

## تحلیل قابلیت اعتماد سازه‌ها براساس روش ترکیبی کوچک‌ترین مربعات دستگاه بردارهای پشتیبان و شبیه‌سازی مونت کارلوی پیشرفته\*

(باداشه پژوهشی)

بهروز احمدی ندوشن<sup>(۱)</sup>محمد مهدی مجاهد<sup>(۲)</sup>

**چکیده** با توجه به کوچک بودن احتمال خرابی سازه‌ها، تحلیل قابلیت اعتماد سازه‌ها هزینه زمانی بالایی را به همراه خواهد داشت. در این مقاله، به منظور کاهش زمان محاسبات، الگوریتمی براساس ترکیب روش رگرسیونی کوچک‌ترین مربعات دستگاه بردارهای پشتیبان و دو روش شبیه‌سازی مونت کارلوی پیشرفته: نمونه‌برداری باهمیت و ابرمکعب لاتینی، ارائه شده است. با ارائه دو مثال قاب و یک مثال خرپا کارایی الگوریتم‌های پیشنهادی مورد ارزیابی قرار گرفته است. نتایج حاصل نشان می‌دهد که روش پیشنهادی می‌تواند احتمال خرابی را به خوبی تخمین زند و زمان محاسبات در مقایسه با دیگر روش‌های ارائه شده در سال‌های اخیر بسیار کمتر می‌باشد.

**واژه‌های کلیدی** قابلیت اعتماد سازه‌ها، روش‌های پیشرفته شبیه‌سازی مونت کارلو، دستگاه بردارهای پشتیبان، احتمال خرابی.

## Least Squares Support Vector Machine-based Advance Monte Carlo Methods for Reliability Analysis of Structures

M. Mojahed

B. Ahmadi-Nedushan

**Abstract** The failure probability of structures are rather small and therefore calculation of structural reliability generally has a high computational cost. In order to reduce computational costs, this articles proposes a hybrid approach based on combination of the least squares support vector regression and two advanced Monte Carlo methods: importance sampling and Latin hypercube sampling. Two frames and one truss example are used to evaluate the performance of the proposed algorithm. Results demonstrate that proposed method provides an accurate estimation of failure probability and that the computational costs are lower than those of other methods.

**Key Words** Structural Reliability, Advanced Monte Carlo Methods, Support Vector Machine, Failure Probability.

\* تاریخ دریافت مقاله ۹۱/۱۲/۳ و تاریخ پذیرش آن ۹۲/۱۱/۹ می‌باشد.

(۱) نویسنده مسئول، دانشجوی کارشناسی ارشد سازه، دانشکده عمران، پردیس فنی و مهندسی، دانشگاه یزد.

Email: mahdimojahed@gmail.com

(۲) دانشیار دانشکده عمران، پردیس فنی و مهندسی، دانشگاه یزد.

متغیرهای زیادی هستند، کمتر می‌شود و هزینه زمانی زیادی را برای آموزش مدل صرف می‌کند. برای رفع مشکلات ناشی از این روش، بای گانچن در سال ۲۰۰۹ به بررسی کاربردهای روش رگرسیونی کوچک‌ترین Least Squares مربعات دستگاه بردارهای پشتیبان (Support Vector Machine) (LSSVM) و ترکیب آن با روش نمونه‌برداری مونت‌کارلوی معمولی پرداخت و با ارائه مثال‌های عددی نشان داد که این روش در مقایسه با روش SVM از کارایی بالاتری از لحاظ کاهش هزینه زمانی برخوردار است [10].

باتوجه به اینکه کاربرد روش LSSVM اخیراً به عنوان نسخه بهبودیافته‌ای از SVM در سایر رشته‌های علوم و مهندسی بسیار مورد توجه قرار گرفته است [13-13]، در تعیین قابلیت اعتماد سازه‌ها بسیار محدود است و هم‌چنین باتوجه به مشکلات روش‌های نوین دیگر برای کاهش زمان محاسبات؛ لذا در این مقاله از این روش استفاده شده است. زمان ناشی از تعداد تحلیل براساس روش شبیه‌سازی مونت‌کارلوی معمولی زیاد می‌باشد لذا در این مقاله با استفاده از روش‌های نمونه‌برداری بالهمیت و ابرمکعب لاتینی و براساس اطلاعات اضافی مسئله، نواحی انتخابی نمونه‌ها در قسمت‌های مهم و موثر فضای متغیرها محدود شده و بدین ترتیب تعداد تحلیل‌های مورد نیاز و درنتیجه زمان کل محاسبات نسبت به روش شبیه‌سازی مونت‌کارلوی معمولی کاهش داده می‌شود.

در ادامه باتوجه به اصولی که هر کدام از روش‌های پیشنهادی در کاهش زمان محاسبات دارند، به بررسی روش‌های نمونه‌برداری بالهمیت و ابرمکعب لاتینی درجهت تولید نمونه‌ها برای تحلیل سازه‌ها و سپس به فرمول‌بندی LSSVM پرداخته می‌شود. درنهایت با ارائه نمونه‌هایی از سازه‌های اسکلتی (دو قاب و یک خرپا)، کارایی بالای الگوریتم‌های پیشنهادی در مقایسه با سایر روش‌های نوین ارائه شده در سالیان اخیر جهت تحلیل قابلیت اعتماد این سازه‌ها نشان داده شده

## مقدمه

قابلیت اعتماد، موضوعی بالهمیت در تحلیل و طراحی سازه‌ها می‌باشد. بحث اصلی تحلیل قابلیت اعتماد سازه‌ها، محاسبه تخمین احتمال خرابی ناشی از عدم قطعیت پارامترها خواهد بود. بهدلیل ماهیت غیرقطعی پارامترهای سازه و در دسترس نبودنتابع حالت حدی به فرم ریاضی، محاسبه اینمی مطلق غیرممکن می‌باشد [1].

باتوجه به مشکلات روش‌های تحلیلی و شبیه‌سازی، از اوایل دهه ۸۰ میلادی روش‌های سطح پاسخ به منظور کاهش حجم محاسبات و درنتیجه کاهش هزینه زمانی ناشی از روش‌های المان محدود به کار گرفته شدند. ایده اساسی این روش‌ها، جایگزینی توابع حالت حدی با توابع سطح پاسخ ساده‌تر می‌باشد. با تخمین تابع عملکرد مناسب، می‌توان تحلیل قابلیت اعتماد سازه‌ها را به درستی انجام داد [2-4].

