

عیب‌یابی سازه‌ها با استفاده از شاخص تابع پاسخ فرکانسی و مدل جایگزین مبتنی بر الگوریتم ماشین یادگیری حداکثر بهینه شده

رامین قیاسی*، محمدرضا قاسمی و محمدرضا سهرابی
دانشکده مهندسی عمران، دانشگاه سیستان و بلوچستان

(دریافت مقاله: ۱۳۹۴/۱۰/۰۸ - دریافت نسخه نهایی: ۱۳۹۵/۰۴/۰۸)

DOI: 10.18869/acadpub.jcme.36.1.1

چکیده - امروزه استفاده از مدل‌های جایگزین مبتنی بر الگوریتم‌های هوش مصنوعی در زمینه عیب‌یابی سازه‌ها مورد توجه بسیاری از محققین قرار گرفته است. در این تحقیق، جهت افزایش دقت الگوریتم تشخیص عیوب چندگانه در سیستم‌های سازه‌ای، کرنل جدیدی مبتنی بر موجک لیتلود پالی برای الگوریتم هوش مصنوعی ماشین یادگیری حداکثر، توسعه داده می‌شود. به منظور کاهش حجم محاسبات به‌روزرسانی مدل سازه از ماشین یادگیری حداکثر به‌عنوان مدل جایگزین برای تحلیل اجزای محدود دقیق سازه استفاده می‌شود. در روش دو مرحله‌ای پیشنهادی در مرحله اول با استفاده از شاخص مبتنی بر تابع پاسخ فرکانسی سازه، المان‌های معیوب مشخص می‌شود و در مرحله دوم شدت خرابی در این اعضا با استفاده از مدل جایگزین مبتنی بر ماشین یادگیری حداکثر تعیین می‌شود. برای مقایسه کارایی سیستم مبتنی بر ماشین یادگیری حداکثر، نتایج حاصل از کرنل پیشنهادی با سایر کرنل‌های پیشنهاد شده برای ماشین یادگیری حداکثر و همچنین الگوریتم ماشین بردار پشتیبان حداقل مربعات، مقایسه شده است. مثال‌های عددی حل شده بیانگر افزایش قابل توجه دقت الگوریتم ماشین یادگیری حداکثر در فرایند عیب‌یابی سازه‌ها در صورت استفاده از کرنل موجکی لیتلود پالی است.

واژه‌های کلیدی: عیب‌یابی سازه‌ها، مدل‌های جایگزین، الگوریتم ماشین یادگیری حداکثر، کرنل موجکی لیتلود پالی.

Structural Damage Detection using Frequency Response Function Index and Surrogate Model Based on Optimized Extreme Learning Machine Algorithm

R. Ghiasi*, M. R. Ghasemi and M. R. Sohrabi

School of Engineering, Sistan Balouchestan University, Sistan Balouchestan, Iran

Abstract: Utilizing surrogate models based on artificial intelligence methods for detecting structural damages has attracted the attention of many researchers in recent decades. In this study, a new kernel based on Littlewood-Paley Wavelet (LPW) is proposed for Extreme Learning Machine (ELM) algorithm to improve the accuracy of detecting multiple damages in structural systems. ELM is used as metamodel (surrogate model) of exact finite element analysis of structures in order to efficiently reduce

* : مسئول مکاتبات، پست الکترونیکی: rghiasi.s@gmail.com

the computational cost through updating process. In the proposed two-step method, first a damage index, based on Frequency Response Function (FRF) of the structure, is used to identify the location of damages. In the second step, the severity of damages in identified elements is detected using ELM. In order to evaluate the efficacy of ELM, the results obtained from the proposed kernel were compared with other kernels proposed for ELM as well as Least Square Support Vector Machine algorithm. The solved numerical problems indicated that ELM algorithm accuracy in detecting structural damages is increased drastically in case of using LPW kernel.

Keywords: Detecting structural damages, Surrogate model, Extreme Learning Machine (ELM) algorithm, Littlewood-Paley Wavelet (LPW) kernel.

فهرست علائم

$\dot{X}(t)$	بردار سرعت سازه در لحظه t	C	ماتریس میرایی سازه
$X(t)$	بردار جابه‌جایی سازه در لحظه t	$F(t)$	بردار نیروهای وارد بر درجات آزادی سازه در لحظه t
$\ddot{X}(t)$	بردار شتاب سازه در لحظه t	$g(x)$	تابع تحریک در شبکه SFLN
(x_i, t_i)	بردار داده‌های آموزشی شامل ورودی و خروجی برای نمونه i	K	ماتریس ساختی سازه
$X(\omega)$	جابه‌جایی سازه در حوزه فرکانس	M	ماتریس جرم سازه
ω	فرکانس بار محرک	\tilde{N}	تعداد گره‌های مخفی در شبکه SFLN
ζ	نسبت میرایی سازه	$F(\omega)$	نیروی وارد بر سازه در حوزه فرکانس
ω_n	فرکانس طبیعی سازه	$H(\omega)$	پاسخ سازه در حوزه فرکانس
ϕ_{ik}, ϕ_{jk}	اشکال مودی درجه آزادی i و j	$H_{ij}(\omega)$	پاسخ فرکانسی محاسبه شده در گره i تحت نیروی وارد شده در گره j
$\Delta H_{i,j}''$	قدرمطلق اختلاف ماتریس هسیان FRF برای سازه آسیب دیده و سازه سالم	h	فاصله بین دو گره متوالی
S_i	مجموع تغییرات هسیان FRF محاسبه شده در درجه آزادی i تحت بارهای اعمال شده در درجات آزادی j	$(H_{i,j}''(\omega))_{\text{health}}$	مشتمل دوم تابع FRF سازه سالم
S_i	مجذور S_i	$(H_{i,j}''(\omega))_{\text{damaged}}$	مشتمل دوم تابع FRF سازه خراب
β	وزن‌های داده‌های خروجی در شبکه SFLN	$a_i > 0$	مقدار مرز- عدد برای کرنل پیشنهادی
		$q > 1$	ضریب نرمی موجک برای کرنل پیشنهادی

باعث فروریزش آن می‌شود. بنابراین لزوم شناسایی محل و مقدار خرابی در سازه‌ها بسیار حائز اهمیت است تا از این طریق بتوان با حداقل هزینه باعث دوام بیشتر سازه شد. با استفاده از روش‌های غیب‌یابی سازه می‌توان مکان خرابی در سازه آسیب دیده را شناسایی کرد و بدین ترتیب با انجام

۱- مقدمه

تمامی سازه‌ها پس از گذشت زمان و در اثر نوع کاربری و یا اعمال بارگذاری‌های بیش از مقادیر منظور شده در طراحی، ممکن است دچار خستگی و آسیب شوند. در صورت عدم اصلاح این آسیب‌ها؛ خرابی در سازه گسترش یافته و در نهایت

در روند عیب‌یابی سازه‌ها نیاز به تحلیل تکرار شونده سازه‌ها در فرایند به‌روزرسانی مدل اجزا محدود سازه^۷ است. در صورت بزرگ بودن تعداد درجات آزادی^۸ سازه فرایند به‌روزرسانی مدل سازه زمان‌بر بوده و از این‌رو محققین از مدل‌های جایگزین^۹ به‌جای تحلیل دقیق سازه استفاده می‌کنند. بررسی جامعی در مورد کارایی مدل جایگزین مبتنی بر شبکه عصبی^{۱۰} در فرایند عیب‌یابی توسط حکیم و رزاک در سال ۲۰۱۴ صورت گرفته است [۸]. همچنین قیاسی و همکاران در سال ۲۰۱۴ مقایسه جامعی بین روش‌های مختلف هوش مصنوعی انجام دادند [۹]. در پژوهش انجام شده هفت روش هوش مصنوعی از جمله سیستم استنتاج قازی عصبی تطبیقی^{۱۱}، پردازش گوسی^{۱۲}، ماشین بردار پشتیبان حداقل مربعات^{۱۳} و ... با هم مقایسه شده و نتایج بیانگر دقت بیشتر الگوریتم ماشین بردار پشتیبان حداقل مربعات نسبت به سایر الگوریتم‌ها مطرح شده است [۹]. همچنین فتح نجات و همکاران مدل‌های جایگزین کارایی مبتنی بر شبکه عصبی پیش‌رو^{۱۴} اصلاح شده به‌منظور شناسایی خرابی در صفحات خمشی^{۱۵} و سازه‌های فضاکار بزرگ مقیاس^{۱۶} ارائه کرده‌اند [۱۰].

