

Modeling the Damage Index in a Slider-Crank Mechanism with Clearance Joints Using Optimized Multilayer Perceptron Neural Networks

Seyed Hesam Zahabi Baboukani, Seyed Mojtaba Varedi-Koulaei*, Naserodin Sepehry

Faculty of Mechanical Engineering, Shahrood University of Technology, Shahrood, Iran

* varedi@shahroodut.ac.ir

Abstract

Mechanisms typically have clearance in their joints due to manufacturing and assembly requirements, and this clearance tends to increase during operation. If the clearance exceeds the allowable limit, it can lead to decreased accuracy, increased vibration and noise, and reduced system efficiency. Therefore, timely identification of the growth of clearance in the joints is essential for preventing destructive effects and increased maintenance costs. In recent years, health-monitoring methods have gained considerable attention owing to their effectiveness and cost efficiency. In this study, the time history of the slider-link acceleration produced by a slider-crank mechanism with radial clearance in its revolute joints is investigated. To identify defects, a novel index based on nonlinear monitoring methods, including vibro-acoustic modulation and higher-harmonic generation, is presented; this index can predict the presence or absence of clearance in the mechanism. Using the collected data, a multilayer perceptron neural network is then trained to address the problem and to predict the index value. In addition, the structure of the neural network is optimized using the particle swarm optimization algorithm. The results show that the optimized network can accurately predict the desired index from the input values.

Keywords

Slider-crank mechanism, structural health monitoring, vibro-acoustic modulation, higher-harmonic generation, Multilayer Perceptron neural network.

1. Introduction

Most kinematic and dynamic analyses of mechanisms idealize joints as clearance-free. In practice, however, manufacturing tolerances and assembly requirements leave clearance in every joint, introducing uncontrolled degrees of freedom that degrade kinematic accuracy, generate impulsive contact forces, increase vibration, and shorten service life. This study addresses clearance identification in a planar slider-crank mechanism to mitigate these effects. Prior work has focused mainly on modeling the effect of clearance on kinematic and dynamic behavior, using contact-force and friction models, with less attention to detection. Nonlinear structural health monitoring techniques—particularly vibro-acoustic modulation (VAM) and higher-harmonic generation (HHG)—are more sensitive to incipient damage than linear methods, while neural networks have proven effective for automating damage classification from vibration and image data. The novelty here is twofold: a new damage index combining VAM and HHG is proposed for a slider-crank mechanism with two clearance joints, and an MLP neural network optimized via particle swarm optimization across one to five hidden layers is trained to predict this index accurately.

2. Methodology

2.1. Mechanism model and damage index

The planar slider-crank mechanism considered here consists of a crank, a coupler, and a slider, connected by two revolute joints (A and B) that may contain radial clearance. The links are assumed rigid, and each clearance joint adds two generalized coordinates to the system. The governing equations of motion are derived using the Lagrangian formulation for the crank, coupler, and slider, together with a continuous contact-force model that represents the contact/impact forces within the clearance joints. For a given clearance size, excitation frequency, and crank speed, the resulting time history of the slider acceleration is transformed into the frequency domain, and the damage index (DI) is computed as the ratio of the mean sideband amplitude (from VAM and HHG) to the probe-frequency amplitude and analog gain:

$$DI = \frac{1}{\omega G} \sum_{fc \in F_{SB}} A(fc) \quad (1)$$

where $A(fc)$ denotes the sideband amplitudes at the relevant frequencies, ω is the probe (carrier) amplitude, G is the analog gain, and F_{SB} is the set of sideband frequencies considered.

2.2. Data generation

Training data were generated by finite-element (FE) simulation in COMSOL Multiphysics, modeling the mechanism in the healthy state and with one or two clearance joints (mesh size 6860 elements, simulation time 1.2 s). Four input parameters were varied factorially: presence of clearance (one or two joints), clearance size (100, 200, 400, 600, 800 and 1000 μm), excitation frequency (233 and 533 Hz) and input angular speed (400–5000 rpm). Fast Fourier transform of the resulting slider acceleration was used to evaluate the damage index for every combination, yielding a dataset of 144 samples with four inputs and one output (DI). The FE results were verified against the analytical solution of the governing equations, showing close agreement in the location and magnitude of the VAM-related spectral peaks.