در دو دهه اخیر با پیشرفت تحقیقات در زمینه هوش مصنوعی، روش شبکه عصبی مصنوعی به منظور تقریب تابع عملکرد به سرعت جایگزین روش‌های پیشین شد. کاربرد و جوانب مختلف روش شبکه عصبی در بسیاری از مقالات مطرح شده است [5-7]. شبکه عصبی با تمام مزیت‌هایی که نسبت به روش‌های کلاسیک دارد، در بسیاری از مسائل سازه‌ای با تعداد متغیرهای زیاد می‌تواند هزینه زمانی نسبتاً زیادی، برای محاسبات دربرداشته باشد [8].

در همین راستا برای رفع مشکلات شبکه عصبی، روش رگرسیونی دستگاه بردار پشتیبان (Support Vector Machine) (SVM) به عنوان یک روش یادگیری هوشمند برای به دست آوردن مدل رگرسیونی مناسب، به کار گرفته شده است. و اینکه، برای اولین بار در سال ۱۹۹۸، این روش را براساس تئوری بهینه‌یابی پیشنهاد داد [9]. روش SVM برای تقریب تابع عملکرد با افزایش تعداد داده‌های آموزشی، کارایی مناسبی از خود نشان نمی‌دهد لذا کارایی آن برای سازه‌هایی که دارای

خرابی واقعند برابر ۱ و در غیر این صورت برابر صفر درنظر گرفته می شود. تابع  $h_v(v)$  نیز به عنوان تابع چگالی بالاهمیت مناسب می باشد. یک تخمین ناریب از احتمال خرابی به صورت رابطه (۴) بیان می شود.

$$p_f = \frac{1}{N} \sum_{j=1}^N \left( I(V_j) \frac{f_x(V_j)}{h_v(V_j)} \right) \quad (4)$$

در رابطه (۴) نمونه تصادفی  $V_i$  با استفاده از تابع توزیع بالاهمیت  $h_v(v)$  تولید شده و  $f_x(v)$  نیز تابع توزیع احتمال اصلی متغیرها است [۱۵].

### روش نمونه برداری ابرمکعب لاتینی [۱۶] (Latin Hypercube Sampling (LHS))

روش نمونه برداری ابرمکعب لاتینی برای اولین بار توسط «مکی» در سال ۱۹۷۹ ارائه شد [۱۶]. این روش براساس روش لا یه لایه شده (The Layered Method) به تقسیم محدوده تغییرات هر متغیر به صورت احتمال مساوی می پردازد. بدین ترتیب فضای متغیرها عملاً به صورت ابرمکعب هایی تقسیم می شود. سپس نمونه گیری از محدوده هر یک از این ابرمکعب ها به عمل می آید و براساس قضیه احتمال کل،  $P_f$  به دست می آید. در این روش تعدادی از مقادیر ممکن هر متغیر که به لا یه هایی جزء بنده شده است، انتخاب می شود و یک مقدار از هر لا یه به طور تصادفی به عنوان مقدار نماینده انتخاب می گردد. تابع حالت حدی  $Y$  با  $K$  متغیر تصادفی به صورت رابطه (۵) می باشد.

$$Y = f(x_1, x_2, \dots, x_k) \quad (5)$$

برای به دست آوردن اولین ترکیب، از هر متغیر تصادفی  $K$ ، یک نماینده به طور تصادفی انتخاب می شود. برای به دست آوردن دومین ترکیب، یک نماینده به طور تصادفی از  $N-1$  مقدار باقی مانده هر متغیر تصادفی  $K$  انتخاب می شود و این مراحل تا به دست آوردن  $N$  ترکیب از متغیرهای تصادفی ادامه داده می شود و درنهایت  $N$  مقدار نماینده برای هر کدام از  $K$  متغیر تصادفی به دست می آید. در کل،  $N^K$  ترکیب محتمل از

است.

### روش نمونه برداری بالاهمیت

#### (Importance Sampling Method (ISM))

روش نمونه گیری بالاهمیت یکی از روش های پیشرفتۀ مونت کارلو می باشد که برای تخمین میزان احتمال خرابی و هم چنین تعیین محدوده های خرابی، مورد استفاده قرار می گیرد. اگر ناحیه خرابی به دست آمده از تحلیل سازه ها  $D$  باشد، آن گاه در حالت کلی احتمال خرابی هر سازه براساس تحلیل قابلیت اعتماد در این ناحیه، براساس رابطه (۱) بیان می شود [۱۴].

$$p_f = \int_{D} \dots \int f_x(x) dx \quad (1)$$

در رابطه (۱)،  $f_x(x)$  تابع چگالی احتمال مشترک متغیرها،  $D$  ناحیه خرابی معین شده به وسیله یک یا چند تابع حالت حدی و  $P_f$  میزان احتمال خرابی سازه می باشد. با تعریف تابع نشانگر  $I(x)$  به گونه ای که به ازای نمونه های واقع در ناحیه خرابی  $I(x) = 1$  و در سایر موارد  $I(x) = 0$  باشد، می توان رابطه (۱) را برای همه متغیرها به صورت رابطه (۲) بیان نمود [۳].

$$p_f = \int_{D} \dots \int I(x) f_x(x) dx \quad (2)$$

برای تولید و شبیه سازی نمونه ها، به جای استفاده از تابع توزیع احتمالی اصلی متغیرها،  $f_x(x)$ ، از یک تابع چگالی احتمال جدید  $h_v(v)$  با عنوان تابع چگالی نمونه گیری بالاهمیت استفاده می شود. بنابراین نتایج شبیه سازی باید به صورت توابع وزنی برای تخمین تابع چگالی بالاهمیت، به کار گرفته شوند. با توجه به موارد ذکر شده، احتمال خرابی رابطه (۲) به صورت رابطه (۳) تصحیح می شود.

$$p_f = \int_{D} \dots \int \left\{ I(V) \frac{f_x(V)}{h_v(V)} \right\} h_v(V) dx \quad (3)$$

در رابطه (۳)، تابع  $I(V)$  به عنوان یک تابع نشانگر می باشد. مقدار این تابع برای نقاطی که در محدوده

نمونه اصلی تبدیل می‌کند.

