از حداکثر کردن حاشیه^{۲۸} به دست می‌آید. به این منظور باید یک مساله بهینه‌سازی غیرخطی مقید^{۲۹} حل شود. نظریه SVM با این فرضیه که تابع تفکیک گر در فضای ورودی می‌تواند غیرخطی باشد، تکمیل شد. نظریه عملکرد شبکه‌های

عملگر فیلتر بازگشتی^{۳۲} صورت می‌پذیرد [۱۳]. بعد از z -سطح گسسته‌سازی، سیگنال اصلی $f(t)$ می‌تواند به این صورت بیان شود:

$$f(t) = \sum_{i=1}^j f_j^i(t) \quad (۳)$$

$$f_j^i(t) = \sum_{i=1}^j C_{j,k}^i(t) \psi_{j,k}^i(t) \quad (۴)$$

در اینجا سیگنال سازنده $f_j^i(t)$ می‌تواند به وسیله ترکیب خطی توابع موجکی $\psi_{j,k}^i(t)$ بیان شود. اعداد i ، j و k به ترتیب نشان دهنده پارمترهای مدول^{۳۳}، مقیاس و انتقال هستند. $C_{j,k}^i(t)$ و $\psi_{j,k}^i(t)$ به عنوان ضرایب موجک بسته‌ای و توابع موجک بسته‌ای تعریف می‌شوند. ضرایب موجک بسته‌ای را می‌توان با کمک این رابطه محاسبه کرد:

$$C_{j,k}^i = \int_{-\infty}^{\infty} f(t) \psi_{j,k}^i(t) dt \quad (۵)$$

در حوزه عیب‌یابی سازه‌ها، اطلاعات محدوده فرکانسی بسیار مهم هستند و از این‌رو WPT سطح بالایی برای تشخیص تغییرات کوچک در سیگنال نیاز دارد. بعد از WPT، از انرژی سیگنال‌های سازنده گسسته شده، می‌توان برای ارزیابی وضعیت سازه استفاده کرد. انرژی سیگنال‌های سازنده چنین بیان می‌شود:

$$E_j^i = \int_{-\infty}^{\infty} (f_j^i(t))^2 dt \quad (۶)$$

می‌توان نشان داد وقتی موجک مادر متعامد و یا نیمه‌متعامد است، انرژی سیگنال E_f به صورت جمع انرژی اجزای سازنده z -سطح، بیان می‌شود [۱۳]:

$$E_f = \int_{-\infty}^{\infty} f^2(t) dt = \sum_{i=1}^j E_j^i \quad (۷)$$

در قسمتی از این پژوهش، از انرژی نسبی سیگنال‌های سازنده پاسخ شتاب سازه به عنوان ورودی WWLS-SVM استفاده شده است. انرژی نسبی E_i در i -امین باند فرکانسی به صورت رابطه (۸) محاسبه می‌شود:

$$E_i = \frac{E_j^i}{E_f} \quad (۸)$$

تشخیص الگو در می‌آید. فرایند عیب‌یابی سازه‌ها مسئله‌ای چند کلاسه است لذا این نوع دسته‌بندی کننده می‌تواند توسط ترکیب SVMهای دو کلاسه ساخته شوند و این روش برخلاف سایر روش‌ها، دسته‌بندی را بین هر کلاس و سایر کلاس‌های باقی‌مانده انجام می‌دهد [۲۳]. در این پژوهش از نسخه اصلاح شده SVM که در آن به منظور افزایش توانایی الگوریتم در پردازش داده‌ها در روند ریاضی پایه آن تغییراتی ایجاد شده است و به عنوان روش ماشین بردار پشتیبان حداقل مربعات وزن دار شناخته می‌شود (WLS-SVM)، استفاده شده است [۲۳]. از آنجایی که انتخاب هسته SVM تأثیر زیادی بر دقت و کارایی مدل جایگزین مبتنی بر آن دارد، در این پژوهش از هسته ترکیبی موجکی پیشنهاد شده در مقاله قیاسی و همکاران استفاده می‌شود [۱۴]. هسته ترکیبی موجکی $TPSLPW^{۳۰}$ بر اساس رابطه (۲) ساخته می‌شود:

$$\begin{aligned} K_{TPSLPW}(x_k, x_l) &= \rho K_{ThinPlateSpline}(x_k, x_l) + \\ & (1-\rho) K_{L-Pwavelet}(x_k, x_l) \\ K_{TPSLPW} &= \rho \|x_k - x_l\|^2 \ln \|x_k - x_l\| + \\ & (1-\rho) \prod_{i=1}^n \frac{1}{\pi \sqrt{q-1}} \frac{\sin q \pi \left(\frac{(x_k)_i - (x_l)_i}{a_i} \right) - \sin \pi \left(\frac{(x_k)_i - (x_l)_i}{a_i} \right)}{\left(\frac{(x_k)_i - (x_l)_i}{a_i} \right)} \end{aligned} \quad (۲)$$

که در آن $K_{L-Pwavelet}$ و $K_{ThinPlateSpline}$ به ترتیب هسته شعاع مبنا و هسته موجکی استفاده شده و x_k و x_l داده‌های آموزشی هستند. در نهایت WWLS-SVM با هسته ترکیبی موجکی پیشنهاد شده دارای ۴ پارامتر تنظیمی (ضریب جریمه $\gamma > 0$ ، ضریب نرمی موجک $a > 0$ ، مقدار مرز-عدد $q > 1$ و ضریب وزن $0 \leq \rho \leq 1$) است که با استفاده از الگوریتم بهینه‌سازی هارمونی-پرندگان ارائه شده در این پژوهش مقادیر مناسب آنها انتخاب می‌شود.

۴- تبدیل موجک بسته‌ای (WPT^{۳۱})

تبدیل موجک بسته‌ای سیگنال محدوده زمانی $f(t)$ با استفاده از

در این پژوهش موجک Battle-Lemarie [۲۴] به عنوان موجک بسته‌ای پایه در نظر گرفته شده است و از آن به منظور گسسته سازی سیگنال ارتعاشی به باندهای فرکانسی مختلف با انرژی مستقل استفاده می‌شود. نقاط اندازه‌گیری انتخابی روی سازه مشخص شده و پس از آن، پاسخ ارتعاشی ثبت شده به وسیله WPT مورد آنالیز قرار می‌گیرد.

تعداد سطح‌های گسسته‌سازی از طریق آزمون و خطا و آنالیز حساسیت داده‌های ناشی از سازه سالم و معیوب مشخص می‌شود. انرژی باند فرکانسی پس از محاسبه نرمالایز می‌شود. انرژی نسبی بسته‌های موجکی^{۳۴} (WPRE) سیگنال‌های ناشی از حسگر s به صورت زیر بیان می‌شود:

$$E_p^s = \{E_m, m=1, \dots, M\} \quad (9)$$

که در آن $s=1, 2, \dots, S$ و $p=1, 2, \dots, P$ تعداد نقاط برداشت است. مقدار WPRE ناشی از یک حسگر با مقادیر WPRE سایر حسگرها ترکیب شده تا بردار ورودی ترکیبی^{۳۵} نهایی ایجاد شود:

$$E_p = \{E_p^1, E_p^2, \dots, E_p^s\} \quad (10)$$

این بردار ورودی الگوریتم مدل جایگزین خواهد بود. همان‌طور که در بخش (۴) بیان شد از مدل جایگزین به منظور مشخص کردن وضعیت سازه استفاده می‌شود.

۵- الگوریتم جستجوی هارمونی^{۳۶}

الگوریتم جستجوی هارمونی توسط گیم و همکارانش در سال ۲۰۰۱ ارائه شده است. این الگوریتم برای بهینه‌سازی مسائل از پدیده موسیقی در یافتن یک حالت خارق‌العاده از هارمونی الهام گرفته است [۲۵].

نت‌هایی که با آلات موسیقی توسط نوازنده‌ها نواخته می‌شوند و در کنار یکدیگر هارمونی را ایجاد می‌کنند، مشابه مقادیر اختصاص داده شده به متغیرهای تابع هدف است که در کنار هم جواب مسئله را می‌دهند. سپس هارمونی جدید بر اساس معیارهای زیباشناسی ارزیابی می‌شود که اگر مطلوب باشد آن نت‌ها در حافظه هر نوازنده به خاطر سپرده می‌شوند.

به‌طور مشابه در روند بهینه‌سازی با الگوریتم جستجوی هارمونی، برای هر متغیر مقداری از دامنه‌اش انتخاب می‌شود سپس مقدار تابع هدف به دست آمده به‌زای این مقادیر از نظر جنبه‌هایی مثل حداقل هزینه و یا خطا، حداکثر بازده و ... ارزیابی می‌شود، اگر این مقادیر منجر به جواب مطلوبی شده باشند برای متغیرهای مربوطه ذخیره می‌شوند [۲۵].

الگوریتم جستجوی هارمونی برای بهینه‌سازی مسئله مورد نظر این روند را در پنج مرحله پیاده می‌کند، که عبارتند از: مرحله اول: مقداردهی اولیه پارامترهای مسئله و الگوریتم؛ مرحله دوم: مقداردهی اولیه حافظه هارمونی^{۳۷} (HM) و اختصاص پارامترهای تنظیمی الگوریتم از جمله سرعت بررسی حافظه هارمونی^{۳۸} (HMCR) و سرعت تنظیم قطعات^{۳۹} (PAR)؛ مرحله سوم: ایجاد یک هارمونی جدید از حافظه هارمونی؛ مرحله چهارم: به‌روز کردن حافظه هارمونی؛ مرحله پنجم: بررسی شرط توقف؛ اطلاعات تکمیلی در مورد هریک از مراحل فوق در مرجع [۲۵] قابل دسترسی است.