2.3. Neural network design and optimization

An MLP network was used to map the four input parameters to the damage index. Because the number of hidden layers, the number of neurons per hidden layer, the transfer function of each layer, and the training algorithm all affect accuracy, these were treated as design variables of an optimization problem solved with particle swarm optimization (PSO). The number of neurons per hidden layer was allowed to vary between 1 and 30, three transfer functions were considered (log-sigmoid, tan-sigmoid and Elliot-sigmoid), and eleven training algorithms were included (e.g., Levenberg–Marquardt, resilient backpropagation, BFGS quasi-Newton and conjugate-gradient variants). Separate optimization problems were solved for networks with one to five hidden layers, with a swarm size equal to twice the number of design variables and a maximum of 100 iterations. The dataset was split randomly into 70% training, 15% validation and 15% test subsets, and early stopping on the validation error was used together with this three-way split to prevent overfitting. The cost function to be minimized was the mean-squared error (MSE) of the network output; the correlation coefficient (R) was used as a complementary performance measure:

$$MSE = \frac{1}{n} \sum (Y_d - Y_p)^2 \quad (2)$$

$$R = \sqrt{1 - \frac{\sum (Y_d - Y_p)^2}{\sum (Y_d - \bar{Y}_d)^2}} \quad (3)$$

where n is the number of training samples, and Y_d , Y_p , and $\bar{Y}_d$ are the actual, predicted outputs and the mean value of Y_d , respectively.

3. Results and Discussion

The PSO algorithm was run independently for MLP structures with one to five hidden layers, and the optimal design variables obtained for each case are summarized

in Table 1 and compared in Figure 1. Increasing the number of hidden layers from one to three steadily reduces the MSE and increases R, but adding a fourth or fifth hidden layer degrades performance again, indicating over-parameterization relative to the size of the dataset.

Table 1. Optimal design variables and performance of the MLP networks

Net.	Ni	FCN	MSE	R
1HL	9	trainlm	49.674	0.9703
2HL	26,9	trainrp	47.199	0.9714
3HL	26,27,7	trainlm	27.815	0.9840
4HL	25,24,22,5	trainbfg	36.860	0.9776
5HL	25,17,5,19,21	trainlm	46.251	0.9729

The best overall performance was obtained with three hidden layers containing 26, 27 and 7 neurons, using tan-sigmoid, Elliot-sigmoid and log-sigmoid transfer functions, respectively, and trained with the Levenberg–Marquardt algorithm (MSE = 27.8145, R = 0.9840). Training of this optimal network stopped at epoch 13 through early stopping, before the validation error began to increase, confirming that overfitting was avoided. The mean absolute error (MAE) of the optimal network was 2.62, which — being noticeably smaller than the square root of the MSE — indicates that a limited number of samples carry a comparatively large error while the majority of samples are predicted with very small error. Overall, the correlation-coefficient plots for the training, validation, test and total datasets confirm that the optimized three-hidden-layer MLP reproduces the damage index accurately over the whole range of clearance sizes, excitation frequencies and input speeds considered.




Fig 1. a)MSE and b) correlation coefficient (R) of the optimal networks versus the number of hidden layers

4. Conclusion

A damage index combining vibro-acoustic modulation and higher-harmonic generation was formulated and evaluated for a planar slider-crank mechanism with radial clearance in one or two revolute joints, using slider-acceleration data obtained from finite-element simulation over 144 combinations of clearance size, excitation frequency and input speed. An MLP neural network was trained to map these four input parameters onto the damage index, and its architecture number of hidden layers, number of neurons, transfer functions and training algorithm was optimized using particle swarm optimization. Among networks with one to five hidden

layers, the three-hidden-layer architecture (26-27-7 neurons, tan-sigmoid/Elliot-sigmoid/log-sigmoid, trained with Levenberg–Marquardt) achieved the best accuracy (MSE = 27.8145, R = 0.9840). In contrast, additional layers increased error due to over-parameterization. These results confirm that an optimized MLP can reliably predict the proposed damage index from readily measurable operating parameters, offering a practical, data-driven tool for the early detection of joint clearance in slider-crank mechanisms.