$$f(x, w) = W \cdot \Phi(x) + b \quad (8)$$

بنابراین الگوریتم LSSVM قادر به تعیینتابع رگرسیونی براساس یک مسئله بهینه‌سازی برمنای برنامه‌ریزی غیرخطی ( $\|w\|^2$ ) طبق رابطه (۹) و با قید تساوی (۱۰) می‌باشد.

$$\min j(w, e) = \frac{1}{2} w^T w + \gamma \sum_{i=1}^l e_i^2 \quad (9)$$

$$y_i = w^T \Phi(x_i) + b + e_i \quad (10)$$

$i = 1, \dots, l$

تابع لاغرانژ به صورت رابطه (۱۱) به دست می‌آید و با مشتق‌گیری از تابع لاغرانژ جمله‌ای قیود بهینه‌یابی نیز به صورت روابط (۱۲) به دست می‌آیند.

$$L(w, b, e, a) = j(w, e) - \sum_{i=1}^l a_i (w^T \Phi(x_i) + b + e_i - y_i) \quad (11)$$

$$\begin{aligned} \frac{\partial L}{\partial b} &= 0 \rightarrow -\sum_{i=1}^l a_i = 0 \\ \frac{\partial L}{\partial w} &= 0 \rightarrow w = \sum_{i=1}^l a_i \Phi(x_i) \\ \frac{\partial L}{\partial e_i} &= 0 \rightarrow a_i = \gamma e_i \\ \frac{\partial L}{\partial a_i} &= 0 \rightarrow w^T \Phi(x_i) + b + e_i - y_i = 0 \end{aligned} \quad (12)$$

روابط (۱۲) را برای سادگی می‌توان به صورت ماتریسی به شکل رابطه (۱۳) نمایش داد.

$$\begin{bmatrix} I & 0 & 0 & -Z^T \\ 0 & 0 & 0 & -1^T \\ 0 & 0 & \gamma I & -I \\ Z & 1 & I & 0 \end{bmatrix} \begin{bmatrix} w \\ b \\ e \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ y \end{bmatrix} \quad (13)$$

در رابطه ماتریسی (۱۳)، پارامترها براساس روابط (۱۴) به دست می‌آیند.

$$y = [y_1 \ y_2 \ \dots \ y_l]^T \quad (14)$$

این مقادیر می‌تواند وجود داشته باشد. هدف روش ابرمکعب لاتینی این است که با انتخاب  $N$  ترکیب از این مقادیر نماینده، یکی و تنها یک مقدار از  $N$  ترکیب را به دست آورد.

### فرمول‌بندی روش رگرسیونی کوچک‌ترین مربعات دستگاه بردارهای پشتیبان (LSSVM) [10-11]

تابع توزیع معین  $P(x, y)$  که در آن  $x \in R^n$ ,  $y \in R$  است، را در نظر بگیرید، درنتیجه می‌توان نقاط نمونه‌برداری را براساس رابطه (۶) به صورت نگاشت نقاط در فضای  $R^d$  به  $R$  تولید نمود.

$$D : \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\} \subset R^d \times R \quad (6)$$

در رابطه (۱۱)،  $x_t$  بردارهای ورودی،  $y_t$  مقدار تابع حالت حدی،  $t = 1, 2, \dots, l$ ،  $d$  ابعاد بردار و  $l$  تعداد مشاهدات ورودی‌ها و خروجی می‌باشد. می‌توان رابطه بین بردارهای ورودی  $x$  و خروجی  $y$  را به صورت  $y = f(x)$  در نظر گرفت. اگر رابطه خطی بین نقاط نمونه‌برداری، فرض شود، آنگاه تابع رگرسیونی به صورت  $f(x) = W^T(X) + b$  به دست می‌آید. در این تابع  $W$  و  $b$  به ترتیب بردار وزن و عرض مدل به دست آمده می‌باشد. خطای آموزشی تابع براساس کمترین ریسک به صورت رابطه (۷) به دست می‌آید.

$$\min j(w, e) = \frac{1}{2} w^T w + \gamma \sum_{i=1}^l e_i^2 \quad (7)$$

در رابطه (۷)،  $0 < \gamma < \infty$  و تابع  $f$  براساس روابطی که در ادامه ذکر می‌شود به دست می‌آید؛ اما در اغلب موارد، ارتباط غیرخطی بین بردارهای ورودی و خروجی برقرار می‌باشد. درنتیجه تابع رگرسیونی براساس تابع غیرخطی  $\Phi$  به فضایی با ابعاد بزرگ‌تر تبدیل می‌شود و درنتیجه رگرسیون خطی به رگرسیونی با ابعاد بالاتر تبدیل می‌شود. درنتیجه اگر بین نقاط نمونه‌برداری ورودی و خروجی رابطه غیرخطی (۸) فرض شود، آنگاه روش LSSVM به وسیله تابع غیرخطی  $\Phi$ ، تابع رگرسیون خطی را به یک تابع غیرخطی در فضای

تخمین دقت مناسب برای داده‌های آزمایشی می‌باشد. برای ایجاد چنین مدلی، باید براساس میزان‌سازی بین مدل آموزش‌دیده و مقادیر تابع حالت حدی واقعی، تابع پاسخ مناسبی را به دست آورد، این در حالی است که مدل‌های دیگر با توجه به عدم میزان‌سازی ممکن است توابع نامناسبی را به دست آورند. با توجه به این که حل انتگرال مونت‌کارلوی معمولی رابطه (۲) در سازه‌های خرپایی و قاب‌های فولادی که دارای توابع حالت حدی با متغیرهای زیادی هستند، نیاز به زمان بسیار زیادی خواهد داشت. بنابراین برای تسهیل در انتگرال‌گیری، از روش‌های نمونه‌برداری بالاهمیت و ابرمکعب لاتینی استفاده شده است. با توجه به این که واریانس مقدار  $P_f$  با  $\sigma_{\epsilon(x)}^2$  (واریانس متغیرها) رابطه مستقیم و با تعداد نمونه‌های تولید شده رابطه عکس دارد درنتیجه انحراف معیار مقدار  $P_f$  و حاصل تخمین مونت‌کارلو با نسبت  $\frac{1}{N^2}$  کاهش می‌یابد و این حکایت از همگرایی کند روشن مونت‌کارلو دارد. همگرایی کند روشن مونت‌کارلو با روش‌های LHS و ISM که برمبنای کاهش واریانس هستند جبران خواهد شد. با توجه به این که روش نمونه‌برداری بالاهمیت برای افزایش تعداد نقاط نمونه‌گیری در ناحیه خرابی، از یک تابع چگالی احتمال که تأیید آن بر روی ناحیه خرابی است، استفاده می‌نماید، روش مناسبی برای نمونه‌برداری داده‌ها می‌باشد. برای انجام نمونه‌گیری و پخش نمونه‌ها در نمونه‌برداری ابرمکعب لاتینی نیز برای تحلیل قابلیت اعتماد سازه‌های پیچیده‌ای که زمان محاسبه فقط یک نمونه شبیه‌سازی آن ممکن است بسیار زیاد باشد، به منظور کاهش تعداد نمونه‌های مورد نیاز مناسب است. با توجه به مطلب ارائه شده، براساس روش‌های پیشرفتة مونت‌کارلو تعداد تحلیل سازه نسبت به روش مونت‌کارلوی معمولی به طور قابل توجهی کاهش می‌یابد اما هم‌چنان تحلیل المان محدود امری ضروری می‌باشد.