۶- الگوریتم هارمونی-پرنندگان

الگوریتم هارمونی-پرنندگان ارائه شده در این پژوهش یک ترکیب خاص از الگوریتم‌های اجتماع پرنندگان^{۴۰} (PSO) و جستجوی هارمونی است، به‌طوری که در مقایسه با هر یک از آنها دارای شخصیت همگرایی بهتر و حجم محاسبات کمتری است. الگوریتم اجتماع پرنندگان در مقایسه با سایر الگوریتم‌های بهینه‌سازی مبتنی بر جستجوی تصادفی دارای مزیت‌هایی همچون سادگی و سرعت همگرایی بالا است، اما تعداد پرنندگان عملکرد الگوریتم را به شدت تحت تأثیر قرار می‌دهد [۲۶]. در مرجع [۲۶] عنوان شده است که محدوده تغییرات معمول برای تعداد پرنندگان بین ۲۰ تا ۴۰ است. برای برخی مسائل بهینه‌سازی تعداد ۱۰ پرنده کافی است اما در مسائل پیچیده یا خاص ۱۰۰ تا ۲۰۰ پرنده در نظر گرفته می‌شود. در حالت کلی استفاده از تعداد زیادی پرنندگان سبب افزایش

چشمگیر میزان محاسبات فرایند بهینه‌سازی خواهد شد درحالی که با تعداد کم پرندگان، میزان محاسبات کاهش خواهد یافت هرچند که در این حالت احتمال به‌دام افتادن الگوریتم بهینه‌سازی در بهینه‌های موضعی افزایش می‌یابد. الگوریتم هارمونی-پرندگان یک راهکار مناسب برای دستیابی به جواب بهینه با حجم محاسبات کم است.

در شروع الگوریتم هارمونی، ماتریس حافظه هارمونی با گروهی از بردارهای جواب (هارمونی) که به‌صورت اتفاقی ایجاد می‌شوند پر می‌شود. پر کردن حافظه هارمونی آغازگر به‌صورت بهینه می‌تواند سرعت همگرایی الگوریتم را به‌طور قابل ملاحظه‌ای افزایش دهد، از این‌رو در الگوریتم ترکیبی پیشنهادی، اجتماع پرندگان جایگزین انتخاب تصادفی بردارهای هارمونی می‌شود. در این الگوریتم ترکیبی یک دور بهینه‌سازی اولیه با استفاده از الگوریتم اجتماع پرندگان و با در نظر گرفتن ۲۰ پرنده انجام می‌گیرد. در این حالت به دلیل استفاده از تعداد کم پرندگان، جواب به‌دست آمده به احتمال زیاد یک بهینه موضعی است. این جواب حاصل یک جستجوی کلی در فضای طراحی و با استفاده از الگوریتم اجتماع پرندگان است. در این حالت انجام یک جستجوی موضعی در اطراف نقطه به‌دست آمده منجر به دستیابی جواب بهتری خواهد شد. بنابراین در ادامه، از جستجوی هارمونی جهت انجام جستجوی محلی استفاده می‌شود.

برای ایجاد حافظه هارمونی اولیه در الگوریتم ترکیبی، بهترین پاسخ الگوریتم اجتماع پرندگان انتخاب می‌شود (Xpso). این عضو به تعداد $HMS/2$ بار در حافظه هارمونی زیاد می‌شود و بقیه اعضای حافظه مانند الگوریتم جستجوی هارمونی استاندارد به‌صورت تصادفی انتخاب می‌شوند. اندازه حافظه هارمونی^{۴۱} (HMS) بیان‌گر تعداد بردارهای جواب (هارمونی) است که در حافظه هارمونی قرار داده می‌شوند. معمولاً مقداری بین ۲۰ تا ۵۰ به آن اختصاص داده می‌شود. این پارامتر شبیه تعداد جمعیت در الگوریتم ژنتیک است. در فرایند جستجوی نقاط بهینه باید دو اصل اساسی را

به‌طور همزمان مورد توجه قرار داد. اول اینکه نقطه بهینه کلی می‌تواند در هر جای فضای جستجو قرار داشته باشد. دوم اینکه احتمال یافتن نقطه جدید که بتواند مقدار تابع هدف را بهبود بخشد، نزدیک نقطه‌ای با مقدار تابع هدف بهتر، بیشتر از نقطه‌ای با مقدار تابع هدف بدتر است [۲۶]. در الگوریتم هارمونی-پرندگان دو استراتژی گفته شده در کنار هم و به‌طور همزمان و مؤثر در یافتن نقطه بهینه به‌کار برده می‌شوند. با انتخاب تصادفی چندین عضو حافظه هارمونی، استراتژی اول را به‌کار بسته‌ایم و با تکثیر کردن بهترین پاسخ الگوریتم اجتماع پرندگان در حافظه هارمونی استراتژی دوم را به‌کار می‌گیریم.

نتایج به‌دست آمده در این پژوهش حکایت از عملکرد محاسباتی مناسب الگوریتم هارمونی-پرندگان دارد. فرایند الگوریتم هارمونی-پرندگان در شکل (۲) نشان داده شده است.

۷- روند چارچوب پیشنهادی برای عیب‌یابی سازه‌ها

همان‌طور که در مقدمه اشاره شد روش پیشنهادی از دو گام اساسی تشکیل شده است:


گام اول: استخراج ویژگی‌های پاسخ شتاب سازه؛

گام دوم: انتخاب ویژگی‌های بهینه با استفاده از الگوریتم بهینه‌سازی و مشخص کردن وضعیت سازه با استفاده از الگوریتم مدل جایگزین که در زیر بخش‌های (۷-۱) و (۷-۲) هر یک از این دو گام تشریح می‌شود.

۷-۱- استخراج ویژگی‌های داده‌های حاصل از حسگرها

در این پژوهش، از دو رویکرد مختلف برای استخراج ویژگی‌های پاسخ شتاب سازه استفاده می‌شود. بدین منظور پس از تحلیل سازه برای حالت خرابی مورد نظر، با استفاده از اطلاعات حسگرها پاسخ شتاب سازه (سیگنال ارتعاشی) برداشت می‌شود؛ سپس از خصوصیات آماری سیگنال و یا WPRE آن به‌عنوان ورودی سیستم عیب‌یابی استفاده می‌شود.

خصوصیات آماری بر اساس روابط جدول (۱) محاسبه می‌شوند که نشان‌دهنده انرژی، دامنه ارتعاشی^{۴۲} و پخش



شکل ۲- فرآیند الگوریتم هارمونی-پرندگان

جدول ۱- ویژگی‌ها در حوزه زمان

معادله	ویژگی
$rms = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$	جذر میانگین مربعات ^{۴۶}
$var = \sigma^2 = \frac{\sum_{n=1}^N (x(n) - \text{mean}(n))^2}{(N-1)}$	واریانس ^{۴۷}
$skewness = \frac{\sum_{n=1}^N (x(n) - \text{mean}(n))^3}{(N-1) \times \sigma^3}$	چولگی ^{۴۸}
$kurtosis = \frac{\sum_{n=1}^N (x(n) - \text{mean}(n))^4}{(N-1) \times \sigma^4}$	درجه اوج ^{۴۹}
$crest = \frac{\max x(n) }{rms}$	ضریب اوج ^{۵۰}
$max = \max x(n) $	حداکثر مقدار ^{۵۱}


سطرهای ماتریس داده‌ها کاهش می‌یابد (شکل ۳). بعد از ترکیب ویژگی‌های حسگرهای مختلف با هم، ویژگی‌های اختلال‌دار، غیرمرتبط، اضافی و به‌شدت همبسته با استفاده از الگوریتم بهینه‌ساز حذف می‌شود. درنهایت از این ماتریس جدید، که سطرهای آن حالت‌های مختلف خرابی سازه و ستون‌های آن ویژگی‌های منتخب پاسخ سازه است، برای شناسایی خرابی در سازه با استفاده از الگوریتم‌های WWLS-SVM و RBFNN استفاده می‌شود (شکل ۳).

روند کلی عیب‌یابی با روش‌های مبتنی بر الگوریتم‌های هوش مصنوعی کلاسه‌بندی مانند WWLS-SVM و یا شبکه عصبی به این صورت است که ابتدا بایستی الگوریتم، روند ایجاد ماتریس خروجی براساس ماتریس ورودی را آموزش ببیند. در این پژوهش ماتریس خروجی محل و شدت خرابی در سازه و ماتریس ورودی، ویژگی‌های بهینه استخراج شده است. همان‌طور که اشاره شد، تعداد ویژگی‌های هر داده ورودی (تعداد ستون‌های ماتریس آموزشی) تأثیر زیادی بر دقت و

سری‌های زمانی^{۴۳} سیگنال در حوزه زمان است [۲۷]. WPRE نیز براساس مطالب بخش (۴) صورت می‌پذیرد.

۲-۷- انتخاب ویژگی‌های داده‌های ورودی با الگوریتم‌های بهینه‌ساز

در مقدمه مقاله اشاره شد که یکی از تعاریف کلان داده در زمینه عیب‌یابی سازه‌ها عبارت است از یک ماتریس داده بسیار بزرگ که از نمونه‌های حاصل از تعداد فراوانی حسگر تشکیل شده است و حاصل یک سیستم پایش سلامت سازه بزرگ مقیاس است. سطرهای ماتریس داده‌ها در این حالت گام‌های زمانی برداشت پاسخ سازه و ستون‌های ماتریس حسگرهای نصب شده روی آن است. در این پژوهش به‌منظور کاهش ابعاد مسائل عیب‌یابی سازه‌های کاربردی، مرحله پیش پردازش روی داده‌ها انجام می‌شود. بدین منظور با استفاده از تبدیل موجک بسته‌ای ویژگی‌های اساسی پاسخ شتاب ناشی هر از کدام از حسگرهای نصب شده روی سازه استخراج می‌شود. بدین ترتیب تعداد



شکل ۳- روند کاهش ابعاد داده‌ها به منظوری شناسایی خرابی در سازه

انتخاب شده و اگر صفر باشد نشان‌دهنده عدم انتخاب آن ویژگی است.