در الگوریتم‌های هوش مصنوعی نظیر ماشین بردار پشتیبان حداقل مربعات و ماشین یادگیری حداکثر^{۱۷} از کرنل^{۱۸} برای تبدیل ابعاد مسأله استفاده می‌شود و تعیین کرنل مناسب برای مسأله مورد نظر و یا پیشنهاد کرنل جدید زمینه تحقیقاتی مهمی در این زمینه است [۱۱]. خطیبی‌نیا و همکاران در سال ۲۰۱۴ کرنل جدیدی مبتنی بر موجک^{۱۹} مورلت^{۲۰} برای الگوریتم ماشین بردار پشتیبان حداقل مربعات پیشنهاد داده و از آن به‌منظور ارزیابی قابلیت اعتماد لرزه‌ای سازه‌های بتنی^{۲۱} در صورت در نظر گرفتن اندرکنش خاک و سازه^{۲۲} استفاده کردند [۱۲]. همچنین قیاسی و همکاران کرنلی ترکیبی^{۲۳} براساس ترکیب تابع شعاع مبنای^{۲۴} تین پلینت اسپیلان^{۲۵} و تابع موجکی لیتلود پالی^{۲۶} ارائه کردند و به مقایسه کارایی آن در فرایند عیب‌یابی سازه‌های فضاکار پرداختند. نتایج بیانگر افزایش دقت الگوریتم ماشین بردار پشتیبان حداقل مربعات

اقدامات لازم از گسترش آسیب در اعضای مختلف سازه جلوگیری کرد و عمر سازه را افزایش داد. در این راستا روش‌های غیرمخرب به‌دلیل هزینه کم و اقتصادی بودن دارای اهمیت ویژه‌ای هستند که ضرورت این تحقیق را بیش از پیش آشکار می‌کند. علاوه بر این می‌توان با پیش‌بینی مکان‌های ضعیف سازه، عملیات بهینه‌ای جهت ترمیم و بهسازی آن در برابر زلزله انجام داد. بدین صورت که با شناسایی محل‌های ضعف سازه و ترمیم فقط همان قسمت آسیب دیده، می‌توان از صرف هزینه‌های زیاد و بعضاً غیرعملی جهت ترمیم کل سازه جلوگیری کرد [۱ و ۲].

با توجه به اینکه سختی سازه در اثر خرابی تغییر می‌کند؛ متعاقباً رفتار و پاسخ سازه در برابر تحرک وارده نیز دچار تغییراتی شده و با استفاده از این خصوصیت می‌توان به شناسایی خرابی در سازه‌ها پرداخت. جهت بررسی خرابی در سازه‌ها روش‌های مختلفی مبتنی بر پاسخ‌های دینامیکی و یا استاتیکی سازه همچون انرژی کرنشی مودال^۱؛ باقی‌مانده نیروی مودی^۲، تابع پاسخ فرکانسی^۳ و ... مطرح شده است که در بین آنها روش مبتنی بر شاخص تابع پاسخ فرکانسی نتایج با اطمینان بیشتری نسبت به روش‌های دیگر تحلیل مودال در بر دارد [۳ و ۴]. تحقیقات جامعی توسط سمپایو و همکاران در مورد کاربرد تابع پاسخ فرکانسی که به اختصار با FRF نشان داده می‌شود، در فرایند عیب‌یابی سازه‌ها انجام پذیرفته است [۵]. همچنین در پژوهشی در سال ۲۰۱۴ ترک‌زاده و خمسه روشی دو مرحله‌ای مبتنی بر شاخص تابع پاسخ فرکانسی و الگوریتم اصلاح شده اجتماع ذرات^۴ پیشنهاد کرده و از آن برای عیب‌یابی سازه‌های فضاکار^۵ استفاده کردند [۶]. در پژوهشی دیگر لینک و زیمرمن در سال ۲۰۱۵ از روشی مبتنی بر جستجوی متعامد تطبیقی^۶ و تابع پاسخ فرکانسی به‌منظور عیب‌یابی سازه‌ها در صورت ناکامل بودن داده‌های حاصل از حسگرها پرداختند. این روند بر روی چند مثال سازه‌ای از جمله خرپا مورد بررسی قرار گرفته است و نتایج بیانگر دقت بالای روش در شناسایی خرابی در اعضای سازه است [۷].

در صورت استفاده از کرنل پیشنهاد شده است [۱۳ و ۱۴].
در این تحقیق، از روشی دو مرحله‌ای به منظور عیب‌یابی
سازه‌ها استفاده شده است. به این منظور در مرحله اول با
استفاده از ماتریس هسیان^{۲۷} تابع پاسخ فرکانسی مکان
المان‌های^{۲۸} معیوب سازه مشخص می‌شود و در این راستا از
روش عددی تفاضلات محدود^{۲۹} برای ماتریس هسیان
استفاده می‌شود. بدین ترتیب که با توجه به فرمول‌بندی انجام
گرفته براساس اصول دینامیک سازه‌ها^{۳۰}، تابع پاسخ فرکانس
تعریف شده و در ادامه با روش‌های تئوری، اطلاعات FRF
سازه محاسبه و پس از برآورد ماتریس هسیان تابع پاسخ
فرکانس، نمودار تغییرات هسیان FRF را برای سازه سالم و
آسیب دیده رسم کرده، در نهایت با توجه به نمودار تغییرات
هسیان FRF، محل خرابی در سازه‌ها تشخیص داده می‌شود.
در مرحله دوم شدت خرابی در المان‌های سازه با استفاده از
الگوریتم ماشین یادگیری حداکثر که به اختصار با ELM
نشان داده می‌شود مشخص می‌شود. در این مرحله مدل
جایگزینی برای تحلیل اجزای محدوده دقیق سازه اصلی
ایجاد می‌شود. ورودی این الگوریتم اختلاف فرکانسی سازه
سالم و معیوب بوده و خروجی آن شدت خرابی در
المان‌های سازه است. به منظور افزایش دقت مدل جایگزین
کرنل موجکی جدیدی بنام لیتلود پالی براساس موجک لیتلود
پالی معرفی شده و تأثیر استفاده از آن در کارایی روش مورد
بررسی قرار می‌گیرد.

۲- اصول دینامیک سازه‌ها و تابع فرکانسی (FRF)

براساس اصول دینامیک سازه‌ها، معادله دیفرانسیل حاکم بر
رفتار دینامیکی سازه‌ها چند درجه آزادی از مرتبه دوم بوده و
به صورت زیر نمایش داده می‌شود [۱۵]:

$$\mathbf{M}\ddot{\mathbf{X}}(t) + \mathbf{C}\dot{\mathbf{X}}(t) + \mathbf{K}\mathbf{X}(t) = \mathbf{F}(t) \quad (1)$$

در رابطه فوق \mathbf{M} ، \mathbf{C} و \mathbf{K} به ترتیب ماتریس‌های جرم، میرایی و
سختی سازه بوده و $\ddot{\mathbf{X}}(t)$ ، $\dot{\mathbf{X}}(t)$ و $\mathbf{X}(t)$ به ترتیب بردارهای
شتاب، سرعت و جابه‌جایی سازه در لحظه t هستند. همچنین

$$F(t) = F(\omega)e^{i\omega t} \quad (2)$$

$$X(t) = X(\omega)e^{i\omega t} \quad (3)$$

در رابطه فوق، ω فرکانس بار محرک و $X(\omega)$ و $F(\omega)$
به ترتیب جابه‌جایی و نیروی وارد بر سازه در حوزه فرکانس
است. با جای‌گذاری روابط (۲) و (۳) در رابطه (۱) داریم:

$$X(\omega) = H(\omega)F(\omega) \quad (4)$$

در رابطه فوق، $H(\omega)$ پاسخ سازه در حوزه فرکانس بوده و
به عنوان تابع پاسخ فرکانس (FRF) تعریف می‌شود. تابع پاسخ
فرکانسی به صورت زیر نشان داده می‌شود:

$$H(\omega) = \frac{1}{1 - \left(\frac{\omega}{\omega_n}\right)^2 + i2\zeta\left(\frac{\omega}{\omega_n}\right)} \quad (5)$$

در رابطه فوق، ω_n فرکانس طبیعی سازه، ζ نسبت میرایی
سازه و i برابر با $\sqrt{-1}$ است.