$$\begin{aligned} Z &= [\Phi(x_1) \quad \Phi(x_2) \quad \dots \quad \Phi(x_n)]^T \\ e &= [e_1 \quad e_2 \quad \dots \quad e_n]^T \\ a &= [a_1 \quad a_2 \quad \dots \quad a_n]^T \\ 1 &= [1 \quad 1 \quad \dots \quad 1]^T \end{aligned}$$

باتوجه به این که در مسائل بهینه‌یابی محاسبه ضرب داخلی  $\Phi(x_i) \cdot \Phi(x_j)$  مشکل می‌باشد، بنابراین به منظور تسهیل در محاسبات می‌توان تابع کرنل  $\Psi(x_i, x_j)$  را در روابط (۱۴) به جای ضرب داخلی نمود.

$$\Omega_{kj} = (\Phi(x_i))^T \Phi(x_j) = \Psi(x_i, x_j) \quad (15)$$

(k,j=1,2,...,n)

برای تعیین پارامترهای تابع رگرسیونی انتخابی (a و b) می‌توان با حذف e و w در رابطه (۱۴) و با استفاده از رابطه (۱۵)، رابطه (۱۶) را به دست آورد.

$$\begin{bmatrix} 0 & 1^T \\ 1 & \Omega + \gamma^{-1} I \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (16)$$

در رابطه (۱۶) بافرض  $I = \Omega + \gamma^{-1} I$  و باتوجه به معین بودن ماتریس فرض شده، می‌توان پارامترهای تابع رگرسیونی را براساس روابط (۱۷) به دست آورد.

$$a = A^{-1}(y - bI) \quad (17)$$

$$b = \frac{1^T A^{-1} y}{1^T A^{-1} 1}$$

با استفاده از اولین رابطه از روابط (۱۲) و جایگزینی آن با رابطه (۱۵)، تابع رگرسیونی انتخابی به صورت رابطه (۱۸) به دست می‌آید.

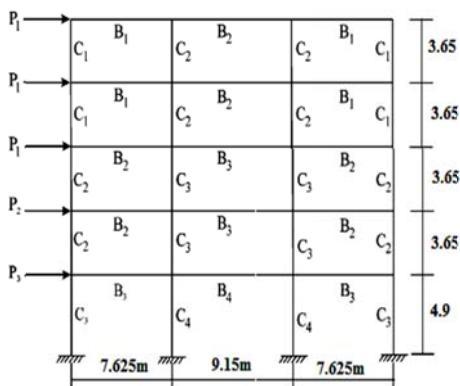
$$f(x) = \sum_{i=1}^n a_i \Psi(x, x_i) + b \quad (18)$$

**الگوریتم‌های پیشنهادی براساس ترکیب LSSVM با روش‌های نمونه‌برداری بالاهمیت و ابرمکعب لاتینی (LSSVM-ISM, LSSVM-LHS)**

ایدهٔ روش‌های پیشنهادی، به دست آوردن مدلی کارا و مناسب برای توصیف مجموعه داده‌های آموزشی و

در انتگرال‌گیری عددی به کار می‌رود. در ادامه به بررسی تحلیل قابلیت اعتماد سازه با توابع حالت حدی و تعداد متغیرهای مختلف پرداخته و کارایی بالای الگوریتم‌های پیشنهادی نسبت به دیگر روش‌های نوین نشان داده می‌شود. تعداد داده‌های آزمایش برابر ۲۵ و تعداد تحلیل‌ها برابر ۵۰ درنظر گرفته شده است. نتایج نشان‌دهنده کارایی بالای روش‌های پیشنهادی نسبت به دیگر روش‌ها می‌باشد. بهمنظور تشکیل مدل کارا، برای هر سازه، تحلیل حساسیت بر روی مجموعه داده‌های آموزشی انجام شده و مناسب‌ترین تعداد داده برای آموزش به‌دست آمده است.

**مثال ۱: قاب پرتال فولادی با ۳ دهانه و ۵ طبقه.**  
تحلیل این قاب برای اولین بار توسط آقایان بوچر و بورگاند ارائه شد [15]. شمای این قاب در شکل (۱) نشان داده شده است.



شکل ۱ شمای قاب پرتال خطی ۳ دهانه ۵ طبقه

این قاب پرتال شامل ۲۱ متغیر تصادفی می‌باشد. این متغیرها شامل مدول یانگ، ممان اینرسی، سطح مقطع اعضا با توزیع نرمال و همچنین بارهای جانبی با تابع توزیع رایلی می‌باشد. خصوصیات و پارامترهای آماری این متغیرها براساس جداول (۱) و (۲) می‌باشند. اگر جابه‌جایی مجاز این طبقه برابر با ۱۰ سانتی‌متر باشد، آن‌گاه معیار خرابی براساس تحلیل المان محدود به صورت تابع حالت حدی رابطه (۱۹) می‌باشد.