برای بالا بردن دقت الگوریتم از روش ارزیابی فاصله^{۴۵} نیز استفاده شده است. در روش ارزیابی فاصله سعی بر این است که فاصله بین کلاس‌های متفاوت افزایش یافته، ضمن آنکه فاصله بین داده‌های مربوط به یک کلاس کاهش پیدا کند تا دقت کلاسه‌بندی افزایش پیدا می‌کند. فاصله درون یک کلاس به‌صورت رابطه‌های (۱۱) و (۱۲) تعریف می‌شود [۲۷]:

$$J_c = \sum_{i=1}^c p_i J_i \quad (11)$$

$$J_i = \left(\frac{1}{n_i} \right) \sum_{k=1}^n (x_k^i - m_i)^T (x_k^i - m_i) \quad (12)$$

که در آن $i=1, 2, \dots, c$ شماره کلاس، m_i نشان‌دهنده میانگین یک کلاس i ، n_i نشان‌دهنده تعداد داده‌های یک کلاس و p_i نسبت داده‌های یک کلاس به کل داده‌ها است.

فاصله بین کلاس‌ها به‌صورت رابطه (۱۳) تعریف می‌شود:

$$J_b = \sum_{k=1}^c p_i (m_i - m)^T (m_i - m) \quad (13)$$

که در آن m میانگین کل داده‌ها است. نسبت J_c/J_b به‌نحوی

سرعت الگوریتم‌های درونیاب دارد. به‌عبارتی، اگر فقط از اطلاعات حاصل از یک حسگر استفاده شود ویژگی‌های کمی از وضعیت سازه به الگوریتم منتقل می‌شود. به‌علاوه ممکن است این تک‌حسگر دقیق نباشد و در نتیجه کل فرایند عیب‌یابی دقت مطلوبی نخواهد داشت. از طرف دیگر اگر از اطلاعات کل حسگرهای نصب شده روی یک سازه استفاده شود حجم اطلاعات به‌ازای حالت‌های مختلف خرابی بالا می‌رود و در نتیجه فرایند عیب‌یابی با استفاده از الگوریتم‌های هوش مصنوعی کند می‌شود.

همان‌طور که بیان شد برای رفع این مشکل، پژوهشگران از روش‌های مختلفی همچون PCA و ICA^{۴۴} برای کاهش ابعاد داده‌ها استفاده کرده‌اند [۲۰]، هرچند در این روش‌ها تضمینی بر اینکه اطلاعات حذف شده برای عیب‌یابی مفید نبوده‌اند، وجود ندارد. در این پژوهش از الگوریتم‌های هوشمند بهینه‌ساز برای انتخاب بهینه ویژگی‌های داده‌های ورودی استفاده می‌شود. برای رسیدن به این هدف در الگوریتم هارمونی، بردار هارمونی جدید به‌صورت باینری در نظر گرفته می‌شود، که در آن هر ستون نشان‌دهنده یک ویژگی پاسخ شتاب سازه خواهد بود. با این روش اگر مقدار ستون برابر با یک باشد یعنی آن ویژگی

محاسبه می‌شود که مقدار کمتری برای J_c و مقداری بیشتری برای J_b انتخاب می‌شود. فرایند بهینه‌سازی به‌نحوی است که مقدار J_c/J_b کمینه شود.

در نهایت تابع هدف مسئله بهینه‌سازی به‌صورت زیر خواهد بود:

$$F = W(WWLS-SVM_{TrainingAccuracy})^{-1} + (1-W) \times \frac{J_c}{J_b} \quad (14)$$

که در آن W پارامتر وزن بوده که بین ۰ تا ۱ تغییر می‌کند. با توجه به رابطه اخیر هدف مسئله بهینه‌سازی افزایش دقت الگوریتم WWLS-SVM با انتخاب بهینه ویژگی‌های داده‌های ورودی است.

در نهایت پس از استخراج ویژگی‌های پاسخ شتاب سازه، در گام بعد ویژگی‌های منتخب و همچنین پارامترهای تنظیمی الگوریتم WWLS-SVM با استفاده از الگوریتم هارمونی-پرنندگان انتخاب می‌شوند. در شکل (۴) فرایند چارچوب پیشنهادی برای انتخاب ویژگی‌های بهینه و عیب‌یابی سازه با استفاده از آنها، ارائه شده است.

۸- شاخص‌های بررسی کارایی الگوریتم

برای بررسی کارایی چارچوب پیشنهادی در این پژوهش از شاخص‌های پرکاربرد علم داده^{۵۲} در زمینه محاسبه کارایی الگوریتم‌های کلاسه‌بندی استفاده می‌شود [۱۰]. این شاخص‌ها شامل دقت^{۵۳}، صحت^{۵۴}، بازخوانی^{۵۵} و امتیاز اف^{۵۶} است که در ادامه تشریح می‌شوند.

با فرض اینکه هدف ما پیش‌بینی معیوب‌بودن سازه است، یعنی اگر پیش‌بینی مثبت باشد سازه مورد نظر معیوب بوده و اگر پیش‌بینی منفی باشد، یعنی سازه سالم است، اولین معیار (آماره)، معیار دقت یا میزان تشخیص درست مدل است. به عبارت دیگر نسبت تشخیص‌های درست به کل داده‌ها برابر است با:

$$\text{کل داده‌ها/تشخیص‌های درست} = \text{دقت} \quad (15)$$

دومین آماره مورد استفاده آماره بازخوانی است که بر تعداد

نمونه‌های مثبت شناسایی شده به کل نمونه‌های مثبت تمرکز شود. به عبارت دیگر از وضعیت‌هایی که در آن سازه معیوب است چه تعداد توسط الگوریتم شناسایی شده است. معیار بازخوانی بدین منظور به‌صورت زیر تعریف می‌شود:


$$(16) \quad \text{تعداد نمونه‌های تشخیصی درست مثبت} / \text{بازخوانی کل نمونه‌های واقعا مثبت}$$

کل نمونه‌های واقعاً مثبت شامل نمونه‌هایی است که به‌درستی مثبت شناسایی شده‌اند و نمونه‌هایی که مثبت بوده‌اند اما به اشتباه منفی شناسایی شده‌اند. به عبارت دیگر تمامی وضعیت‌هایی که سازه در آنها معیوب است فارغ از اینکه الگوریتم کلاسه‌بندی چه پیش‌بینی انجام داده باشد. در کنار معیار بازخوانی معیار دیگری را به نام صحت، برابر تعداد نمونه‌های تشخیصی درست مثبت به کل نمونه‌های مثبت اعلام شده به‌صورت زیر تعریف می‌شود تا میزان مثبت‌های اشتباه نیز در نظر گرفته شود:

$$(17) \quad \text{تعداد نمونه‌های تشخیصی درست مثبت} / \text{تعداد کل نمونه‌های تشخیص مثبت} = \text{صحت}$$

در این فرمول، اگر تعداد تشخیص‌های اشتباه زیاد باشد، حالت‌هایی در مخرج که سازه سالم باشد اما نتیجه پیش‌بینی نشانگر معیوب‌بودن سازه باشد، باعث می‌شود که درستی الگوریتم عددی به صفر نزدیک شود. بنابراین کارایی مدل زیر سوال می‌رود. با این توضیحات، معیارهای بازخوانی و درستی به جای معیار اولیه دقت، کاربرد وسیع‌تری در دنیای امروز یادگیری ماشین پیدا کرده است [۱۰].



در اغلب موارد، این دو معیار با هم رشد و حرکت نمی‌کنند. گاهی درستی مدل با الگوریتم‌های دقیق‌تر بالا برده می‌شود، یعنی آنهایی که مثبت اعلام می‌شود، اغلب درست هستند. موارد نادرست مثبت بسیار کم هستند یعنی صحت الگوریتم بسیار بالاست اما ممکن است جنبه یا ویژگی خاصی از داده‌ها در نظر گرفته نشده باشد و تعداد کل نمونه‌های مثبت، بسیار بیشتر از نمونه‌های تشخیص داده شده توسط الگوریتم باشد. به عبارت دیگر سیستم بازخوانی بسیار پایینی داشته باشد.



شکل ۴- فرآیند الگوریتم انتخاب بهینه ویژگی های داده های ورودی

بالاتری را نشان می دهد. به طور مثال الگوریتمی که فارغ از وضعیت واقعی سازه همه حالات را معیوب تشخیص دهد. از این رو بایستی از معیاری مرکب از این دو معیار برای سنجش

از طرفی ممکن است الگوریتم تشخیصی ساده تر شود تا تعداد مثبت های تشخیصی بالاتر برود، در این صورت میزان اشتباهات زیاده تر شده، درستی الگوریتم عدد پایین تر و بازخوانی آن، عدد



شکل ۵- سازه پنج مارک گروه پایش سلامت سازه IASC-ASCE [۲۸]

سازه برای تحریک سازه استفاده می‌شود.

پلان سازه ۲/۵×۲/۵ مترمربع بوده و ارتفاع آن ۳/۷ متر است. اعضای سازه فولاد گرم نورد شده ۳۰۰W با تنش تسلیم ۳۰۰ مگاپاسکال هستند. تحریک سازه به صورت بار باد است که در جهت y به سقف‌های هر طبقه وارد می‌شود. برای شبیه سازی بار باد از اختلال گوسی فیلتر شده استفاده می‌شود. حسگرها روی ستون وسط هر وجه سازه در هر طبقه نصب شده‌اند. بنابراین در مجموع این سازه دارای ۱۶ حسگر برای ثبت سیگنال پاسخ شتاب سازه است.