برای سیستم‌های چند درجه آزادی، تابع پاسخ فرکانس
برای درجات آزادی i و j از روابط (۱)، (۲) و (۳) به صورت
زیر استخراج می‌شود [۱۷]:

$$H_{ij}(\omega) = \sum_{k=1}^N \frac{\phi_{ik}\phi_{jk}}{\omega_k^2 - \omega + i2\zeta_k\omega_k} \quad (6)$$

در رابطه فوق، $H_{ij}(\omega)$ پاسخ درجه آزادی i تحت اثر بار هارمونیک
با دامنه واحدی است که بر درجه آزادی j اعمال می‌شود. در این
تحقیق ζ نسبت میرایی مودال سازه برابر با ۰/۰۵ در نظر گرفته شده
و ϕ_{ik} و ϕ_{jk} به ترتیب اشکال مودی درجه آزادی i و j مربوط به
مود k ام هستند. قابل ذکر است که تابع $H_{ij}(\omega)$ را می‌توان
به صورت یک ماتریس بیان کرد که در این صورت ابعاد این
ماتریس، برابر تعداد درجات آزادی سازه خواهد بود.

۳- ماتریس هسیان و منحنی تغییرات هسیان FRF

مشق مرتبه دوم تابع پاسخ فرکانس با عنوان ماتریس هسیان

۴- الگوریتم ماشین یادگیری حداکثر (ELM)

شبکه‌های عصبی پیش‌رو، به دلیل توانایی بالا، در زمینه‌های زیادی مورد استفاده قرار می‌گیرند:

۱. برای تقریب‌سازی نگاشت‌های غیرخطی پیچیده^{۳۱} در نمونه‌های ورودی.

۲. برای بهبود دادن مدل‌های موجود پدیده‌های طبیعی و مصنوعی که دسترسی به آنها با تکنیک پارامترهای کلاسیک مشکل است.

از طرف دیگر، فقدان یک الگوریتم آموزشی سریع‌تر هم، برای شبکه‌های عصبی وجود دارد [۱۹]. در کاربردهای واقعی، شبکه‌های عصبی در گروه‌های آموزشی محدود آموزش داده می‌شوند. برای تقریب‌سازی توابع در گروه‌های آموزشی محدود، شبکه عصبی پیش‌رو تک لایه مخفی، با N گره مخفی و با تقریباً هر تابع تحریک غیرخطی، می‌توانند N مشاهده متمایز را آموزش ببینند. این مورد که در هر الگوریتم آموزشی عملی از شبکه‌های عصبی پیش‌رو، وزن‌های ورودی (ارتباط بین لایه ورودی و اولین لایه مخفی) و بایاس‌های لایه مخفی^{۳۲} باید تنظیم شوند، باید مدنظر قرار گیرد.

به‌طور سنتی، همه پارامترهای شبکه عصبی پیش‌رو نیاز به تنظیم دارند و بنابراین یک وابستگی بین لایه‌های متفاوت (وزن‌ها و بایاس‌ها) وجود دارد. در دهه‌های گذشته، روش گرادین کاهشی^{۳۳}، اساساً در الگوریتم‌های آموزشی متفاوتی از شبکه‌های عصبی، استفاده می‌شد. اما این واضح است که روش آموزشی گرادین کاهشی به دلیل گام‌های آموزشی نامناسب، بسیار کند است و گام‌های آموزشی تکراری بسیار زیادی برای بهتر اجرا کردن الگوریتم مورد نیاز است.

شبکه عصبی پیش‌رو تک لایه، با N گره مخفی، با وزن‌های ورودی انتخابی تصادفی و بایاس‌های لایه مخفی (و گره‌های مخفی که گره‌های مخفی تصادفی نامیده می‌شوند) به‌طور کامل می‌تواند N مشاهده متمایز را آموزش ببیند.

هانگ و همکاران در سال ۲۰۰۶، ابتدا به‌طور دقیق، ثابت کردند که اگر تابع تحریک در لایه مخفی به‌طور نامحدود قابل

FRF تعریف می‌شود. از آنجا که این پارامتر به تغییرات و اغتشاشات کوچک در متغیرهای اصلی FRF حساسیت نشان می‌دهد، جهت تشخیص محل خرابی می‌تواند عملکرد مثبتی داشته باشد. بنابراین می‌توان جهت بررسی تغییرات FRF ایجاد شده در سازه آسیب دیده نسبت به سازه سالم، از این کمیت بهره گرفت. در این تحقیق برای محاسبه ماتریس هسیان FRF از روش عددی تفاضلات محدود استفاده شده که رابطه آن به‌صورت زیر است [۱۸]:

$$H_{i,j}''(\omega) = \frac{H_{i+1,j}(\omega) - 2H_{i,j}(\omega) + H_{i-1,j}(\omega)}{h^2} \quad (7)$$

در رابطه فوق، h فاصله بین دو گره متوالی و $H_{i,j}(\omega)$ پاسخ فرکانسی محاسبه شده در گره i تحت نیروی وارد شده در گره j است که از رابطه (۶) محاسبه می‌شود.

قدرمطلق اختلاف ماتریس هسیان FRF برای سازه آسیب دیده و سازه سالم در یک محدود فرکانسی به‌صورت زیر محاسبه می‌شود:

$$\Delta H_{i,j}'' = \sum_{\omega} \left| (H_{i,j}''(\omega))_{\text{health}} - (H_{i,j}''(\omega))_{\text{damaged}} \right| \quad (8)$$

در رابطه فوق، $(H_{i,j}''(\omega))_{\text{health}}$ و $(H_{i,j}''(\omega))_{\text{damaged}}$ به ترتیب مشتق دوم FRF سازه سالم و سازه آسیب دیده در گره i تحت نیروی وارد شده در گره j است. اگر تعداد نقاط اعمال نیرو را افزایش داده و مجموع تغییرات محاسبه شده از رابطه (۸) برای این نقاط محاسبه شود، داریم:

$$S_i = \sum_j \Delta H_{i,j}'' \quad (9)$$

در رابطه فوق، S_i مجموع تغییرات هسیان FRF محاسبه شده در درجه آزادی i تحت بارهای اعمال شده در درجات آزادی j است. با محاسبه S_i برای تمام درجات آزادی i در سازه و رسم این تغییرات با عنوان منحنی تغییرات هسیان FRF، می‌توان تغییرات ناگهانی FRF سازه سالم و سازه آسیب دیده را بررسی و محل آسیب را شناسایی کرد. برای شناسایی و بررسی آسان‌تر و دقیق‌تر می‌توان از مجذور S_i تحت عنوان SQS استفاده کرد:

$$SQS_i = (S_i)^2 = \left(\sum_j \Delta H_{i,j}'' \right)^2 \quad (10)$$

$$\beta = H^+T \quad (11)$$

به طوری که:

$$T = [t_1, \dots, t_N]^T$$

در الگوریتم ELM، به منظور کاهش خطای آموزشی، وزن‌های لایه خروجی به صورت تحلیلی محاسبه می‌شوند:

$$\text{Minimize: } \|H\beta - T\|^2 \text{ and } \|\beta\| \quad (12)$$

نتایج مرجع [۲۱] نشان می‌دهد این الگوریتم برای هر تابع تحریک^{۳۵} $g(x)$ کار می‌کند. از توابع تحریک سیگموئید^{۳۶}، بنیادی شعاعی، سینوسی، کسینوسی، نمایی و بسیاری توابع غیرمنظم دیگر استفاده می‌شود.

در مقاله‌ای در سال ۲۰۱۲، هانگ و همکارانش به بررسی تفاوت بین الگوریتم ELM با ماشین بردار پشتیبان و شاخه‌های آن نظیر ماشین بردار پشتیبان حداقل مربعات پرداختند و نتایج حاکی از سرعت بیشتر ELM نسبت به دیگر الگوریتم‌ها در زمینه‌های رگرسیون^{۳۷} و طبقه‌بندی^{۳۸} است [۲۱]. همچنین آنها در سال ۲۰۱۴، به بررسی نرون‌های تصادفی^{۳۹}، وزن‌های تصادفی و کرنل‌ها پرداختند [۲۲]. در تحقیقی دیگر هانگ و همکاران این بحث را به صورت کلی‌تر و براساس وجود نرون‌های مختلف در لایه مخفی مطرح کردند. این لایه مخفی نقش تبدیل فضا داده‌های ورودی به خروجی را دار است. کرنل‌ها نیز چنین ویژگی دارند. کرنل‌های مختلفی بدین منظور معرفی شده است [۲۲]:

$$K(x, \bar{x}) = \langle x \times \bar{x} \rangle + \theta \quad \text{کرنل خطی}^{۴۰}$$

$$K(x, \bar{x}) = (\langle x \bar{x} \rangle + 1)^P \quad \text{کرنل چند جمله‌ای}^{۴۱}$$

$$K(x, \bar{x}) = \exp\left\{\frac{\|x - \bar{x}\|^2}{-2\sigma^2}\right\} \quad \text{کرنل گوسی}^{۴۲}$$