همان‌طور که در قسمت‌های قبل ذکر شد، روش‌هایی از قبیل شبکه عصبی بر پایه اصل مینیمم‌سازی ریسک تجربی و براساس توپولوژی مناسب تنها می‌توانند خطای آموزش را کاهش دهند و تعمیم‌دهنده کل داده‌ها نمی‌باشند و درنتیجه روش تحلیلی مناسبی برای پیش‌بینی رفتار سازه نمی‌باشند، این در حالی است که روش LSSVM بر پایه اصل مینیمم‌سازی ریسک سازه‌ای و بدون نیاز به توپولوژی با ایجاد مدلی مناسب و تعمیم آن به کل داده‌ها، روش تحلیلی مناسبی برای پیش‌بینی رفتار سازه ارائه می‌دهد و علاوه بر به‌دست آوردن خطای مناسب، زمان محاسبات را نیز به‌مقدار قابل توجهی کاهش خواهد داد.

در این مقاله الگوریتمی براساس ترکیب روش رگرسیونی LSSVM با روش‌های نمونه‌برداری بالهمیت و ابرمکعب لاتینی ارائه شده است. اصول کلی این الگوریتم بدین صورت است که ابتدا مجموعه‌ای از داده‌ها که براساس روش‌های نمونه‌برداری بالهمیت و ابرمکعب لاتینی ایجاد شده‌اند، به دو گروه داده‌های آموزشی و آزمایشی تقسیم می‌شوند و پارامترهای مدل باستفاده از آموزش مجموعه داده‌های آموزشی (آموزش مدل LSSVM) و براساس توابع مختلف کرنل، به‌دست می‌آیند. براساس مدل آموزش یافته، تابع رگرسیونی جدیدی محاسبه می‌شود و درنهایت مقادیر تابع رگرسیونی به‌ازای داده‌های نمونه‌برداری شده محاسبه می‌شود و میزان احتمال خرابی تخمین زده می‌شود. الگوریتم‌های ترکیبی براساس اصولی که هر کدام از روش‌ها دارند، برتری‌های خاصی نسبت به تک‌تک آنها دارد. یکی از این مزیت‌ها، کاهش تعداد نمونه‌ها توسط روش‌های نمونه‌برداری پیشنهادی و کاهش تعداد تحلیل‌های المان محدود برای تعیین احتمال خرابی است که در صورت استفاده از مدل رگرسیونی LSSVM به صورت قابل توجهی کاهش می‌یابد. روش‌های نمونه‌برداری برای تعیین نمونه‌ها و مدل LSSVM برای تقریب محدوده خرابی به‌منظور تسهیل

$$G(X) = 10 - U_x \quad (19)$$

جدول ۱ خصوصیات اعضاي قاب ۳ دهانه ۵ طبقه

اعضا	مدول یانگ	ممان اینرسی	سطح مقطع
B1	E1	I5	A5
B2	E1	I6	A6
B3	E1	I7	A7
B4	E1	I8	A8
C1	E2	I1	A1
C2	E2	I2	A2
C3	E2	I3	A3
C4	E2	I4	A4

در رابطه (۱۹)،  $U_x$  جابه‌جایی افقی واقعی بر حسب تابعی از متغیرهای تصادفی می‌باشد. نتایج به دست آمده براساس الگوریتم‌های پیشنهادی همچنین نتایج روش‌های مراجع دیگر در جدول (۳) ارائه شده است (مقدار احتمال خرابی دقیق براساس روش شبیه‌سازی مونت‌کارلوی معمولی و با ۵۰۰۰۰۰ نمونه بعد از ۱۰ بار تحلیل پیاپی در زمان ۹۵۱۲ ثانیه برابر با ۰/۰۰۰۲۸۹ به دست آمده است). نتایج به دست آمده در جدول (۳) نشان‌دهنده کارایی بالای روش‌های پیشنهادی از لحاظ دقت محاسبات و کاهش هزینه محاسبات نسبت به دیگر روش‌های تحلیل این قاب

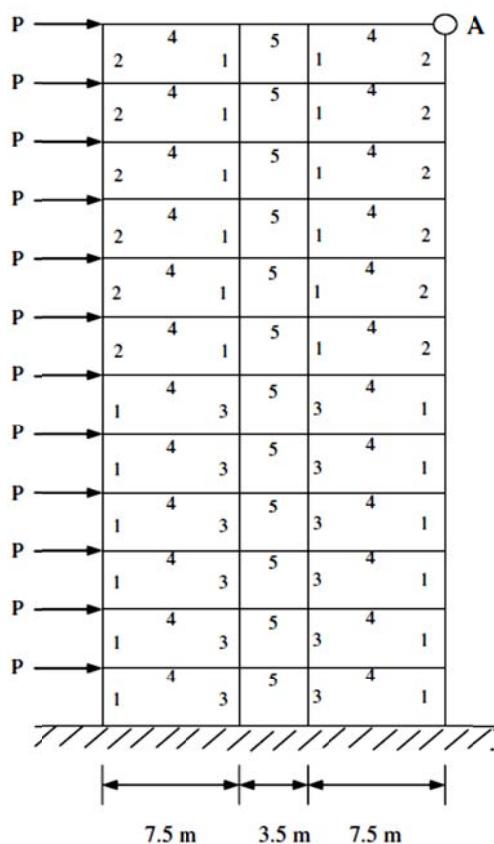
جدول ۲ پارامترهای آماری قاب ۳ دهانه ۵ طبقه

متغیر تصادفی	تابع توزیع	میانگین	انحراف معیار	واحد
P1	Rayleigh	30	9	KN
P2	Rayleigh	20	8	KN
P3	Rayleigh	16	6.4	KN
E1	Normal	45400	4000	KN/m <sup>2</sup>
E2	Normal	49700	4000	KN/m <sup>2</sup>
I1	Normal	107.47	13.72057	m <sup>4</sup>
I2	Normal	152.06	17.15071	m <sup>4</sup>
I3	Normal	282.415	34.3014	m <sup>4</sup>
I4	Normal	343.014	40.018	m <sup>4</sup>
I5	Normal	142.92	34.3014	m <sup>4</sup>
I6	Normal	186.3711	45.7352	m <sup>4</sup>
I7	Normal	307.569	74.319	m <sup>4</sup>
I8	Normal	343.014	85.753	m <sup>4</sup>
A1	Normal	35.9281	6.4157	m <sup>2</sup>
A2	Normal	42.7716	8.5543	m <sup>2</sup>
A3	Normal	58.1693	10.692	m <sup>2</sup>
A4	Normal	64.1574	12.8314	m <sup>2</sup>
A5	Normal	29.084	10.69	m <sup>2</sup>
A6	Normal	33.468	11.762	m <sup>2</sup>
A7	Normal	42.878	13.900	m <sup>2</sup>
A8	Normal	48.11805	15.504	m <sup>2</sup>