برای صحت‌سنجی روش پیشنهادی در زمینه عیب‌یابی این سازه، ابتدا بایستی سناریوهای مختلف برای آن ایجاد شود. بدین منظور خرابی به صورت حذف بادبندهای جهت y سازه شبیه‌سازی می‌شود. شدت خرابی به صورت حذف ۴، ۳، ۲ و ۱ بادبند مدل می‌شود. به علاوه فرض می‌شود خرابی محدود به ۱، ۲، ۳ و ۴ طبقه از این سازه باشد. به عبارت دیگر اگر خرابی فقط به یک طبقه از این سازه محدود باشد، به ازای هر طبقه، ۴ سناریوی مختلف خرابی، و به ازای هر یک این طبقات ۴ حالت مختلف حذف بادبندها خواهیم داشت، و در نتیجه ۱۶ سناریوی خرابی برای کل سازه ایجاد می‌شود. در حالت کلی، تمام سناریوهای مختلف خرابی برای این سازه عبارت


الگوریتم‌های دسته‌بندی استفاده کرد. بدین منظور در ادبیات علم داده از میانگین هارمونیک شاخص‌های صحت و بازخوانی با عنوان امتیاز اف بدین منظور استفاده می‌شود:

$$F1-Score = \frac{2}{\frac{1}{Recall} + \frac{1}{Precision}} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (18)$$


۹- مثال‌های عددی

۹-۱- سازه پنج مارک گروه پایش سلامت سازه IASC-ASCE


در سال ۱۹۹۹ در دوازدهمین کنفرانس مهندسی مکانیک [۲۸] برای به وجود آوردن بستر مناسب برای مقایسه انواع روش‌های عیب‌یابی یک سازه پنج مارک توسط گروه پایش سلامت سازه IASC-ASCE مدنظر قرار گرفت. این سازه فلزی دارای ۴ طبقه و دو دهانه است که مدل مقیاس شده آن در دانشگاه بریتیش کلمبیا ساخته شده است. شکل نمادین و مدل با مقیاس ۱/۳ این سازه در شکل (۵) نشان داده شده است. مدل عددی این سازه دارای دو حالت ۱۲ درجه آزادی و ۱۲۰ درجه آزادی است که در این پژوهش از حالت ۱۲ درجه آزادی استفاده شده است. خرابی با حذف بادبندها و یا شل کردن پیچ‌ها شبیه‌سازی می‌شود. از یک ارتعاشگر الکترونیکی نصب شده روی پشت بام




(ب)



(الف)



(د)



(ج)

شکل ۶- پاسخ‌های شتاب ثبت شده: (الف) حذف چهار بادبند در طبقه همکف (گره ۴)، (ب) حذف سه بادبند از طبقه همکف و اول (گره ۶)، (ج) حذف دو بادبند در طبقات همکف و اول و دوم (گره ۸) و (د) حذف یک بادبند از طبقات همکف، اول، دوم و سوم (گره ۲)

است از:

۱- خرابی محدود به یک طبقه از سازه $4 \times 4 = 16$

۲- خرابی در دو طبقه از سازه $4 \times 6 = 24$

۳- خرابی در سه طبقه از سازه $4 \times 4 = 16$


۴- خرابی در ۴ طبقه از سازه $1 \times 4 = 4$

اعداد شده که نشان‌دهنده ویژگی‌های آن سیگنال هستند. شکل (۶) نشان‌دهنده توانایی آنالیز موجک به‌عنوان شاخصی برای عیب‌یابی است. به‌عنوان مثال برای حالتی که چهار بادبند طبقه اول حذف شود حسگر روی گره ۴ پاسخ شتاب نشان‌داده را ثبت می‌کند (شکل ۶-الف). پس از اعمال آنالیز موجک و به دست آوردن انرژی بسته‌های موجکی، نتایج حسگر به شکل (۷-الف) تبدیل می‌شوند. همان‌طور که در شکل مشخص است نتایج برای این حالت خرابی با سایر حالات خرابی متفاوت است و در نتیجه می‌توان از آنها به‌عنوان ورودی الگوریتم WWLS-SVM استفاده کرد.


مشخصات سیگنال ارتعاشی ثبت شده توسط هر حسگر با بقیه حسگرها با روش ترکیب داده‌ها، ترکیب شده و بردار ورودی به الگوریتم را تشکیل می‌دهند. بردار خروجی نیز مکان و شدت خرابی در هر عضو است. برای حالت تجزیه موجکی از تابع پایه Battle-Lemarie استفاده شده و موج سه سطح تجزیه می‌شود. انرژی بسته‌های موجکی بر اساس بزرگی مرتب شده می‌شود و از بین آنها ۸ جز اول که بیشترین مقدار و بیشترین حساسیت نسبت به خرابی را دارند انتخاب می‌شود

بنابراین با در نظر گرفتن حالتی که سازه سالم است در مجموع ۶۱ سناریوی مختلف خرابی برای این سازه ایجاد می‌شود. با در نظر گرفتن اختلال ناشی از محیط و عدم دقت حسگرها، اختلال مصنوعی با شدت‌های مختلف به پاسخ ارتعاشی ثبت شده توسط حسگرها اعمال می‌شود. در این پژوهش نسبت جذر میانگین مربعات RMS ^{۵۱} بین اختلال و سیگنال اصلی برابر با ۱۰، ۲۰ و ۳۰ درصد است. این سه شدت اختلال به هر یک از ۶۱ سناریوی خرابی ایجاد شده اعمال می‌شود و در نتیجه کل مجموعه داده‌ها به ۱۸۳ حالت می‌رسد. از داده‌های با اختلال ۱۰ و ۲۰ درصد به‌عنوان داده آموزشی و از داده‌های با اختلال ۳۰ درصد به‌عنوان داده‌های تست استفاده می‌شود.


پس از ثبت پاسخ ارتعاشی با استفاده از خصوصیات آماری و یا آنالیز موجک، هر پاسخ ارتعاشی تبدیل به مجموعه‌ای از




(ب)



(الف)



(د)



(ج)

شکل ۷- انرژی نسبی موجک بسته‌ای: الف) حذف چهار بادبند در طبقه همکف (گره ۴)، ب) حذف سه بادبند از طبقه همکف و اول (گره ۶)، ج) حذف دو بادبند در طبقات همکف و اول و دوم (گره ۸) و د) حذف یک بادبند از طبقات همکف، اول، دوم و سوم (گره ۲)

است. با توجه به نتایج حاصل، استفاده از آنالیز موجک دقت بالاتری در عیب‌یابی سازه‌ها دارد و این ناشی از قدرت آن در ایجاد تحلیل دقیق موج و استخراج ویژگی‌های اساسی هر سیگنال ارتعاشی است. به عبارت دیگر آنالیز موجک، بهتر از خصوصیات آماری هر موج توانایی تشخیص و بازنمود تغییرات ایجاد شده در پاسخ ارتعاشی به‌ازای سناریوهای مختلف خرابی را دارد. از این‌رو از داده‌های ایجاد شده توسط آنالیز موجک برای سایر تحلیل‌های این مثال استفاده می‌شود. در جدول (۲) معیارهای آماری دو مدل جایگزین پیشنهادی نیز با یکدیگر مقایسه شده‌اند. بر اساس تعریف بیان شده از آماره‌های دقت، صحت، بازخوانی و امتیاز اف طبق بخش ۸، الگوریتم WWLS-SVM در اکثر حالات کارایی بالاتری در کلاسه‌بندی داده‌های مربوط به سازه پنج مارک چهار طبقه نسبت به الگوریتم RBFNN دارد. با این حال طبق جدول (۲)، در صورتی که از خصوصیات آماری پاسخ شتاب سازه به‌عنوان ورودی الگوریتم کلاسه‌بندی استفاده شود، کارایی الگوریتم RBFNN بالاتر از WWLS-SVM خواهد بود.

قابل توجه است که بالاترین دقت کسب شده توسط

[۱۴]. از این‌رو هر پاسخ شتاب به یک بردار ۸ بعدی تبدیل می‌شود. برای حالتی که از خصوصیات آماری موج (جدول ۱) استفاده می‌شود، هر سیگنال به یک بردار ۶ بعدی تبدیل می‌شود. از آنجایی که در این سازه ۱۶ حسگر نصب شده است ترکیب این بردارها برای تمام حسگرهای روی سازه در حالتی که از انرژی بسته‌های موجکی استفاده شود ایجاد یک بردار ۱۲۸ بعدی به‌ازای هر حالت خرابی می‌کند. بردار خروجی ۵ بعدی بوده که ۴ آرایه اول نشان‌دهنده طبقه‌ای که خرابی در آن اتفاق افتاده است و آرایه پنجم نشان‌دهنده تعداد بادبندهای حذف شده است.

در ابتدا، بدون استفاده از روش پیشنهادی کاهش ابعاد ویژگی‌ها، تأثیر انتخاب ویژگی‌های حاصل از WPRE و یا خصوصیات آماری به‌عنوان ورودی الگوریتم کلاسه‌بندی مورد بررسی قرار می‌گیرد. به‌منظور مقایسه الگوریتم WWLS-SVM با شبکه‌های عصبی از الگوریتم RBFNN با روندی مشابه استفاده می‌شود.