علاوه بر کرنل‌های استاندارد الگوریتم ELM، هانگ و همکاران از موجک مورلت به عنوان کرنل ELM استفاده کرده‌اند [۲۱]:

$$K(x, \bar{x}) = \prod_{i=1}^n \frac{1}{\sqrt{a}} \cos\left(\omega_i \left(\frac{x_i - \bar{x}_i}{a}\right)\right) \exp\left(-\frac{\|x_i - \bar{x}_i\|}{a^2}\right) \quad (13)$$

موجک دارای ویژگی محلی کردن زمان فرکانس^{۴۳} است و

تشخیص باشد، وزن‌های ورودی و بایاس‌های لایه مخفی شبکه عصبی پیش‌رو تک لایه به طور تصادفی انتخاب می‌شوند [۱۹]. بعد از وزن‌های ورودی و بایاس‌های لایه مخفی، که به طور تصادفی انتخاب شدند، شبکه عصبی پیش‌رو تک لایه، به سادگی با یک سیستم خطی، وزن‌های خروجی را (ارتباط بین لایه مخفی و لایه خروجی) به طور تحلیلی و از طریق عملکرد معکوس ماتریس خروجی لایه مخفی، تخمین می‌زند. براساس این نظریه، الگوریتم آموزشی ساده‌ای از شبکه عصبی پیش‌رو تک لایه به نام ماشین یادگیری حداکثر پیشنهاد شد که سرعت یادگیری در آن هزاران بار سریع‌تر از الگوریتم آموزشی شبکه پیش‌رو انتشار برگشتی^{۴۴} است، در حالی که اجرای عمومی بهتری هم به همراه دارد.

متفاوت از الگوریتم‌های آموزشی سنتی، الگوریتم پیشنهاد شده به دست آوردن کوچک‌ترین خطای آموزشی و کمترین میانگین وزنی تمایل دارد و براساس تئوری بارلت در اجرای عمومی شبکه عصبی پیش‌رو، با به دست آوردن کوچک‌ترین خطای آموزشی و کمترین میانگین وزنی، بهترین و سریع‌ترین اجرا را در بر دارد.

ساهو و همکاران در سال ۲۰۱۳، الگوریتم ELM را با شبکه عصبی پس انتشار درباره شبکه‌های عصبی تک لایه پیش‌رو مقایسه کردند و بدون تنظیمات تکرار شونده مقادیر وزن‌های خروجی را تخمین زدند. این مقایسه نشان داد که الگوریتم ELM تمایل به اجرای بهتر با سرعت بیشتر در رگرسیون و طبقه‌بندی دودویی دارد و همچنین در مورد طبقه‌بندی چندگانه هم بهترین اجرا را در بردارد [۲۰]. روند کلی این الگوریتم از قرار زیر است:

یک گروه داده‌های آموزشی $\{(x_i, t_i) | x_i \in R^n, t_i \in R^m, i = 1, \dots, N\}$ ، تعداد \tilde{N} گره مخفی وجود دارند [۲۱].

گام اول: به طور تصادفی وزن‌های ورودی w_i و بایاس مخفی b_i برای $i = 1, \dots, N$ انتخاب می‌شوند.

گام دوم: ماتریس خروجی لایه مخفی H محاسبه می‌شود.

گام سوم: وزن‌های خروجی β محاسبه می‌شوند.

به این منظور باید یک مسأله بهینه‌سازی غیرخطی مقید^{۵۳} حل شود. نظریه SVM با این فرضیه که تابع تفکیک‌گر در فضای ورودی می‌تواند غیرخطی هم باشد، تکمیل شد. نظریه عملکرد شبکه‌های 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 داده می‌شوند. بعد در این فضای جدید سطوح خطی تصمیم‌گیر ساخته می‌شوند. خصوصیات این صفحات تصمیم‌گیر به نحوی است که قابلیت تعمیم را برای روش فراگیری ماشین تضمین می‌کند. بنابراین به‌خاطر قابلیت نگاشت است که می‌توان گفت SVM یک حالت کلی از ماشین‌های فراگیر است که شبکه عصبی، شبکه‌های شعاع مینا و دسته‌بندی‌کننده‌های چند جمله‌ای، حالت‌های خاصی از آن هستند.

SVM جزء گروه دسته‌بندی‌کننده‌هایی است که بدون دانستن مدل توزیع داده‌ها، دسته‌بندی را انجام می‌دهد؛ حتی فراتر از آن، این مدل نیازی به دانستن یک ساختار کلی از مسأله ندارد. شبکه بردارهای پشتیبان یک ماشین آموزشی جهت دسته‌بندی داده‌های ورودی به دو گروه است، اما با استفاده از تکنیک‌هایی برای مسائل چند دسته‌ای نیز استفاده می‌شود [۲۴].

به‌طور کلی SVM بردارهای ورودی را با استفاده از یک کرنل به یک فضای بزرگتری می‌برد که تفکیک‌پذیری خطی در آن بهتر و قاطعانه‌تر انجام می‌شود. با استفاده از کرنل‌های مختلف، می‌توان روش‌های فراگیری مختلفی با انواع سطوح تصمیم‌گیری دلخواه ساخت. به این ترتیب است که SVM به‌عنوان یک کلاس جدید از دسته‌بندی‌کننده‌ها و ماشین‌های تشخیص الگو در می‌آید. چون فرایند عیب‌یابی سازه‌ها مسأله‌ای چند کلاسه است لذا این نوع دسته‌بندی‌کننده می‌تواند توسط ترکیب SVM‌های دو کلاسه ساخته شوند و این تکنیک برخلاف سایر تکنیک‌ها، دسته‌بندی را بین هر کلاس و سایر کلاس‌های باقی‌مانده انجام می‌دهد [۲۴]. در این تحقیق از نسخه اصلاح شده SVM که در آن به‌منظور افزایش توانایی

ابزاری مناسب برای تخمین توابع دلخواه در فضای $L_p(R)$ (فضای انتگرال پیوسته درجه دوم^{۴۴}) است. از این رو قابلیت تعمیم بخشی^{۴۵} ELM با استفاده از موجک به‌عنوان توابع کرنل، افزایش می‌یابد.

انتخاب تابع موجک مناسب به‌عنوان تابع تشکیل دهنده کرنل موجکی موضوعی حساس است. چون علاوه بر مشخصات تابع موجک باید به اغنا شدن شرایط مرسر^{۴۶} به‌منظور ایجاد تابع کرنل، توجه کرد.


معادل موجک هارمونیک^{۴۷}، هنگامی که تابع پایه حقیقی باشد، موجک لیتلود پالی است. موجک لیتلود پالی که به اختصار با LWP نشان داده می‌شود نوعی از توابع متعامد^{۴۸} است که دارای خصوصیات خوبی در آنالیز زمان فرکانسی سیگنال محلی است و برای تعدیل مرزی عددی^{۴۹} مناسب است و می‌تواند با دقت مطلوبی پارامترها را مشخص کند [۲۳]. از این‌رو در این پژوهش برای اولین بار از موجک LWP برای ELM استفاده می‌شود. به‌منظور افزایش بیشتر دقت کرنل پیشنهادی از نسخه اصلاح شده LWP براساس پژوهش یانگ ژینگ استفاده می‌شود. این محققین از این کرنل برای الگوریتم ماشین بردار پشتیبان استفاده کرده‌اند. صورت ریاضی این کرنل موجکی به‌صورت زیر است [۲۳]:

$$K_{LWP}(x, \bar{x}) = \prod_{i=1}^n \frac{1}{\pi \sqrt{q-1}} \times \frac{\sin q\pi \left(\frac{x_i - \bar{x}_i}{a_i} \right) - \sin \pi \left(\frac{x_i - \bar{x}_i}{a_i} \right)}{\left(\frac{x_i - \bar{x}_i}{a_i} \right)} \quad (14)$$

که در آن $q > 1$ مقدار مرز-عدد و $a_i > 0$ ضریب نرمی^{۵۰} موجک است.

۵- ماشین بردار پشتیبان حداقل مربعات (LS-SVM)

ماشین بردار پشتیبان در سال ۱۹۹۵ توسط واپنیک بر پایه تئوری یادگیری آماری بیان شده است [۲۴]. SVM از یک ابرصفحه^{۵۱} خطی تفکیک‌گر بهینه، برای دسته‌بندی داده‌ها استفاده می‌کند که این ابرصفحه بهینه از حداکثر کردن حاشیه^{۵۲} به‌دست می‌آید.