جدول ۳ نتایج روش‌های پیشنهادی و مرجع در مثال ۱

روش	تعداد نمونه	تعداد آموزشی	احتمال خرابی	زمان (ثانیه)	خطای نسبی (%)
LSSVM-MCS	500000	150	0.00029	44.62	0.34482
LSSVM-ISM	3000	50	0.000291	24.67	0.82361
LSSVM-LHS	3500	200	0.000292	44.11	1.027397
FORM [8]	-	-	0.000291	-	0.6872852
KRIGING [8]	-	-	0.00022	-	-31.36363
روش سطح پاسخ کلاسیک [8]	-	-	0.000312	-	7.494838

پیشنهادی هزینه زمانی را به نحو مؤثری کاهش می‌دهند و برآورده احتمال خرابی را با دقت مناسب ارائه می‌دهند (مقدار احتمال خرابی دقیق با  $100000$  نمونه مونت‌کارلو و با  $10$  بار تحلیل پیاپی در زمان  $5246$  ثانیه برابر با  $0.0751$  به دست آمده است، این میزان برابر مقدار دقیق ارائه شده در مرجع ۷ می‌باشد).



شکل ۲ شماتی قاب ۳ دهانه ۱۲ طبقه

## مثال ۲: قاب پرتال فولادی با ۳ دهانه و ۱۲ طبقه.

قاب مفروض شامل یک قاب پرتال الاستیک خطی با ۳ دهانه و ۱۲ طبقه می‌باشد [7,13]. شکل (۲) این قاب را به همراه تیپ‌بندی تیر و ستون‌های آن نشان می‌دهد (ارتفاع هر طبقه ۴ متر می‌باشد). سطح مقطع تیر و ستون‌ها و همچنین بار افقی وارد به قاب به عنوان متغیرهای تصادفی مستقل درنظر گرفته شده‌اند. مدول یانگ به عنوان پارامتر قطعی برابر با  $2 \times 10^7$  می‌باشد. ممان اینرسی اعضای این قاب نیز به عنوان متغیری وابسته به سطح مقطع‌ها، براساس رابطه (۲۰) بیان می‌شود.

$$I_i = a_i A_i^2 \quad (20)$$

با فرض این که ماقزیم جابه‌جایی افقی گره برابر با  $0.096$  متر باشد، آنگاه تابع حالت حدی براساس پارامترهای تصادفی فرض شده، به صورت رابطه (۲۱) درنظر گرفته می‌شود.

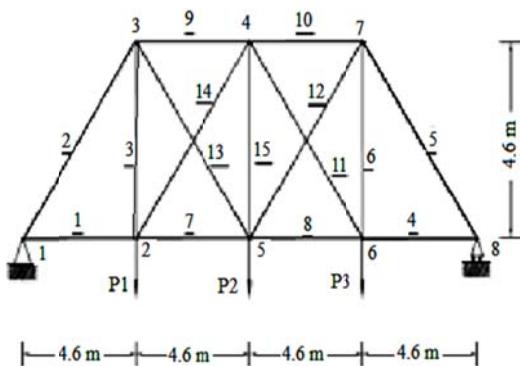
$$G(x) = 0.096 - u_A(A_1, A_2, A_3, A_4, A_5, P) \quad (21)$$

پارامترهای آماری نمونه‌های تصادفی اصلی و ضرایب ممان اینرسی این قاب نیز مطابق جدول (۴) می‌باشد. نتایج به دست آمده از روش‌های پیشنهادی براساس تعداد نمونه‌های آموزشی که براساس تحلیل حساسیت به دست آمده‌اند، به همراه نتایج روش‌های پیشنهادی مرجع اصلی به صورت جدول (۵) می‌باشد. نتایج به دست آمده نشان می‌دهند که روش‌های

با  $7/5$  سانتی متر به دست آمده است. پارامترهای آماری متغیرها، در جدول (۶)، ارائه شده است. همچنین نتایج به دست آمده از روش های پیشنهادی براساس تعداد نمونه های آموزشی که براساس تحلیل حساسیت به دست آمده اند، به همراه نتایج روش پیشنهادی مرجع اصلی به صورت جدول (۷)، می باشد. میزان احتمال خرابی دقیق در مرجع ۳ برابر  $۰/۰۱۴$  به دست آمده است.

جدول ۴ پارامترهای آماری قاب ۳ دهانه ۱۲

متغیر	میانگین	انحراف معیار	واحد	توزیع	ضرایب $a_i$
$A_1$	0.25	0.025	$m^2$	Lognormal	0.0833
$A_2$	0.16	0.016	$m^2$	Lognormal	0.0833
$A_3$	0.36	0.036	$m^2$	Lognormal	0.0833
$A_4$	0.2	0.02	$m^2$	Lognormal	0.2667
$A_5$	0.15	0.015	$m^2$	Lognormal	0.2
P	30	7.5	KN	Type I Largest	-



شکل ۳ هندسه خرپای ۱۵ عضوی

مثال ۳: خرپای ۱۵ عضوی با تابع حالت حدی جابه جایی. مثال آخر یک خرپای ۱۵ عضوی است که از مرجع ۳ برگرفته شده است. هندسه این خرپا در شکل (۳) نشان داده شده است. سطح مقطع همه ۱۵ عضو و ۳ بار متتمرکز که بر گره های ۲، ۵ و ۶ وارد شده است، به عنوان متغیرهای تصادفی مستقل از هم می باشند. مدل یانگ نیز به عنوان پارامتر قطعی برابر با  $200 \text{ GPA}$  فرض می شود. براساس تحلیل الاستیک خطی، میزان جابه جایی مجاز گرۀ میانی (گره ۵) برابر

جدول ۵ نتایج روش های پیشنهادی و مرجع در مثال ۲

روش	تعداد نمونه	تعداد داده	احتمال خرابی	زمان (ثانیه)	خطای نسبی
LSSVM-MCS	100000	100	0.07515	17.09	0.0665
LSSVM-ISM	1000	60	0.07517	8.7	0.0931
LSSVM-LHS	1000	50	0.07515	5.75	0.0665
GA-ANN [7]	-	-	0.0718	491.7	-4.596
GA-ANN-MCSIS [7]	-	160	0.0777	80.7	3.346
RBF-MCS [14]	-	257	0.07405	-	-1.417