در جدول (۲) نتایج مقایسه‌ای بین آنالیز موجک و خصوصیات آماری به‌عنوان ورودی الگوریتم صورت گرفته

جدول ۲- مقایسه بین آنالیز مویک و خصوصیات آماری

آنالیز مویک					خصوصیات آماری				الگوریتم کلاسه بندی
زمان آنالیز	امتیاز اف	بازخوانی	صحت	دقت	زمان آنالیز	امتیاز اف	بازخوانی	صحت	
۳۱	۸۸/۲	۰/۸۶۸	۰/۸۶۱	۸۷	۲۸	۸۳/۵۱	۰/۸۱۳	۰/۸۲۲	۸۳/۱۲
شبکه عصبی تغذیه شعاعی									
۲۷	۹۰/۰۲	۰/۸۹	۰/۸۸۲	۸۹/۲۱	۲۲	۸۲/۱	۰/۸۰۳	۰/۸۱۳	۸۱/۱
ماشین بردار پشتیبان مدل قاعده مرعات مویک وزن دار									

سایر پارامترهای تنظیمی باقی الگوریتم‌ها طبق حالت استاندارد توصیه شده در مقالات مرجع تنظیم شده است. برای بررسی دوام و پایداری روش پیشنهادی و به منظور حذف اثرات تصادفی بودن، هریک از مسائل به تعداد ۲۵ دفعه به صورت مستقل توسط هریک از الگوریتم‌ها مورد ارزیابی قرار گرفته و نتایج آماری حاصله از قبیل میانگین و انحراف معیار و بهترین پاسخ به دست آمده در جدول (۳) نشان داده شده است. با توجه به نتایج حاصل، الگوریتم پیشنهادی هارمونی-پرنندگان سرعت و راندمان بهتری نسبت به الگوریتم‌های اجتماع پرنندگان و جستجوی هارمونی دارد زیرا این الگوریتم خصوصیات مثبت دو الگوریتم گفته شده را دارد. به دلیل انتخاب جمعیت اولیه به صورت نخه، میانگین دقت بالاتر و انحراف معیار پایین تری نسبت به سایر الگوریتم‌ها دارد.

جدول‌های (۴) و (۵) نشانگر دقت روش‌های WWLS-SVM و RBFNN در ترکیب با روش انتخاب زیر مجموعه ویژگی‌ها با الگوریتم فراکاوشی پیشنهادی است. با توجه به جدول (۵) انتخاب پنج ویژگی ۱۱، ۱۶، ۳۲، ۶۰ و ۸۰ موجب بالاترین دقت عیب‌یابی در صورت استفاده از الگوریتم WWLS-SVM می‌شوند. این پنج ویژگی از بین ۱۲۸ ویژگی استخراج شده انتخاب شده است. دقت

الگوریتم‌ها برابر ۸۹/۲۱ است. در این بخش، به منظور بهبود دقت شناسایی وضعیت سازه، از روند پیشنهادی به منظور انتخاب ویژگی‌های مؤثر و حذف ویژگی‌های تکراری و کم اثر استفاده می‌شود. نگاشت داده‌ها از فضای ۱۲۸ بعدی ورودی به فضای ۵ بعدی خروجی فرایندی زمان‌بر بوده و دقت الگوریتم را کاهش می‌دهد، از این رو با استفاده از الگوریتم هارمونی-پرنندگان ویژگی‌های منتخب از بین ۱۲۸ ویژگی انتخاب می‌شود و در ادامه فقط از این ویژگی‌ها به عنوان ورودی WWLS-SVM استفاده می‌شود.

در جدول (۳) مقایسه‌ای بین الگوریتم بهینه‌سازی پیشنهاد شده در این پژوهش و چهار الگوریتم پرکاربرد در حوزه شناسایی اعضای معیوب سازه، انجام شده است. این الگوریتم‌ها شامل الگوریتم خفاش [۲۹]، برخورد ذرات [۳۰]، اجتماع پرنندگان و هارمونی است.

پارامترهای تنظیمی الگوریتم هارمونی پرنندگان پیشنهادی به شرح زیر اختصاص داده می‌شود: حافظه هارمونی (HM)=۴۰، سرعت بررسی حافظه هارمونی (HMCR)=۰/۹، سرعت تنظیم قطعات (PAR)=۰/۵ و تعداد پرنندگان=۲۰. تعداد حلقه‌های تکرار در تمامی الگوریتم‌ها برابر با ۱۰۰۰ منظور شده است.

جدول ۳- مقایسه بین الگوریتم‌های بهینه‌ساز

الگوریتم بهینه‌ساز	شماره ویژگی‌های ورودی انتخاب شده	بهترین دقت میانگین دقت	ماشین بردار پشتیبان حداقل مربعات موجکی وزن‌دار	
			پارامترهای کرنل	بهترین دقت
			پارامترهای کرنل ماشین بردار پشتیبان حداقل مربعات موجکی وزن‌دار γ, α, q, p	میانگین دقت
				انحراف معیار
الگوریتم خفاش	۱۰,۱۱,۱۷,۴۹,۷۲, ۸۰,۹۲,۱۱۰	۹۷ ۹۲ ۰/۰۲	۱۱,۱۵,۲۲,۴۹,۷۲, ۸۰,۹۱	۹۸
				۹۴/۱
				۰/۰۱۲
الگوریتم برخورد ذرات	۱۱,۱۵,۱۹, ۲۲,۴۲,۶۲,۷۹,۸۸	۹۸/۲ ۹۳ ۰/۰۲۱	۱۱,۱۶, ۱۹ ,۴۰,۶۲,۸۸	۹۹
				۹۲/۹
				۰/۰۳۱
اجتماع پرندگان	۱۰,۲۶,۳۳,۴۹,۷۲, ۷۹,۸۴,۹۴	۹۸ ۹۲ ۰/۱۲	۱۰,۲۳,۵۶,۷۶,۷۷, ۷۹,۸۰	۹۸/۶۸
				۹۳
				۰/۱۱
جستجوی هارمونی	۱۲,۳۳,۳۷,۷۹,۸۰	۹۷/۶۶ ۹۰ ۰/۱۵	۵,۱۰,۱۷,۳۱,۴۱, ۵۳,۷۹,۸۴,۹۴	۹۸/۲
				۹۱/۰۲
				۰/۱۲۱
هارمونی-پرندگان	۱۱,۱۵,۲۰,۳۵,۶۰, ۸۰	۹۹ ۹۵ ۰/۰۰۶۹	۱۱,۱۶,۳۲,۶۰,۸۰	۱۰۰
				۹۵/۸
				۰/۰۰۸

جدول ۴- نتایج شناسایی شدت و مکان خرابی با استفاده از الگوریتم هارمونی-پرندگان و ماشین بردار پشتیبان حداقل مربعات موجکی وزن‌دار

شماره ویژگی‌های ورودی انتخاب شده	پارامتر γ	پارامتر α	پارامتر q	پارامتر P	دقت عیب‌یابی (%)
۵,۱۰,۱۱,۱۶,۱۷,۲۲,۲۸,۳۱,۴۱,۵۳,۶۰, ۷۲,۷۹,۸۴,۹۴	۵/۱۱	۰/۲۸	۲	۰/۴۵	۹۸
۱۰,۷۶,۷۷,۷۹,۸۰	۵/۰۱	۰/۳۲	۲	۰/۵۰	۹۶
۱۱,۱۶,۳۲,۶۰,۸۰	۵/۱۵	۰/۳۳	۲	۰/۵۲	۱۰۰
۲۸,۳۲,۵۲,۸۰	۵/۲۲	۰/۳۳	۲	۰/۴۸	۹۶

ویژگی‌های شماره ۱۱، ۶۰ و ۸۰ در بهترین دقت هر دو الگوریتم مشترک هستند و نشان‌دهنده این است که انتخاب این ویژگی تأثیر

۹۹ درصدی در شبکه عصبی RBFNN نیز به‌ازای استفاده از ویژگی‌های ۱۱، ۱۵، ۲۰، ۲۵، ۶۰ و ۸۰ حاصل می‌شود. از این‌رو

جدول ۵- نتایج شناسایی شدت و مکان خرابی با استفاده از الگوریتم

هارمونی-پرندگان و شبکه عصبی تابع پایه شعاعی

شماره ویژگی های ورودی انتخاب شده	دقت عیب یابی (%)
۱۰,۲۶,۳۳,۴۹,۷۲,۷۹,۸۴,۹۴	۸۵
۱۲,۳۳,۳۷,۷۹,۸۰	۹۵
۱۱,۱۵,۲۰,۳۵,۶۰,۸۰	۹۹
۱۳,۳۲,۵۴,۹۱	۹۰

جدول ۶- مقایسه استفاده از کل ویژگی های داده های ورودی در مقابل ویژگی های انتخاب شده

مدل جایگزین	ویژگی های انتخاب شده	درصد کاهش ابعاد داده (%)	پارامترهای کرنل پارامترهای کرنل ماشین بردار پشتیبان حداقل مربعات موجکی وزن دار γ, α, q, ρ	دقت عیب یابی (%)
ماشین بردار پشتیبان حداقل مربعات موجکی وزن دار	همه	۰	۴/۳۲,۰/۳۳,۲,۰/۴۸	۸۹/۲۱
شبکه عصبی تابع پایه شعاعی	همه	۰	-	۸۷
ماشین بردار پشتیبان حداقل مربعات موجکی وزن دار	۱۱,۱۶,۳۲,۶۰,۸۰	۹۴/۷۹	۵/۱۵,۰/۳۳,۲,۰/۵۲	۱۰۰
شبکه عصبی تابع پایه شعاعی	۱۱,۱۵,۲۰,۳۵,۶۰,۸۰	۹۳/۷۵	-	۹۹

قابل ملاحظه ای در دقت روند پیشنهادی دارند.

WWLS-SVM از RBFNN بیشتر است.