شکل ۱- خرابای دو بعدی ۳۱ المانی

۷- نتایج عددی

۷-۱- خرابای دو بعدی ۳۱ المانی

به منظور صحت سنجی روند ارائه شده در این پژوهش، عیب‌یابی خرابای دو بعدی ۳۱ عضوی شکل (۱) مورد بررسی قرار گرفته است [۲۶]. جرم مخصوص و مدول الاستیسیته تمامی اعضای این خرپا به ترتیب برابر با $2770 \frac{\text{kg}}{\text{m}^3}$ و 70 GPa و سطح مقطع همه اعضا 5 cm^2 است. برای مدل‌سازی آسیب از روش‌های مختلف مانند کاهش سطح مقطع، کاهش مدول الاستیسیته و یا کاهش سختی المان‌ها استفاده می‌شود [۱۳]. در اکثر تحقیقات انجام شده در مورد عیب‌یابی سازه‌های اسکلتی عیب به صورت کاهش مدول الاستیسیته در نظر گرفته می‌شود از این رو در این تحقیق نیز، آسیب به صورت کاهش در مدول الاستیسیته المان‌ها و بدون هیچ تغییری در جرم سازه مدل شده است. شدت خرابی نیز به صورت درصد کاهش مدول الاستیسیته مورد بررسی قرار می‌گیرد [۲۶]. بدین منظور برای شناسایی وجود ۲ المان خراب در سازه با در نظر گرفتن کاهش مدول الاستیسیته در محدوده ۱۰ تا ۵۰ درصد با گام‌های ۱۰ درصد، تعداد سناریوهای خرابی ۵۴ ممکن برای سازه برابر با ۱۱۶۲۵ حالت می‌شود که بیشتر از ظرفیت قابل تحلیل با الگوریتم ELM است. به همین علت در ابتدا با استفاده از نمودار تغییرات همیان FRF تعداد المان‌های محتمل خرابی به ۲ عدد کاهش یافته و سپس از بین تمامی سناریوهای خرابی، فقط سناریوهایی که شامل المان‌های محتمل خرابی می‌شوند، انتخاب می‌شوند. در این حالت تعداد سناریوهای خرابی با در نظر گرفتن گام ۵ درصد برابر با ۱۰۰ است.

الگوریتم در برازش داده‌ها در روند ریاضی پایه آن تغییراتی ایجاد شده است و به عنوان روش ماشین بردار پشتیبان حداقل مربعات شناخته می‌شود (LS-SVM)، استفاده شده است [۲۵].

۶- مراحل اساسی شناسایی خرابی در سازه‌ها

مراحل اساسی شناسایی خرابی در سازه‌ها در روش دو مرحله‌ای پیشنهادی در این پژوهش به صورت زیر است:

گام اول: تحلیل سازه سالم و سازه آسیب دیده و محاسبه پاسخ‌های دینامیکی سازه شامل اشکال مودی و فرکانس‌های طبیعی

گام دوم: محاسبه تابع پاسخ فرکانسی برای سازه سالم و آسیب دیده در تمام درجات آزادی با استفاده از پاسخ گام قبل

گام سوم: برآورد ماتریس همیان تابع پاسخ فرکانس با کمک روش عددی تفاضلات محدود


گام چهارم: محاسبه قدرمطلق اختلاف ماتریس همیان FRF سازه سالم و سازه آسیب دیده با به کارگیری یک محدوده فرکانسی از بار اعمال شده بر سازه

گام پنجم: رسم منحنی‌های همیان تابع پاسخ فرکانس برای تمام درجات آزادی سازه و تعیین محل یا محل‌های خرابی با توجه به نقاط اوج آن

گام ششم: محاسبه شدت خرابی در اعضا سازه با استفاده از مدل جایگزین مبتنی بر الگوریتم ELM، در این گام ورودی الگوریتم اختلاف فرکانسی سازه سالم و آسیب دیده و خروجی آن شدت خرابی در المان‌های تشخیص داده شده در مرحله پنج است.

جدول ۱- عضوهای آسیب دیده و میزان آسیب

حالت ۲			حالت ۱		
درصد کاهش سختی	گره‌های مربوط به عضو خراب	شماره عضو	درصد کاهش سختی	گره‌های مربوط به عضو خراب	شماره عضو
۳۰٪	۳ و ۱۱	۱۴	۴۰٪	۳ و ۱۰	۱۱
۳۰٪	۴ و ۱۱	۱۶	۲۰٪	۵ و ۶	۲۵



شکل ۲- منحنی تغییرات هسیان FRF برای حالت خرابی ۱

رادیان بر ثانیه محاسبه می‌شود. این محدوده فرکانسی با توجه به پیشنهاد سمپایو در نظر گرفته شده، زیرا او به این نتیجه رسیده بود که قبل از اولین فرکانس تشدید نتایج FRF عملکرد بهتری دارد [۵]. نمودار تغییرات هسیان FRF برای این خرابی با توجه به پارامتر SQS در شکل‌های (۲) و (۳) رسم شده که این تغییرات را در گره‌های مختلف سازه خرابایی نشان می‌دهد.

همان‌طور که در همه نمودارهای رسم شده ملاحظه می‌شود، گره‌های مربوط به اعضای خراب دارای نقاط اوج هستند. به‌عنوان مثال همان‌طور که در نمودار شکل (۲) مشاهده می‌شود برای حالت خرابی ۱، گره‌های ۳، ۵، ۶ و ۱۰ که مربوط به عضوهای آسیب دیده شماره ۱۱ و ۲۵ می‌شوند، دارای تغییرات زیادی هستند. از طرف دیگر در حالت خرابی ۲، با توجه به اینکه ۲ عضو آسیب دیده دارای خرابی یکسان هستند، شکل (۴) نشان می‌دهد که تغییرات هسیان FRF ایجاد شده در


ورودی الگوریتم ۱۰ فرکانس اول سازه به‌ازای هر سناریوی خرابی است و خروجی الگوریتم درصد خرابی المان‌ها است. روابط (۱۵) و (۱۶) ورودی و خروجی الگوریتم را به‌صورت پارامتری نشان می‌دهند:

$$\text{ورودی} = [\omega_1, \omega_2, \dots, \omega_{10}]_{\times 10} \quad (15)$$

(۱۶) [....] شدت خرابی در المان دوم، شدت خرابی در المان اول = خروجی که ω_i فرکانس و شدت خرابی، درصد خرابی هر یک از المان‌های هر سناریوی خرابی است.

در این مثال، حالت‌های خرابی براساس مرجع ذکر شده و مطابق جدول ۱ در نظر گرفته شده است. با تأثیر این خرابی‌ها در تحلیل نمونه، پاسخ مورد نیاز سازه آسیب دیده به‌دست می‌آید.


با توجه به اینکه اولین فرکانس طبیعی سازه خرابایی برابر ۷۳ رادیان بر ثانیه است، $H_{ij}(\omega)$ در محدوده فرکانسی ۵ تا ۶۵



شکل ۳- منحنی تغییرات هسیان FRF برای حالت خرابی ۱

جدول ۲- تعداد داده‌های تست و آموزشی مورد استفاده


الگوریتم	تعداد داده‌های آموزشی	تعداد داده‌های تست	MSE	زمان اجرا (s)
ماشین یادگیری حداکثر با کرنل پیشنهادی	۶۰	۴۰	۰/۰۰۰۵۱	۳۰۰
ماشین بردار پشتیبان حداقل مربعات با کرنل گوسی	۶۰	۴۰	۰/۰۰۰۶۷۸	۴۸۰



شکل ۴- حالت خرابی ۱

ELM و LS-SVM و میزان میانگین مربعات خطا^{۵۵} (MSE) برای هر یک از این دو الگوریتم در جدول ۲ آورده شده است. با توجه به جدول ۲ می‌توان نتیجه گرفت الگوریتم ELM با کرنل پیشنهادی دقت بالاتری در شناسایی شدت خرابی نسبت به الگوریتم LS-SVM دارد. در شکل‌های (۴) و (۵) خروجی الگوریتم برای هر یک از حالات خرابی نشان داده شده است. جداول ۳ و ۴ اختلاف شدت خرابی واقعی با شدت خرابی تشخیص داده شده، به‌زای در نظر گرفتن کرنل‌های مختلف برای الگوریتم ELM، را نشان می‌دهد.