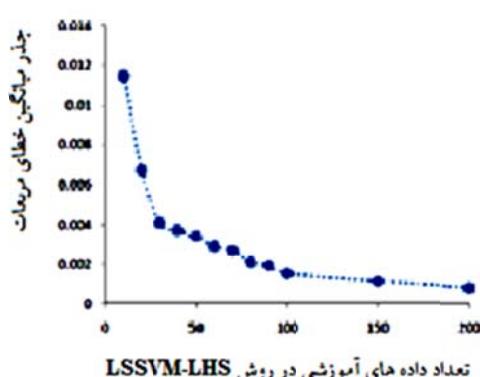
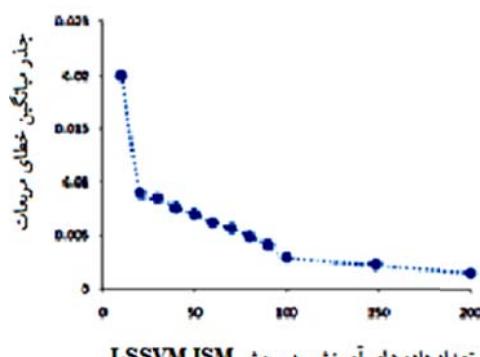
جدول ۶ پارامترهای آماری خرپای ۱۵ عضوی

متغیر	میانگین	انحراف معیار	واحد	تابع توزیع
A1-A6	10.32	0.516	$\text{cm}^2$	Normal
A7-A15	6.45	0.323	$\text{cm}^2$	Normal
Ln P1	4.483	0.09975	KN	Lognormal
Ln P2	5.582	0.09975	KN	Lognormal
Ln P3	4.483	0.09975	KN	Lognormal

جدول ۷ نتایج روش‌های پیشنهادی در مثال ۳

خطای نسبی (%)	زمان (ثانیه)	احتمال خرابی	تعداد داده‌های آموزشی	تعداد نمونه‌ها	روش‌های پیشنهادی
-0.8645	15.36	0.001388	50	1000000	LSSVR-MCS
-0.3584	3.892	0.001395	50	3500	LSSVR-LHS
-0.7194	8.375	0.00139	60	1000	LSSVR-ISM

خطای نسبی مقادیر احتمال خرابی کاهش می‌یابد. با توجه به این که مقادیر ضریب تغییرات و درصد خطای احتمال خرابی به دست آمده براساس تعداد ۵۰ و ۶۰ داده به ترتیب برای روش‌های LSSVM-LHS و LSSVM-ISM در بازه مناسبی قرار دارد، درنتیجه می‌توان براساس تحلیل حساسیت داده‌های آموزشی، این تعداد را به عنوان تعداد داده‌های آموزشی مناسب در نظر گرفت.



شکل ۴ نمودارهای جذر میانگین خطای مربعات براساس تعداد داده‌های آموزشی مختلف

تحلیل حساسیت بر روی داده‌های آموزشی و تعیین میزان خطای داده‌های تست در مثال ۲. تحلیل حساسیت بر روی مدل، براساس تعداد مختلفی از داده‌های آموزشی و با ثابت در نظر گرفتن تعداد داده‌های تست (تعداد داده‌های تست برابر با ۲۵ در نظر گرفته شده است)، انجام می‌شود. براساس این تحلیل حساسیت، محدوده مناسبی از داده‌های آموزشی به دست می‌آید. همان‌طور که در شکل (۴) قبل مشاهده است، در هر دو روش پیشنهادی LSSVM-ISM و LSSVM-LHS، میزان جذر میانگین خطای مربعات (RMSE) ناشی از مقادیر تابع حالت حدی مدل ایجاد شده برای داده‌های تست، با افزایش تعداد داده‌های آموزشی، کاهش می‌یابد.

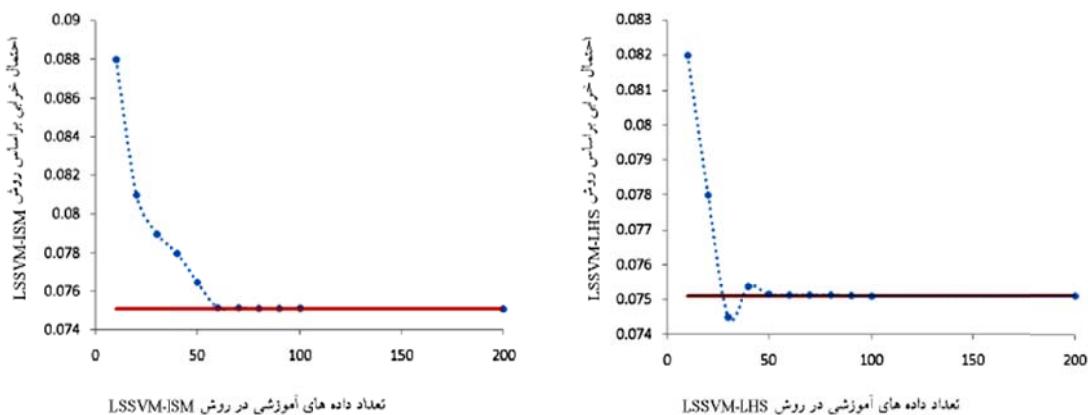
تحلیل حساسیت بر روی داده‌های آموزشی و تعیین میزان احتمال خرابی در مثال ۲. در این قسمت، تحلیل حساسیت برای یافتن بهترین مجموعه از داده‌های آموزشی، براساس میزان احتمال خرابی به دست آمده انجام شده است. این تحلیل بدین صورت است که در هر کدام از روش‌های پیشنهادی، با در نظر گرفتن تعداد مختلفی از داده‌های آموزشی، میزان احتمال خرابی سازه براساس ۱۰۰ بار تحلیل به دست می‌آید. نتایج به دست آمده در جداول (۸) و (۹) نشان داده شده است. شکل (۵) نیز مقادیر احتمال خرابی را برای تعداد داده‌های آموزشی مختلف برای هر دو روش نشان می‌دهد. مقدار ضریب تغییرات کمتر از ۰/۱ و درصد خطای کمتر از یک درصد به عنوان مقادیر مناسب در نظر گرفته می‌شوند. نتایج به دست آمده نشان می‌دهد که با افزایش تعداد داده‌های آموزشی، میزان ضریب تغییرات و درصد