در جدول (۶) مقایسه ای بین حالتی که از کل ویژگی های داده های ورودی به عنوان ورودی الگوریتم استفاده شود و حالتی که ویژگی های داده های ورودی با الگوریتم هارمونی-پرندگان انتخاب شوند صورت گرفته است. در الگوریتم WWLS-SVM استفاده از روش پیشنهاد شده در این پژوهش علاوه بر کاهش ۹۴/۸ درصدی در ابعاد داده ها، موجب افزایش دقت از ۸۹٪/۲۱ به ۱۰۰٪ می شود. از طرف دیگر روند پیشنهادی موجب افزایش دقت الگوریتم RBFNN تا ۹۹٪ درصد شده و کاهش ۹۳٪/۷۵ در ابعاد داده ها را نیز به همراه دارد. به علاوه در اکثر حالات دقت

با استفاده از انتخاب ویژگی ها، دقت هر دو الگوریتم افزایش پیدا می کند. از طرف دیگر، انتخاب مقادیر مناسب برای پارامترهای تنظیمی WWLS-SVM تأثیر قابل توجهی روی دقت این الگوریتم دارد. از این رو استفاده از الگوریتم هارمونی-پرندگان برای انتخاب مقادیر بهینه این پارامترهای تنظیمی سبب افزایش کارایی این الگوریتم شده است. در نهایت برای نشان دادن توانایی روند پیشنهادی در عیب یابی سازه ها، بعد از آموزش الگوریتم های WWLS-SVM و RBFNN، این دو الگوریتم به ازای دو حالت خرابی جدول (۷) مورد سنجش قرار می گیرند.

جدول ۷- عضوهای آسیب دیده و میزان آسیب

حالت ۲	حالت ۱
حذف ۲ بادبند از هر کدام از طبقات ۳ و ۴ (کلاس ۳۸)	حذف ۳ بادبند از طبقه اول (کلاس ۳)

جدول ۸- مقایسه الگوریتم هوش مصنوعی درون یاب

کلاس صحیح	خروجی مدل ماشین بردار پشتیبان حداقل مربعات موجکی وزن دار	خروجی مدل شبکه عصبی تابع پایه شعاعی
حالت خرابی ۱	۳	۳
حالت خرابی ۲	۳۸	۳۹

جدول (۸) مقدار خروجی الگوریتم را به ازای دو حالت خرابی جدول (۷) نشان می دهد. بنابر نتایج جدول (۸)، الگوریتم پیشنهادی مبتنی بر WWLS-SVM در هر دو مورد بدون خطا مکان خرابی را تشخیص داده است که نشان دهنده توانایی بالای آن در کلاسه بندی کردن و فرا گرفتن روند عیب یابی است.


۹-۲- سازه فضاکار ۱۲۰ عضوی

سازه فضاکار ۱۲۰ المانی نشان داده شده در شکل (۸) توسط کاوه و تلاتاھری [۳۱] برای بهینه سازی اندازه و پیکربندی مورد بررسی قرار گرفته است. قطر گنبد $31/78$ متر و ارتفاع آن ۷ متر است. جنس آن فولاد ضد زنگ با مدول الاستیسیته ۲۱۰ مگاپاسکال و چگالی جرمی $7981/810$ کیلوگرم بر مترمکعب بوده و قطر خارجی اعضاء $0/2$ متر و ضخامت آنها $0/06$ متر است.

از نرم افزار OpenSees [۳۲] برای تحلیل سازه به ازای خرابی های مختلف تحت ارتعاش جزئی^{۵۲} استفاده می شود. ارتعاش به صورت اختلال گسسته در جهت قائم مدل می شود. گام های ثبت نتایج $0/05$ ثانیه و کل زمان ثبت نتایج ۳۰۰ ثانیه است. گنبد به علت قریبه بودن به چهار ناحیه تقسیم می شود. ۹ حسگر ثبت شتاب روی گنبد سوار می شود که محل آنها در شکل (۸) نشان داده شده است. مکان حسگرها بر این اساس

انتخاب شده است که فاصله سایر گره ها در هر ناحیه از گنبد تا گره ای که حسگر روی آن نصب است، کمینه باشد. برای عیب یابی چهار ناحیه مستقل از هم در نظر گرفته می شود. برای مدل سازی آسیب از روش های مختلفی مانند کاهش سطح مقطع، کاهش مدول الاستیسیته و یا کاهش سختی المان ها استفاده می شود [۱]. در اکثر تحقیقات انجام شده در مورد عیب یابی سازه های فضاکار عیب به صورت کاهش مدول الاستیسیته در نظر گرفته می شود [۴ و ۱۲] از این رو در این مثال نیز، آسیب به صورت کاهش در مدول الاستیسیته المان ها و بدون هیچ تغییری در جرم سازه مدل شده است. بدین منظور کاهش مدول الاستیسیته با درصد های ۵، ۱۰ و ۱۵ به عنوان شدت خرابی در نظر گرفته می شود. فقط ناحیه (۱) در نظر گرفته می شود چون روند آنالیز برای سایر نواحی مشابه است.


در ناحیه (۱)، یک حسگر روی گره وسط و ۳ حسگر گره های گوشه ناحیه وجود دارد. خرابی به ازای سه شدت گفته شده برای اعضای اصلی شبیه سازی می شود. در این بخش ۱۸ مکان خرابی در نظر گرفته می شود که شامل دو حالت با دو عضو معیوب نیز می شوند. در نتیجه تعداد سناریوهای خرابی برابر با ۵۴ می شود. ارتعاش جزئی به سازه اعمال شده و پاسخ ارتعاشی در گره هایی که دارای حسگر هستند، ثبت می شود. پس از ثبت پاسخ ارتعاشی هر گره با استفاده از خصوصیات آماری و یا آنالیز موجک، ویژگی های هر پاسخ ارتعاشی به




شکل ۸- گنبد فضاکار ۱۲ عضوی [۲۹]

مشابه با مثال اول ویژگی‌های سیگنال ارتعاشی ثبت شده توسط هر حسگر با بقیه حسگرها با روش ترکیب داده‌ها ترکیب شده و بردار ورودی به الگوریتم را تشکیل می‌دهند. بردار خروجی نیز مکان و شدت خرابی در هر عضو است. برای حالت تجزیه موجکی از تابع پایه Battle-Lemarie استفاده شده و موج سه سطح تجزیه می‌شود و هر سیگنال به یک بردار ۸ بعدی تبدیل می‌شود. برای حالتی که از خصوصیات آماری موج استفاده می‌شود هر سیگنال به یک بردار ۶ بعدی تبدیل می‌شود. به منظور در نظر گرفتن اختلال ناشی از محیط و عدم دقت

طریقی مشابه با مثال اول استخراج می‌شود. شکل (۱۰) نشان‌دهنده ویژگی‌های استخراج شده به وسیله آنالیز موجک است. به عنوان مثال برای حالتی که عضو ۴ به اندازه ۱۰ درصد معیوب باشد حسگر یک پاسخ شکل (۹-الف) را ثبت می‌کند. پس از اعمال آنالیز موجک و به دست آوردن انرژی بسته‌های موجکی، نتایج حسگر به شکل (۱۰-الف) تبدیل می‌شوند. همان‌طور که در این شکل مشخص است نتایج برای این حالت خرابی با سایر حالات خرابی متفاوت است و در نتیجه می‌توان از آنها به عنوان ورودی الگوریتم WWLS-SVM استفاده کرد.




(ب)




(الف)

شکل ۹- پاسخ‌های شتاب ثبت شده: الف: خرابی ۱۰ درصدی در عضو ۴ و ب) خرابی ۲۰ درصدی در عضو ۱



(ب)



(الف)

شکل ۱۰- انرژی نسبی موجک بسته ای: الف) خرابی ۱۰ درصدی در عضو ۴ و ب) خرابی ۲۰ درصدی در عضو ۱

شرایط ثابت دقت عیب‌یابی هر دو مدل جایگزین پیشنهاد شده در این پژوهش در صورت استفاده از ویژگی‌های مستخرج WPRE بالاتر از دقت عیب‌یابی با استفاده از ویژگی‌های مستخرج از خصوصیات آماری پاسخ شتاب خواهد بود. به عبارت دیگر WPRE یک ابزار سودمند به منظور بررسی تغییرات ایجاد شده در پاسخ شتاب در اثر ایجاد خرابی در سازه است. به علاوه در مقایسه با خصوصیات آماری، WPRE حساسیت بیشتری نسبت به ایجاد خرابی در سازه دارد و می‌توان از آن برای کاهش ابعاد مسائل کلان داده مطرح شده در حوزه عیب‌یابی سازه‌ها و استخراج ویژگی‌ها استفاده کرد. مقایسه بین آماره‌های دو

حسگرها، اختلال مصنوعی با شدت‌های مختلف به پاسخ ارتعاشی ثبت شده توسط حسگرها اعمال می‌شود. در این مثال نیز، نسبت جذر میانگین مربعات بین اختلال و سیگنال اصلی برابر با ۱۰، ۲۰ و ۳۰ درصد در نظر گرفته می‌شود. این سه شدت اختلال به هر یک از ۵۴ سناریوی خرابی ایجاد شده اعمال می‌شود و در نتیجه کل مجموعه داده‌ها به ۱۶۳ حالت می‌رسد. از داده‌های با اختلال ۱۰ و ۲۰ درصد به عنوان داده آموزشی و از داده‌های با اختلال ۳۰ درصد به عنوان داده‌های تست استفاده می‌شود. در جدول (۹) نتایج مقایسه‌ای بین آنالیز موجک و خصوصیات آماری به عنوان ورودی الگوریتم ارائه شده است. نتایج بیانگر آن است که تحت یک

جدول ۹- مقایسه بین آنالیز مویک و خصوصیات آماری

کلاس بندی	الگوریتم	خصوصیات آماری					آنالیز مویک				
		دقت	صحت	بازخوانی	امتیاز اف	زمان آنالیز	دقت	صحت	بازخوانی	امتیاز اف	زمان آنالیز
شبکه عصبی	۸۵/۱	۰/۸۴۹	۰/۸۵۱	۸۵/۸	۳۲	۸۴/۲	۰/۸۳۸	۰/۸۴	۸۴/۸	۲۰	
حداقل مربعات	۸۸	۰/۸۸۱	۰/۸۷۹	۸۸/۲	۳۰	۹۱/۵۴	۰/۹۱۸	۰/۹۲	۹۲/۳۴	۲۳	
وزندار											
ماشین بردار پشتیبان											

به عنوان انتخاب گر موجب افزایش سرعت و دقت عیب یابی می شود.