گره‌های مربوط به این اعضا یکسان نبوده و بنابراین شدت خرابی در این نمودارها قابل بررسی نخواهد بود. در ادامه بعد از مشخص شدن المان‌های محتمل خرابی برای هر یک از حالت‌های جدول ۱ از بین تمامی حالات خرابی ممکن برای سازه فقط حالت‌هایی که شامل المان‌های محتمل خرابی هستند را انتخاب شده و با استفاده از آنها الگوریتم ELM آموزش داده می‌شود. بعد از آموزش، سیستم قادر خواهد بود شدت خرابی در المان‌های مشخص شده در مرحله قبل را مشخص کند. تعداد داده‌های استفاده شده برای آموزش و تست الگوریتم



شکل ۵- حالت خرابی ۲

جدول ۳- مقایسه کرنل‌های استاندارد ماشین یادگیری حداکثر با کرنل پیشنهادی برای سناریوی اول در مثال اول

مان خراب	شدت خرابی واقعی	اختلاف خرابی تشخیص داده شده با کرنل چند جمله‌ای با خرابی واقعی (%)	اختلاف خرابی تشخیص داده شده با کرنل گوسی با خرابی واقعی (%)	اختلاف خرابی تشخیص مولت با خرابی واقعی (%)	اختلاف خرابی تشخیص پیشنهادی با خرابی واقعی (%)
۱۱	۰/۴	-۲/۷۲۶۸۷۱۶۸۶	۳/۰۱۴۱۵۱۷	۱/۶۶۵۱۴۶۰	۰/۶۶۰۶۲۶۱۸۸
۲۵	۰/۲	۲/۱۴۹۵۰۵۲۴۵	۱/۷۳۳۷۶۶۳	۱/۰۴۲۲۱۴۰	۰/۱۸۱۹۶۵۷۰۷

جدول ۴- مقایسه کرنل‌های استاندارد ماشین یادگیری حداکثر با کرنل پیشنهادی برای سناریوی دوم در مثال اول


مان خراب	شدت خرابی واقعی	اختلاف خرابی تشخیص داده شده با کرنل چند جمله‌ای با خرابی واقعی (%)	اختلاف خرابی تشخیص داده شده با کرنل گوسی با خرابی واقعی (%)	اختلاف خرابی تشخیص مولت با خرابی واقعی (%)	اختلاف خرابی تشخیص پیشنهادی با خرابی واقعی (%)
۱۴	۰/۳	-۳/۹۴۸۳۴۲۴۴۹	۲/۱۹۷۱۵۱۷	۱/۱۲۱۴۰۸۳	۰/۸۹۴۹۰۴۷۳۳
۱۶	۰/۳	۴/۶۳۷۰۳۵۲۶۸	۲/۳۰۸۴۶۱۶	۱/۸۹۲۷۷۵۴	۰/۵۰۵۱۷۷۴۱۱

این کرنل با استفاده از ویژگی‌های مثبت کرنل موجکی موجب افزایش خاصیت تعمیم‌پذیری شبکه می‌شود.

۷-۲- سازه فضاکار دولایه تخت ۲۰۰ عضو

برای نشان دادن قابلیت روش پیشنهادی در عیب‌یابی سازه‌ها با ابعاد بزرگتر، از یک سازه فضاکار، استفاده می‌شود [۲۷]. سازه مورد بررسی دولایه و دارای ۲۰۰ عضو با ۶۱ گره و ۱۷۱ درجه آزادی فعال است. سطح مقطع تمام اعضا برابر ۴۰ سانتی‌متر مربع است. این سازه با مدول الاستیسیته 21000000 kg/cm^2 و وزن واحد حجم 7850 kg/m^3 مدل شده است. هندسه سازه در شکل (۶) مشخص است. برای ارزیابی روش سناریوی

همان‌طور که از نمودارهای شکل (۴) و (۵) و جداول ۳ و ۴ مشخص است، ELM توانایی بالایی در یادگیری روند تشخیص شدت خرابی در المان‌ها براساس فرکانس‌های سازه داشته و در هر دو حالت جدید با خطای بسیار کمی شدت خرابی در المان‌ها را مشخص می‌کند. به‌علاوه براساس نتایج عددی به‌دست آمده قابل استنباط است که الگوریتم ELM دقت و سرعت بسیار خوبی در شناسایی شدت و مکان خرابی در خرپا دارد، این ناشی از بهبود سازی‌های انجام شده روی این الگوریتم و توانایی کار با داده‌ها با ابعاد زیاد است. در نهایت، بنا بر نتایج، کرنل پیشنهادی از تمام کرنل‌های استاندارد و موجکی ELM دقت بالاتری در زمینه عیب‌یابی سازه‌ها دارد.



شکل ۶- سازه فضاکار ۲۰۰ عضوی

جدول ۵- سناریوی خرابی برای سازه فضاکار ۲۰۰ عضوی


سناریو	شماره المان	شماره گره ابتدا و انتها	مقدار خرابی
	۹	۱۰-۱۱	٪۲۰
	۱۹	۲۲-۲۳	٪۳۰
	۲۹	۳۴-۳۵	٪۱۵
۱	۴۰	۱۰-۱۶	٪۴۰
	۵۰	۲۰-۲۶	٪۱۰
	۱۴۲	۳۸-۳۹	٪۲۵
	۱۶۲	۴۰-۴۱	٪۲۰
	۱۹۱	۴۵-۵۱	٪۱۵

به دست می آید. مطابق با توضیحات قسمت ۳ نقاط اوج نمودار نشان دهنده گره های مربوط به اعضای خراب است. قابل توجه است که این نمودارها مربوط به درجات آزادی قائم سازه فضاکار است.

بر اساس نتایج حاصل از این نمودار می توان المان های محتمل خرابی را تشخیص داد. با مشخص بودن گره های

خرابی مطابق جدول ۵ استفاده شده است.

در مرحله اول با استفاده از شاخص مبتنی بر تغییرات هسیان FRF، المان های مشکوک به خرابی تشخیص داده می شود. بدین منظور پس از مدل سازی سازه و محاسبه فرکانس ها و مود شکل های سازه با توجه به فرمول های بخش ۳ نمودار تغییرات FRF گره های مختلف سازه مطابق شکل (۷)



شکل ۷- المان‌های محتمل خرابی

جدول ۶- المان‌های محتمل خرابی برای سازه فضاکار ۲۰۰ عضوی

شماره المان	شماره گره ابتدا و انتها *
۹	۱۰-۱۱
۱۹	۲۲-۲۳
۲۱	۲۲-۲۱
۲۹	۳۴-۳۵
۳۰	۳۸-۳۷
۴۰	۱۰-۱۶
۵۰	۲۰-۲۶
۱۴۲	۳۸-۳۹
۱۶۲	۴۰-۴۱
۱۹۱	۴۵-۵۱


* براساس نمودار تابع پاسخ فرکانسی بحرانی هستند

بعدی دارای تغییرات FRF پایین است و سیستم به اشتباه آنها را وارد گروه المان‌های معیوب می‌کند. علاوه بر آن این المان‌ها به المان‌های معیوب سازه نزدیک بوده و خرابی المان‌های واقعاً خراب بر روی آنها تأثیر می‌گذارد. تمام المان‌های خراب تشخیص داده شده در این مرحله وارد مرحله دوم فرایند عیب‌یابی پیشنهاد شده در این پژوهش می‌شود.

در مرحله دوم با استفاده از الگوریتم ELM شدت آسیب در اعضای خراب مشخص می‌شود. شکل (۸) و جدول ۷ شدت خرابی تشخیص داده شده در المان‌های معیوب سازه را با

خراب می‌توان المان‌های که به این گره متصل هستند را پیدا کرد و اگر هر دو گره یک عضو خراب تشخیص داده شد آن عضو معیوب است. بر این اساس با توجه به شکل المان‌های مشخص شده در جدول ۶ خراب تشخیص داده شده‌اند.

همان‌طور که از نمودار مشخص است شاخص مبتنی بر هسیان FRF با دقت بسیار خوبی مکان المان‌های معیوب را مشخص می‌کند. با این وجود دو المان ۴۹ و ۳۰ نیز به اشتباه خراب تشخیص داده شده‌اند. این المان‌ها، المان‌هایی هستند که یکی از گره‌های آن دارای درصد تغییرات FRF بالا و گره



شکل ۸- نتیجه تعیین شدت خرابی با روش پیشنهادی برای سازه فضاکار با هشت خرابی

جدول ۷- مقایسه کرنل‌های استاندارد ماشین یادگیری حداکثر با کرنل پیشنهادی برای سناریوی اول مثال دوم