5. References

- [1] S.M. Varedi, H.M. Daniali, M. Dardel, A. Fathi, Optimal dynamic design of a planar slider-crank mechanism with a joint clearance, *Mechanism and Machine Theory*, 86 (2015) 191–200.
- [2] S.M. Varedi, H.M. Daniali, M. Dardel, Dynamic synthesis of a planar slider-crank mechanism with clearances, *Nonlinear Dynamics*, 79(2) (2015) 1587–1600.
- [3] X. Chen, S. Gao, Dynamic accuracy reliability modeling and analysis of planar multi-link mechanism with revolute clearances, *European Journal of Mechanics - A/Solids*, 90 (2021) 104317.
- [4] H. Tan, Y. Hu, L. Li, A continuous analysis method of planar rigid-body mechanical systems with two revolute clearance joints, *Multibody System Dynamics*, 40(4) (2017) 347–373.
- [5] S.M. Varedi-Koulaei, H.M. Daniali, M. Farajtabar, B. Fathi, M. Shafiee-Ashtiani, Reducing the undesirable effects of joints clearance on the behavior of the planar 3-RRR parallel manipulators, *Nonlinear Dynamics*, 86(2) (2016) 1007–1022.
- [6] D.M. Donskoy, A.M. Sutin, Vibro-Acoustic Modulation Nondestructive Evaluation Technique, *Journal of Intelligent Material Systems and Structures*, 9(9) (1998) 765–771.
- [7] N. Sepehry, M. Ehsani, S. Asadi, M. Shamshirsaz, F.B. Nejad, Fourier spectral element for simulation of vibro-acoustic modulation caused by contact nonlinearity in the beam, *Thin-Walled Structures*, 174 (2022) 109112.
- [8] S.M.Y. Nikravesh, M. Goudarzi, Experimental and numerical looseness detection and assessment in flanged joints using vibro-acoustic modulation method, *Mechanics Based Design of Structures and Machines*, 50(4) (2022) 1400–1416.
- [9] S. Sony, S. Laventure, A. Sadhu, A literature review of next-generation smart sensing technology in structural health monitoring, *Structural Control and Health Monitoring*, 26(3) (2019) e2321.
- [10] C.-L. Fan, Deep neural networks for automated damage classification in image-based visual data of reinforced concrete structures, *Heliyon*, 10(19) (2024) e38104.
- [11] D. Kautz Monteiro, L.F.F. Miguel, G. Zeni, T. Becker, G. Souza de Andrade, R. Rodrigues de Barros, Detection, Localization, and Quantification of Damage in Structures

via Artificial Neural Networks, Shock and Vibration, 2023(1) (2023) 8829298.

[12] Y. Jiang, Road damage detection and classification using deep neural networks, Discover Applied Sciences, 6(8) (2024) 421.

مدل سازی شاخص عیب در مکانیزم لنگ و لغزنده دارای مفاصل لق با استفاده از شبکه پرسپترون چندلایه بهینه شده عصبی

سید حسام ذهبی بابوکانی^۱، سید مجتبی واردی کولایی^{۲*}، ناصرالدین سپهری^۳

دانشکده مهندسی مکانیک، دانشگاه صنعتی شاهرود، شاهرود، ایران
* varedi@shahroodut.ac.ir