با توجه به جدول (۱۱) در صورت استفاده از الگوریتم WWLS-SVM انتخاب خصوصیات شماره ۳، ۵، ۹، ۱۱، ۲۷ و ۳۲ علاوه بر کاهش ۲۵/۸۱٪ ابعاد داده ها، دقت مدل جایگزین پیشنهادی را به ۱۰۰ می رساند. همچنین استفاده از روند کاهش ابعاد داده ها دقت الگوریتم RBFNN را نیز از ۸۸٪ به ۱۰۰٪ افزایش می دهد. در نهایت برای نشان دادن توانایی روند پیشنهادی در عیب یابی سازه ها، بعد از آموزش الگوریتم های WWLS-SVM و RBFNN، آنها را به ازای دو حالت خرابی جدول (۱۲) مورد سنجش قرار می گیرند.

جدول (۱۳) مقدار خروجی الگوریتم را به ازای دو حالت خرابی جدول نشان می دهد. بنابر نتایج جدول (۱۳)، الگوریتم پیشنهادی مبتنی بر WWLS-SVM در هر دو مورد بدون خطا مکان خرابی را تشخیص داده است که نشان دهنده دقت بالای مدل جایگزین مبتنی بر آن در شناسایی خرابی ها است.

۱۰- نتیجه گیری

سرمایه گذاری در بحث پایش سلامت سازه ها در طولانی مدت وقتی سودمند می شود که کلان داده هایی که از حسگرها استخراج

الگوریتم هوش مصنوعی استفاده شده در این پژوهش بیانگر آن است که اگر از الگوریتم WWLS-SVM با هسته تعریف شده در بخش (۳) به منظور مشخص کردن وضعیت سازه استفاده شود، دقت، صحت، بازخوانی و امتیاز اف بالاتری حاصل خواهد شد.

در جدول (۱۰) مقایسه ای بین الگوریتم های بهینه ساز مطرح شده در این پژوهش صورت گرفته است. پارامترهای تنظیمی الگوریتم ها مشابه مثال اول منظور شده است. نتایج نشان دهنده کارایی بالای الگوریتم پیشنهادی است. به عبارت دیگر ترکیب الگوریتم اجتماع پرندگان با الگوریتم جستجوی هارمونی موجب می شود که جستجوی کلی الگوریتم جستجوی هارمونی کارایی بهتری داشته باشد و الگوریتم سریعتر به فضای نزدیک پاسخ بهینه برسد. این امر سبب می شود جستجوی محلی در اطراف جواب بهینه کلی نیز با دقت بالاتری صورت پذیرد.

در جدول (۱۱) مقایسه ای بین حالتی که از کل ویژگی های داده های ورودی به عنوان ورودی الگوریتم استفاده شود و حالتی که ویژگی های داده های ورودی با الگوریتم هارمونی-پرندگان انتخاب شوند صورت گرفته است. با توجه به اینکه با انتخاب ویژگی های ورودی، ابعاد ماتریس ورودی الگوریتم کاهش پیدا می کند و همچنین ویژگی هایی که تأثیر زیادی در نتیجه الگوریتم ندارند حذف می شوند، استفاده از هارمونی-پرندگان

جدول ۱۰- مقایسه بین الگوریتم‌های بهینه ساز

شبکه عصبی تابع پایه شعاعی			ماشین بردار پشتیبان حداقل مربعات موجکی وزن‌دار		
الگوریتم	شماره ویژگی‌ها	بهترین دقت	شماره ویژگی‌ها	پارامترهای کرنل	بهترین دقت
بهینه‌سازی	ورودی انتخاب شده	میانگین دقت	ورودی انتخاب شده	ماشین بردار پشتیبان حداقل مربعات موجکی	میانگین دقت
		انحراف معیار		وزن‌دار γ, α, q, p	انحراف معیار
الگوریتم	۳,۹,۱۰,۱۲,۱۴,۱۹,۱۹	۸۸	۱۱,۱۴,۲۰,۲۱,۳۲	-	۹۰
خفاش	۲۵,۲۷,۳۲	۸۲	۹,۱۰	۴/۱۰, ۰/۵۲, ۲, ۰/۴۰	۸۷
		۰/۲۸			۰/۲۰
الگوریتم		۹۲			۹۵/۱
برخورد	۸,۱۰,۱۸,۲۰,۲۲,۳۱	۸۸	۳,۱۵,۲۲,۲۸,۲۹,۳۲	۴/۱۵, ۰/۵۲, ۲, ۰/۴۵	۹۰/۲
ذرات		۰/۰۸			۰/۰۷۱
اجتماع		۸۹/۲			۹۰
پرندگان	۱۶,۲۲,۳۱,۳۲	۸۱	۹,۱۱,۱۴,۱۸,۲۱,۲۹	۴/۱۰, ۰/۵۱, ۲, ۰/۳۵	۸۸
		۰/۴۵			۰/۰۴۱
جستجوی		۹۴			۹۶/۱
هارمونی	۸,۱۹,۲۲,۲۳,۳۲	۹۰	۳,۷,۱۸,۲۶,۳۲	۴/۲۲, ۰/۵۳, ۲, ۰/۴۵	۹۲
		۰/۰۱۲			۰/۰۱۸
هارمونی -	۱۵,۱۹,۲۲,۳۱,۳۲	۱۰۰	۳,۵,۹,۱۱,۲۷,۳۲	۴/۱۲, ۰/۵۳, ۲, ۰/۴۴	۱۰۰
پرندگان	۸,۱۱				

جدول ۱۱- مقایسه استفاده از کل ویژگی‌های داده‌های ورودی در مقابل ویژگی‌های انتخاب شده

مدل جایگزین	ویژگی‌های انتخاب شده	درصد کاهش ابعاد داده (%)	پارامترهای کرنل پارامترهای کرنل ماشین بردار پشتیبان حداقل مربعات موجکی وزن‌دار γ, α, q, p	دقت عیب‌یابی (%)
ماشین بردار پشتیبان حداقل مربعات موجکی وزن‌دار	همه	۰	-	۹۱/۵۴
شبکه عصبی تابع پایه شعاعی	همه	۰	-	۸۸
ماشین بردار پشتیبان حداقل مربعات موجکی وزن‌دار	۳,۵,۹,۱۱,۲۷,۳۲	۸۱/۲۵	۴/۱۲, ۰/۵۳, ۲, ۰/۴۴	۱۰۰
شبکه عصبی تابع پایه شعاعی	۸,۱۱,۱۵,۱۹,۲۲,۳۱,۳۲	۷۸/۱۳	۴/۳۱, ۰/۵۱, ۲, ۰/۴۳	۱۰۰

می‌شود قابل تحلیل و بررسی باشد. از این‌رو سیستم‌های حسگری جدید، در کنار روش‌های پیشرفته و مؤثر تحلیل و تفسیر داده‌ها، ابزاری سودمند در اختیار صاحبان زیرساخت‌های عمرانی قرار خواهد داد. در این پژوهش به‌منظور کاهش حجم

جدول ۱۲- عضوهای آسیب دیده و میزان آسیب

حالت ۱	حالت ۲
خرابی عضو ۴ به اندازه ۱۰ درصد (کلاس ۵)	خرابی عضو ۴ به اندازه ۲۰ (کلاس ۱۵)

جدول ۱۳- مقایسه الگوریتم هوش مصنوعی درون یاب

خروجی مدل شبکه عصبی تابع پایه شعاعی	خروجی مدل ماشین بردار پشتیبان	کلاس
حد اقل مربعات موجکی وزن دار	صحيح	
۵	۵	حالت خرابی ۱
۱۴	۱۵	حالت خرابی ۲

الگوریتم هارمونی-پرنندگان هم برای انتخاب مقادیر بهینه پارامترهای تنظیمی WWLS-SVM و هم انتخاب بهینه ویژگی های داده های ورودی استفاده شد. با توجه به نتایج حاصل، الگوریتم پیشنهادی هارمونی-پرنندگان کارایی و راندمان بهتری نسبت به سایر الگوریتم های مطرح شده دارد. از طرف دیگر به مقایسه تأثیر نوع ویژگی های استخراج شده از داده های ورودی شامل خصوصیات آماری پاسخ شتاب سازه و انرژی نسبی بسته های موجکی (WPRE) پاسخ شتاب سازه، بر دقت الگوریتم WWLS-SVM پرداخته شد. نتایج بیانگر آن است که استفاده از آنالیز موجک دقت بالاتری در عیب یابی سازه ها دارد و این ناشی از قدرت آن در ایجاد تحلیل دقیق موج و استخراج ویژگی های اساسی هر سیگنال ارتعاشی است. به عبارت دیگر آنالیز موجک، بهتر از خصوصیات آماری هر موج، تغییرات ایجاد شده در پاسخ ارتعاشی به ازای سناریوهای مختلف خرابی را نشان می دهد.