المان خراب	شدت خرابی واقعی	اختلاف خرابی تشخیص داده شده با کرنل چند جمله‌ای با خرابی واقعی (%)	اختلاف خرابی تشخیص داده شده با کرنل گوسی با خرابی واقعی (%)	اختلاف خرابی تشخیص داده شده با کرنل موجک مولت با خرابی واقعی (%)	اختلاف خرابی تشخیص داده شده با کرنل پیشنهادی با خرابی واقعی (%)
۹	۰/۲	-۱/۸۰۶۶۴۶۶۴۳	۰/۹۵۳۹۱۱۰	۰/۲۳۴۷۷۵۹	۰/۷۰۱۹۳۸۸۵۸
۱۹	۰/۳	-۰/۱۱۶۱۷۵۸۲۶	۲/۳۸۸۷۳۳۴	۱/۸۳۱۰۲۲۸	۱/۰۵۲
۲۹	۰/۱۵	۲/۸۵۱۹۵۴۳۶۸	۱/۶۳۵۶۶۴۳	۰/۱۶۴۹۹۹۲	۰/۰۰۱۳۴
۴۰	۰/۴	۵/۹۱۳۸۱۰۳۵۵	۱/۶۲۱۵۵۲۳	۴/۶۸۳۰۵۰۷	۰/۱۱
۵۰	۰/۱	-۰/۹۳۳۶۳۸۹۹۳	۱/۵۵۴۰۷۸۹	۰/۲۳۰۳۸۰۵	۰/۴۰۴
۱۴۲	۰/۲۵	۲/۸۱۶۶۱۳۷۶۸	۰/۶۱۶۲۷۷۴	۱/۳۳۶۱۹۰۲	۰/۰۱
۱۶۰	۰/۲	۲/۳۸۵۹۵۲۰۸۴	۲/۶۶۷۴۶۶۷	۱/۷۳۰۵۳۰۴	۱/۰۷۱۱
۱۹۱	۰/۱۵	۰/۰۶۱۷۵۱۶۷۲	۰/۸۱۸۴۷۳۶	۰/۵۶۲۴۳۶۰	۰/۱

نتایج بیانگر آن است که در خروجی الگوریتم ELM المان‌هایی که در مرحله اول به اشتباه معیوب تشخیص داده بود دارای شدت خرابی صفر هستند و در نتیجه مرحله دوم علاوه بر مشخص کردن شدت خرابی در المان‌ها، مکان دقیق المان‌های معیوب در سازه را نیز مشخص می‌کند و در صورت تشخیص اشتباه المانی در مرحله اول سیستم در مرحله دوم آنرا حذف می‌کند.

در جدول ۸ نتایج عیب‌یابی با استفاده از کرنل پیشنهادی با سایر کرنل‌های استاندارد ELM مقایسه شده است. بنابر نتایج کرنل پیشنهادی از تمام کرنل‌های استاندارد و موجکی ELM دقت بالاتری در زمینه عیب‌یابی سازه‌ها دارد. این کرنل با استفاده از ویژگی‌های مثبت موجکی LWP موجب افزایش

استفاده از کرنل‌های مختلف برای ELM نشان می‌دهد. در این مثال تعداد کل سناریوهای خرابی بعد از مرحله اول، با در نظر گرفتن سه درصد شدت (۱۰٪، ۲۰٪ و ۴۰٪) برابر با ۶۵۶۱ حالت است که از این تعداد ۶۰٪ آن برای نمونه‌های آموزشی و ۴۰٪ باقی‌مانده برای نمونه‌های آزمایشی استفاده می‌شود.

همان‌طور که در شکل (۸) مشخص است روش پیشنهادی در این پژوهش با دقت بسیار خوبی شدت خرابی را در المان‌های معیوب تعیین می‌کند. به‌علاوه چون با استفاده از مرحله اول تعداد متغیرهای مسئله عیب‌یابی از ۲۰۰ به ۸ عدد کاهش پیدا کرده، روند تشخیص شدت خرابی هم بسیار سریع اتفاق می‌افتد که این نشان‌دهنده کاهش حجم محاسبات مورد نیاز برای تعیین شدت خرابی در المان‌ها است. همچنین

جدول ۸- مقایسه کرنل‌های استاندارد ماشین یادگیری حداکثر با کرنل پیشنهادی

نوع کرنل	خطای سیستم (برحسب شاخص میانگین مربعات خطا)
کرنل چند جمله‌ای	$6/12 \times 10^{-2}$
کرنل گوسی	$1/07 \times 10^{-2}$
کرنل موجک مورلت	$4/48 \times 10^{-2}$
کرنل موجکی پیشنهادی	$1/02 \times 10^{-2}$

جدول ۹- مقایسه کرنل پیشنهادی ماشین یادگیری حداکثر با الگوریتم ماشین بردار پشتیبان حداقل مربعات

نوع الگوریتم و کرنل	خطای سیستم (برحسب شاخص میانگین مربعات خطا)
ماشین بردار پشتیبان حداقل مربعات با کرنل چند جمله‌ای	$18/3 \times 10^{-2}$
ماشین بردار پشتیبان حداقل مربعات با کرنل گوسی	$2/18 \times 10^{-2}$
کرنل موجکی پیشنهادی برای ماشین یادگیری حداکثر	$1/02 \times 10^{-2}$

کرنل LWP که با استفاده از موجکی لیتلود پالی اصلاح شده ایجاد می‌شود باعث افزایش قابلیت تعمیم‌پذیری و پخش‌شدگی ELM می‌شود.

۶- نتیجه‌گیری

در این مطالعه، از یک شاخص خرابی که براساس تغییرات هسیان FRF تعریف می‌شود و نیز الگوریتم ماشین یادگیری حداکثر (ELM) جهت تعیین محل و شدت خرابی سازه‌ها استفاده شده است. به منظور افزایش دقت الگوریتم ELM، کرنل جدیدی مبتنی بر موجک LWP ارائه شد. نتایج این تحقیق بیانگر آن است که تابع پاسخ فرکانس، ابزار مناسبی برای بررسی مکان خرابی در سازه‌ها است. نمودارهای تغییرات هسیان FRF جهت حالت‌های مختلف خرابی نشان می‌دهد که این روش قابلیت شناسایی چندین محل مختلف خرابی را نیز دارد.

به علاوه پس از بررسی و مقایسه نتایج مشخص شد الگوریتم ELM با در اختیار داشتن خصوصیات مثبت الگوریتم‌های مختلف شبکه عصبی و پیاده‌سازی روند آموزشی جدید دارای قدرت بسیار خوبی در برازش توابع و کلاسه‌بندی کردن داده‌ها است و می‌توان از آن به‌عنوان یک الگوریتم هوش مصنوعی قوی در بحث عیب‌یابی و پایش سلامت سازه‌ها^{۵۹}

خاصیت تعمیم‌پذیری شبکه می‌شود.

بنابر نتایج جدول ۸، کرنل مورلت بهترین نتایج را بین بقیه کرنل‌های پیشنهادی دارد. با این وجود دقت عیب‌یابی با استفاده از کرنل LWP ۳/۱٪ بیشتر از این کرنل است. جدول ۹ نتایج مقایسه کرنل پیشنهادی با نتایج حاصل از الگوریتم LS-SVM نشان می‌دهد. از آنجا که الگوریتم LS-SVM مانند الگوریتم ماشین یادگیری حداکثر کرنل مبنا است، در این مثال هم از کرنل چند جمله‌ای و هم از کرنل گوسی برای این الگوریتم استفاده شده است. به منظور آموزش و تست الگوریتم LS-SVM از روندی مشابه با ماشین یادگیری حداکثر استفاده شده است. نتایج بیانگر دقت بالاتر شناسایی شدت خرابی با استفاده از کرنل پیشنهادی برای الگوریتم ماشین یادگیری حداکثر در مقایسه با الگوریتم LS-SVM است.

کرنل گوسی یک تابع کرنل محلی با توانایی زیاد در یادگیری و نگاشت فضا است اما قابلیت تعمیم‌پذیری و پخش‌شدگی آن پایین است. در مقابل تابع موجکی LWP اصلاح شده دارای خواص جابه‌جایی افقی^{۵۷} و نرمی متعامد^{۵۸} است، به علاوه توانایی ساخت پایه متعامد فضای $L_p(R)$ را دارا است، بنابراین با استفاده از کرنل مبتنی بر این تابع می‌توان هر تابع پیچیده‌ای را در فضای $L_p(R)$ تقریب‌سازی کرد. از این رو

قابلیت تعمیم‌پذیری و پخش‌شدگی ELM می‌شود. براساس نتایج حاصل از عیب‌یابی خرپا و سازه فضاکار مطرح شده، کرنل پیشنهادی در مقایسه با سایر کرنل‌های استاندارد و موجکی ELM و همچنین الگوریتم LS-SVM دقت بالاتری در زمینه عیب‌یابی سازه‌ها دارد.