جدول ۸ تحلیل حساسیت بر روی داده‌های آموزشی و تعیین احتمال خرابی در روش LSSVM-LHS

روش	تعداد نمونه	تعداد داده های آموزشی	احتمال خرابی	انحراف معیار خرابی	ضریب تغییرات	خطای نسبی	زمان
LSSVR-LHS	1000	10	0.082	0.077	0.93902	8.414	1.45
		20	0.078	0.0277	0.355128	3.717	2.05
		30	0.0745	0.0161	0.21610	-0.805	3.18
		40	0.0754	0.0077	0.102122	0.3978	4.42
		50	0.07515	0.0027	0.035928	0.0665	5.75
		60	0.075145	0.00265	0.03526	0.0598	7.15
		90	0.07512	0.0015	0.019968	0.0266	12.1
		100	0.07511	0.000756	0.010065	0.0133	14.95
		200	0.075105	0.000452	0.006018	0.0066	50.8

جدول ۹ تحلیل حساسیت بر روی داده‌های آموزشی و تعیین احتمال خرابی در روش LSSVM-ISM

روش	تعداد نمونه	تعداد داده های آموزشی	احتمال خرابی	انحراف معیار خرابی	ضریب تغییرات	خطای نسبی	زمان
LSSVR-ISM	1000	10	0.088	0.02523	0.2867045	14.659	2.04
		20	0.081	0.0232	0.2864197	7.2839	3.05
		30	0.079	0.0223	0.2822784	4.936	4.076
		40	0.078	0.01812	0.2323076	3.717	6.23
		50	0.0765	0.0104	0.1359477	1.830	7.51
		60	0.07517	0.0074	0.098443	0.0931	8.7
		90	0.07514	0.0045	0.0598882	0.05323	12.05
		100	0.07512	0.00211	0.02808	0.0266	15.74
		200	0.075108	0.000463	0.0061	0.0106	54.14



شکل ۵ نمودارهای میزان احتمال خرابی براساس تعداد مختلفی از داده‌های آموزشی

هستند که دارای فرم ریاضی نیستند و جهت تحلیل قابلیت اعتماد نیاز به زمان زیادی جهت تحلیل المان محدود خواهد داشت. هزینه زمانی صرف شده از طریق روش‌های پیشنهادی به طور قابل توجهی از روش‌های دیگر کمتر می‌باشد. در ضمن، دقت محاسبات نیز در حد معقول و حتی بهتر از روش‌های دیگر خواهد بود.

### جمع‌بندی

در این مقاله به بررسی کارایی روش‌های LSSVR-LHS و LSSVM-ISM پرداخته شد. براساس این روش‌ها و باستفاده از داده‌های آموزشی، مدل مربوط ایجاد شد و درنهایت براساس روش‌های پیشنهادی، میزان احتمال خرابی تخمین زده شد. با ارائه ۲ مثال از قاب و یک مثال خرپایی، نشان داده شد که روش‌های پیشنهادی جهت تقریبتابع رگرسیونی، برای توابعی بسیار مفید

### مراجع

- Nowak, A.S., Collins, K.R., "Reliability of Structures", *McGraw-Hill, Boston*, pp. 1-6, (2000).
- Hurtado, J.E., "An Examination of Methods for Approximating Implicit Limit State Functions From the Viewpoint of Statistical Learning Theory", *Structural Safety*, Vol. 26, pp. 271-293, (2004).
- Zhang, H., Robert, L., Muhanna, R., and Almgren, R., " Interval Monte Carlo Methods for Structural Reliability", *Structural Safety*, Vol. 32, pp. 183–190, (2010).
- Rackwitz, R., "Response Surfaces in Structural Reliability", Berichte Zur Zuverl Assign Keits Theorie der Bauwerke, Heft 67 Munchen, (1982).
- Deng, J., Gu, D., Li, X. and Yue, Z.Q., "Structural Reliability Analysis for Implicit Performance Functions Using Artificial Neural Network", *Structural Safety*, Vol. 27, pp. 25–48, (2005).
- Gomes, H.M., Awruch, A.M., "Comparison of Response Surface and Neural Network With Other Methods for Structural Reliability Analysis", *Structural Safety*, Vol. 26, pp. 49–67, (2004).
- Cheng, J., "Hybrid Genetic Algorithms for Structural Reliability Analysis", *Computers and Structures*, Vol. 85, pp. 1524–1533, (2007).
- Kaymaz, I., "Application of Kriging Method to Structural Reliability Problems", *Structural Safety*, Vol. 27, pp. 133–151, (2005).
- Vapnik V. "Statistical Learning Theory", John, Wiley and Sons., New York, (1998).
- Zhiwei, G., Guangchen, B., "Application of Least Squares Support Vector Machine for Regression to Reliability Analysis", *Chinese Journal of Aeronautics*, Vol. 22, pp. 160-166, (2009).
- Li, H.S. And Lu, Z.Z., "Support Vector Regression for Structural Reliability Analysis", *Applied Mathematics and Mechanics*, Vol. 27(10), pp. 1295–1303, (2006).
- Zhao, W., Qiu, Z., "An efficient response surface method and its application to structural reliability and reliability-based optimization", *Finite Elements in Analysis and Design*, Vol. 67, pp. 34–42, (2013).
- Deng, J. "Structural Reliability Analysis for Implicit Performance Function using Radial Basis

- Function Network", *International Journal of Solids and Structures*, Vol. 43, pp. 3255-3291 (2006).
14. Tang, C.X., Jin, W.L. and Chen, J., "Importance Sampling Method based on SVM", *J Yangtze River Scientific Res Inst*, Vol. 24(6), pp. 62–5, (2007).
15. Bucher, C.G., Bourgund, U., "A fast and Efficient Response Surface Approach for Structural Reliability Problems", *Structural Safety*, Vol. 7(1), pp. 57–66, (1990).
16. McKay, M.D., Beckman, R.J., "A comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code", *Technometrics*, Vol. 42(1), pp. 239–45, (2000).