محاسبات و افزایش تطبیق پذیری روش پیشنهادی در برخورد با کلان داده ها، تعداد ویژگی های ماتریس داده ها به روش هوشمند انتخاب می شود. مقایسه ای بین حالتی که از کل ویژگی های داده های ورودی به عنوان ورودی الگوریتم استفاده شود و حالتی که ویژگی های داده های ورودی با الگوریتم هارمونی-پرنندگان انتخاب شود صورت گرفت. با انتخاب ویژگی ها، ابعاد ماتریس ورودی به الگوریتم کاهش پیدا کرد و ویژگی های بی تأثیر و اضافی حذف شد. از این رو استفاده از الگوریتم هارمونی-پرنندگان به عنوان انتخاب گر موجب افزایش سرعت و دقت فرایند عیب یابی در هر دو سازه بررسی شده در این پژوهش شد. انتخاب بهینه ویژگی های داده های ورودی علاوه بر کاهش بیش از ۹۰ درصدی ابعاد داده ها، دقت هر دو الگوریتم WWLS-SVM و RBFNN را به میزان قابل توجهی افزایش داد. به علاوه الگوریتم ترکیبی تکاملی جدید پیشنهاد شده در این پژوهش با چهار الگوریتم فراکاوشی مطرح دیگر مورد مقایسه قرار گرفت. از

واژه نامه

- | | | |
|---|--------------------------|-------------------------------------|
| 1. correlated | 9. variety | 19. knowledge discovery from data |
| 2. degree of redundancy | 10. heterogeneous | 20. data analytics |
| 3. wavelet weighted least square-support vector machine | 11. velocity | 21. data science |
| 4. radial basis function neural network | 12. variability | 22. vulnerability assessment |
| 5. big data | 13. veracity | 23. principal component analysis |
| 6. volume | 14. value | 24. proper orthogonal decomposition |
| 7. terabytes | 15. statistics | 25. data fusion |
| 8. petabytes | 16. data mining | 26. subset selection algorithm |
| | 17. predictive analytics | 27. hyper-plane |
| | 18. business analytics | 28. border |

- | | | |
|--|---------------------------------------|-----------------------------|
| 29. nonlinear constrained optimization | 37. harmony memory | 45. timeseries distribution |
| 30. thin plate spline-littlewood paley wavelet | 38. harmony memory consideration rate | 46. data science |
| 31. wavelet packet transform | 39. pitch adjusting rate | 47. accuracy |
| 32. recursive filter-decimation operation | 40. particle swarm optimization | 48. precision |
| 33. modulation | 41. harmony memory size | 49. recall |
| 34. wavelet pocket relative energy | 42. vibration amplitude | 50. f-score |
| 35. fused feature vector | 43. time series distribution | 51. root mean square |
| 36. harmony search algorithm | 44. individual component analysis | 52. ambient vibration |

مراجع

1. Boller, C., Chang, F.K., and Fujino, Y., *Encyclopedia of Structural Health Monitoring*, John Wiley & Sons, 2009.
2. Ghiasi, R., Ghasemi, M. R. and Sohrabi, M. R., "Structural Damage Detection using Frequency Response Function Index and Surrogate Model Based on Optimized Extreme Learning Machine Algorithm," *Journal of Computational Methods In Engineering*, Vol. 36, No. 1, pp. 1-17, 2017 (in persian).
3. Ghodrati Amir, G. and Zare Hosseinzadeh, A., "Damage Identification in Shear Frames via Grey Relation Theory and Static Displacement Estimated by Limited Modal Data," *Journal of Computational Methods in Engineering*, Vol. 34, No. 1, pp. 139-154, 2015 (in persian).
4. Fan, W., and Qiao, P., "Vibration-based Damage Identification Methods: A Review and Comparative Study", *Structural Health Monitoring*, Vol. 10, No. 1, pp. 83-111, 2011.
5. Das, S., Saha, P., and Patro, S. K., "Vibration-based Damage Detection Techniques Used for Health Monitoring of Structures: A Review", *Journal of Civil Structural Health Monitoring*, Vol. 6, pp. 477-507, 2016.
6. Hakim, S. J. S., and Razak, H. A., "Modal Parameters Based Structural Damage Detection Using Artificial Neural Networks-A Review", *Smart Structure and Systems*, Vol. 14, No. 2, pp. 159-189, 2014.
7. Matarazzo, T. J., Shahidi, S. G., Chang, M., and Pakzad, S. N., "Are Today's SHM Procedures Suitable For Tomorrow's BIGDATA", *In Structural Health Monitoring and Damage Detection*, Vol. 7, pp. 59-65, 2015.
8. Morabito, V., *Big Data and Analytics*, Springer International Publishing, 2015.
9. Matarazzo, T. J., and Pakzad, S. N., "Truncated Physical Model for Dynamic Sensor Networks with Applications In High-Resolution Mobile Sensing And BIGDATA", *Journal of Engineering Mechanics*, Vol. 142, No. 5, pp. 1-13, 2016.
10. Kashef, S. And Nezamabadi-Pour, H., "An Advanced ACO Algorithm for Feature Subset Selection", *Neurocomputing*, Vol. 147, pp. 271-279, 2015.
11. Liu, H. And Yu, L., "Toward Integrating Feature Selection Algorithms for Classification and Clustering", *IEEE Transaction Knowledge and Data Engineering*, Vol. 17, No. 4, pp. 491-502, 2005.
12. Ghiasi, R., Ghasemi, M. R. and Noori, M., "Comparative Studies of Metamodeling and AI-Based Techniques in Damage Detection of Structures", *Advances in Engineering Software*, Vol. 125, pp. 101-112, 2018.
13. Han, J. G., Ren, W. X. and Sun, Z. S., "Wavelet Packet Based Damage Identification of Beam Structures." *International Journal of Solids and Structures*, Vol. 42, No. 26, pp. 6610-6627, 2005.
14. Ghiasi, R., Torkzadeh, P. and Noori, M., "A Machine-Learning Approach for Structural Damage Detection Using Least Square Support Vector Machine Based on a New Combinational Kernel Function", *Structural Health Monitoring*, Vol. 15 , No. 3 , PP. 302-316, 2016.
15. Farrar, C. R., and Worden, K., *Structural Health Monitoring: A Machine Learning Perspective*, John Wiley & Sons, 2012.
16. Laney, D., "3D Data Management: Controlling Data Volume, Velocity and Variety", *META Group Research Note 6*, No. 70, pp. 1, 2001.
17. Ivanov, T., Korfiatis, N., and Zicari, R. V., "on The Inequality of the 3V's of Big Data Architectural Paradigms: A Case for Heterogeneity", *Arxiv Preprint Arxiv:1311.0805*, 2013.
18. Bilal, M., Oyedele, L. O., Qadir, J., Munir, K., Ajayi, S. O., Akinade, O. O., Owolabi, H. A., Alaka, H. A. and Pasha, M., "Big Data in the Construction Industry: A Review of Present Status, Opportunities, and Future Trends", *Advanced Engineering Informatics*, Vol. 30, No. 3, pp. 500-521, 2016.
19. Malekzadeh, M., and Catbas, F. N. "A Machine Learning Framework for Automated Functionality Monitoring of Movable Bridges", *In Dynamics of Civil Structures*, Vol. 2, pp. 57-63, 2016.
20. Zhong, L., Song, H., and Han, B. "Extracting Structural Damage Features: Comparison between PCA and ICA", *Proceedings of International*

- Conference on Intelligent Computing*, ICIC 2006 Kunming, China, pp. 840-845, 2006.
21. Liu, Y. Y., Ju, Y. F., Duan, C. D. and Zhao, X. F., "Structure Damage Diagnosis Using Neural Network and Feature Fusion", *Engineering Applications of Artificial Intelligence*, Vol. 24, No. 1, pp. 87-92, 2011.
 22. Cortes, C. and Vapnik, V., "Support-Vector Networks", *Machine Learning*, Vol. 20, No. 3, pp. 273-297, 1995.
 23. Suykens, J. A., De Brabanter, J., Lukas, L. and Vandewalle, J., "Weighted Least Squares Support Vector Machines: Robustness and Sparse Approximation" *Neurocomputing*, Vol. 48, No. 1-4, pp. 85-105, 2002.
 24. Daubechies, I., *Ten Lectures on Wavelets*, SIAM, Pennsylvania, 1992.
 25. Geem, Z. W, Kim, J. H., and Loganathan. G. V. "A New Heuristic Optimization Algorithm: Harmony Search", *Simulation*, Vol. 76, No. 2, pp. 60-68, 2001.
 26. Kennedy J. *Particle Swarm Optimization*, In Encyclopedia of Machine Learning, pp. 760-766. Springer, Boston, MA, 2011.
 27. Nguyen N. T, Lee H. H, and Kwon J. M. "Optimal Feature Selection Using Genetic Algorithm For Mechanical Fault Detection of Induction Motor", *Journal of Mechanical Science and Technology*, Vol. 22, No. 3, pp. 490-496, 2008.
 28. Johnson, E. A., Lam, H. F, Katafygiotis, L. S., and Beck J. L. "Phase I IASC-ASCE Structural Health Monitoring Benchmark Problem Using Simulated Data", *Journal of Engineering Mechanics*, Vol. 130, No. 1, pp. 3-15, 2004.
 29. Yang, X. *A New Metaheuristic Bat-Inspired Algorithm*, Proceedings of Nature inspired Cooperative Strategies for Optimization (*NICSO 2010*), Granada, Spain, pp. 65-74, 2010.
 30. Kaveh, A., and Mahdavi. V., R., "Colliding Bodies Optimization: A Novel Meta-Heuristic Method", *Computers & Structures* Vol. 139, pp. 18-27, 2014.
 31. Kaveh, A., and Talatahari, S., "Particle Swarm Optimizer, Ant Colony Strategy and Harmony Search Scheme Hybridized for Optimization of Truss Structures", *Computers & Structures*, Vol. 87, No. 5-6, pp. 267-283, 2009.
 32. Mckenna, F., Fenves, G. L. and Scott, M. H., *Open System For Earthquake Engineering Simulation*, University of California, Berkeley, CA, 2000.