استفاده کرد. در نهایت کرنل پیشنهادی در این پژوهش با سایر کرنل‌های استاندارد و موجکی پیشنهاد شده توسط سایر محققین برای ELM و همچنین الگوریتم LS-SVM مقایسه شد. کرنل LWP پیشنهاد شده در این پژوهش، که بر مبنای موجک لیتلود پالی اصلاح شده حاصل شده، باعث افزایش

واژه‌نامه

- | | | |
|--|--|---|
| 1. modal strain energy | 19. wavelet | 40. linear kernel |
| 2. residual modal force | 20. Morlet | 41. polynomial kernel |
| 3. frequency response function (FRF) | 21. seismic reliability assessment of reinforced concrete structures | 42. Gaussian kernel (radial basis function) |
| 4. little modified particle swarm optimization | 22. soil-structure interaction | 43. time-frequency localization |
| 5. space structure | 23. hybrid kernel | 44. quadratic continuous integral space |
| 6. orthogonal matching pursuit | 24. radial basis | 45. generalization |
| 7. finite element model updating procedure | 25. thin plate spline | 46. Mercer's condition |
| 8. degree of freedom | 26. Littlewood-Paley(LWP) | 47. harmonic |
| 9. surrogate model | 27. hessian matrix | 48. orthogonal function |
| 10. neural networks | 28. elements | 49. band scalar adjusting |
| 11. adaptive neuro-fuzzy inference system (ANFIS) | 29. finite difference methods | 50. flexible coefficient |
| 12. Gaussian process (GP) | 30. dynamic of structure | 51. hyper-plane |
| 13. least square support vector machine (LS-SVM) | 31. complex nonlinear mappings | 52. border |
| 14. single layer feedforward neural network (SLFN) | 32. hidden layers bias | 53. nonlinear constrained optimization |
| 15. flexural plate | 33. reduced gradient method | 54. damage scenario |
| 16. large scale | 34. feed forward back propagation learning process | 55. mean square error (MSE) |
| 17. extreme learning machine (ELM) | 35. activation function | 56. dissemination |
| 18. kernel | 36. Sigmoid | 57. horizontal floating |
| | 37. regression | 58. flexible orthonormal |
| | 38. classification | 59. structural health monitoring |
| | 39. stochastic neuron | |

مراجع

1. قدرتی امیری، غ و زارع حسین‌زاده، ع.، "تشخیص آسیب در قاب‌های برشی با کمک نگره وابستگی خاکستری و جابه‌جایی ایستایی تخمین زده شده با داده‌های مودال محدود"، نشریه روش‌های عددی در مهندسی، سال ۳۴، شماره ۱، ص ۱۳۹-۱۵۴، تابستان ۱۳۹۴.
2. Ghiasi, R., Torkzadeh, P., and Noori, M., "Structural Damage Detection using Artificial Neural Networks and Least Square Support Vector Machine with Particle Swarm Harmony Search Algorithm", *International Journal of Sustainable Materials and Structural Systems*, Vol. 1, pp. 303-320, 2014.
3. Xu, Y., Qian, Y., Chen, J., and Song, G., "Probability-Based Damage Detection using Model Updating with Efficient Uncertainty Propagation", *Mechanical Systems and Signal Processing*, Vol. 60, pp. 958-970, 2015.
4. Zang, C., and Imregun, M., "Structural Damage Detection using Artificial Neural Networks and Measured FRF Data Reduced Via Principal Component Projection", *Journal of Sound and Vibration*, Vol. 242, No. 5, pp. 813-827, 2001.
5. Sampaio, R. P. C., Maia, N. M. M., and Silva, J. M. M., "Damage Detection using the Frequency-Response-Function Curvature Method", *Journal of Sound and Vibration*, Vol. 226, No. 5, pp. 1029-1042, 1999.
6. Torkzadeh, P., and Khamseh, M., "Structural Engineering a Two-Stage Damage Detection Method for Truss Structures using FRF Data and LMP SO Algorithm", *Iranian Journal of Structural Engineering*, Vol. 1, No. 2, pp. 114-125, 2014.
7. Link, R. J., and Zimmerman, D. C., "Structural

- Damage Diagnosis using Frequency Response Functions and Orthogonal Matching Pursuit: Theoretical Development”, *Structural Control and Health Monitoring*, Vol. 22, No. 6, pp. 889-902, 2015.
8. Hakim, S. J. S., and Razak, H. A., “Modal Parameters Based Structural Damage Detection using Artificial Neural Networks-A Review”, *Smart Structures and Systems*, Vol. 14, No. 2, pp. 159-189, 2014.
 9. Ghiasi, R., Ghasemi, M. R., and Noori, M., “Comparison of Seven Artificial Intelligence Methods for Damage Detection of Structures”, In: Kruis, J., Tsompanakis, Y., and Topping, B. H. V., (Eds.), *Proceedings of the Fifteenth International Conference on Civil, Structural and Environmental Engineering Computing*, CivilComp Press, Stirlingshire, UK, Paper 116, 2015.
 10. Fathnejat, H., Torkzadeh, P., Salajegheh, E., and Ghiasi, R., “Structural Damage Detection by Model Updating Method Based on Cascade Feed-Forward Neural Network as an Efficient Approximation Mechanism”, *International Journal of Optimization in Civil Engineering*, Vol. 4, No. 4, pp. 451-472, 2014.
 11. Khatibinia, M., Salajegheh, E., Salajegheh, J., and Fadaee, M. J., “Reliability-Based Design Optimization of Reinforced Concrete Structures Including Soil-Structure Interaction using a Discrete Gravitational Search Algorithm and a Proposed Metamodel”, *Engineering Optimization*, Vol. 45, No. 10, pp. 1147-1165, 2013.
 12. Khatibinia, M., Javad Fadaee, M., Salajegheh, J., and Salajegheh, E., “Seismic Reliability Assessment of RC Structures Including Soil-Structure Interaction using Wavelet Weighted least Squares Support Vector Machine”, *Reliability Engineering & System Safety*, Vol. 110, pp. 22-33, 2013.
۱۳. قیاسی، ر.، "عیب‌یابی سازه‌ها با استفاده از روش‌های پیشرفته هوش مصنوعی"، پایان‌نامه کارشناسی ارشد مهندسی عمران- سازه، دانشگاه شهید باهنر کرمان، کرمان، شهریور ۱۳۹۲.
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. Naeim, F., “Dynamics of Structures-Theory and Applications to Earthquake Engineering”, *Earthquake Spectra*, Vol. 23, No. 2, pp. 491-492, 2007.
 16. Craig, R. R., and Kurdila, A. J., *Fundamentals of Structural Dynamics*, John Wiley & Sons, 2006.
 17. Girard, A., and Nicolas, R., *Structural Dynamics in Industry*, Vol. 7, John Wiley & Sons, 2010.
 18. Sánchez, J. C. H., and Carlos, J. “Evaluation of Structural Damage Identification Methods Based on Dynamic Characteristics”, Ph.D Thesis, University of Puerto Rico, Mayagüez, 2005.
 19. Huang, G.-B., Zhu, Q.-Y., and Siew, C.-K., “Extreme Learning Machine: Theory and Applications”, *Neurocomputing*, Vol. 70, No. 1-3, pp. 489-501, 2006.
 20. Sahoo, S., Mohapatra, S. K., and Panda, B., “Classification Using Extreme Learning Machine”, *Compusoft, An International Journal of Advanced Computer Technology*, Vol. 2, No. 12, p. 415-421, 2013.
 21. Huang, G., Member, S., Zhou, H., Ding, X., and Zhang, R., “Extreme Learning Machine for Regression and Multiclass Classification”, *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, Vol. 42, No. 2, pp. 513-529, 2012.
 22. Huang, G.-B., “An Insight Into Extreme Learning Machines: Random Neurons, Random Features and Kernels”, *Cognitive Computation*, Vol. 6, No. 3, pp. 376-390, 2014.
 23. Xing, Y., Wu, X., and Xu, Z., “Multiclass Least Squares Wavelet Support Vector Machines”. *Proceedings of the IEEE International Conference on Networking, Sensing and Control*, Sanya, China, pp. 498-502, 2008.
 24. Cortes, C., and Vapnik, V., “Support-Vector Networks”, *Machine learning*, Vol. 20, No. 3, pp. 273-297, 1995.
 25. Suykens, J. A., and Vandewalle, J. “Least Squares Support Vector Machine Classifiers”, *Neural Processing Letters*, Vol. 9, No. 3, pp. 293-300, 1999.
 26. Yazdanpanah, O., Seyedpoor, S. M., and Bengar, H. A., “A New Damage Detection Indicator for Beams Based on Mode Shape Data”, *Structural Engineering and Mechanics*, Vol. 53, No. 4, pp. 725-744, 2015.
 27. Gholizadeh, S., Salajegheh, E., and Torkzadeh, P., “Structural Optimization with Frequency Constraints by Genetic Algorithm using Wavelet Radial Basis Function Neural Network”, *Journal of Sound and Vibration*, Vol. 312, No. 1-2, pp. 316-331, 2008.