چکیده

مکانیزم‌ها به دلیل الزامات ساخت و مونتاژ، معمولاً دارای لقی در مفاصل خود هستند و مقدار این لقی در حین کارکرد افزایش می‌یابد. اگر مقدار این لقی از حد مجاز بیشتر شود، سبب کاهش دقت، افزایش ارتعاشات و سروصدا و کاهش کارایی در سیستم خواهد شد. از این رو، شناسایی به موقع افزایش مقدار لقی در مفاصل به جهت ممانعت از اثرات مخرب و هزینه‌های فزاینده تعمیر و نگهداری امری ضروری است. در سال‌های اخیر استفاده از روش‌های پایش سلامت به دلیل اثربخشی و مقرون به صرفه بودن، بسیار مورد توجه قرار گرفته است. در این تحقیق به بررسی تاریخچه زمانی شتاب لینک‌ها (رابط‌ها)، به واسطه عملکرد یک مکانیزم لنگ و لغزنده لنگ دارای لقی شعاعی در مفاصل دورانی پرداخته می‌شود. در همین راستا و به منظور شناسایی عیب، شاخص جدیدی، مرتبط با روش‌های پایش غیرخطی از جمله مدولاسیون ارتعاشی-صوتی و تولید هارمونیک‌های مرتبه بالا، ارائه شده که براساس آن می‌توان وجود یا عدم وجود لقی را در مکانیزم پایش‌بینی نمود. در ادامه، به کمک دیتاهای جمع‌آوری شده و استفاده از شبکه عصبی پرسپترون چندلایه، آموزش شبکه برای مساله مورد بررسی و پایش‌بینی مقدار شاخص صورت گرفته است. همچنین ساختار شبکه عصبی با استفاده از الگوریتم ازدحام ذرات بهینه شده است. نتایج نشان می‌دهند شبکه بهینه شده به خوبی می‌تواند شاخص موردنظر را براساس مقادیر ورودی‌ها پایش‌بینی نماید.

کلمات کلیدی

مکانیزم لنگ و لغزنده، پایش سلامت، مدولاسیون ارتعاشی-صوتی، تولید هارمونیک بالاتر، شبکه عصبی پرسپترون چندلایه.

در اکثر تحلیل‌های سینماتیکی و دینامیکی در حوزه طراحی مکانیزم‌ها، مفاصل به صورت ایده‌آل و بدون لقی فرض می‌شوند و هر مفصل بدون توجه به لقی، در یک یا چند درجه آزادی محدود می‌گردد [۱]. با این حال، در عمل، به دلیل نیاز به مونتاژ و تolerانس‌ها و نقص‌های اجتناب‌ناپذیر ناشی از طراحی و فرآیند ساخت، مقدار مشخصی لقی در هر مفصل وجود دارد که منجر به ایجاد درجات آزادی اضافی و غیرقابل کنترل می‌شود و می‌توان آن را منشأ خطا دانست [۲]. حضور این لقی تأثیر قابل توجهی بر دقت سینماتیکی و تکرارپذیری مکانیزم‌ها، به‌ویژه در دامنه‌های حرکتی وسیع، دارد [۳]. لقی‌ها در سیستم‌های مکانیکی به دلیل سایش، عیوب ساخت و تolerانس‌های مونتاژ اجتناب‌ناپذیرند و سبب انحراف عملکرد واقعی مکانیزم از مدل ایده‌آل می‌شوند؛ این امر نیروهای تماسی ایجاد می‌کند که به ارتعاش، کاهش قابلیت اطمینان، دوام و عمر مفید سیستم منجر می‌گردد و شکاف قابل توجهی میان پیش‌بینی‌های نظری و عملکرد واقعی به وجود می‌آورد. این مطالعه با هدف شناسایی لقی‌های مفاصل در مکانیزم لنگ و لغزنده صفحه‌ای انجام شده است تا اثرات منفی این نقص‌ها کاهش یابد.

مدل‌سازی دقیق لقی مفاصل در دینامیک چندجسمی موضوع تحقیقات گسترده‌ای بوده است. بیشتر مطالعات پیشین بر تأثیر لقی بر عملکرد سینماتیکی یا ویژگی‌های دینامیکی مکانیزم‌ها متمرکز بوده و پژوهش‌های مربوط به سنتز مکانیزم با در نظر گرفتن لقی محدودتر است [۱-۱۰]. واردی و همکاران [۱، ۲] از روش‌های بهینه‌سازی برای طراحی مکانیزم دارای لقی استفاده کرده و طول اجزا را بهینه‌سازی نمودند تا اثرات منفی لقی، به‌ویژه مقادیر بیشینه شتاب و نیروها، کاهش یابد. چن و جیانگ [۵] روش مدل‌سازی دینامیکی مکانیزم با چندین لقی و در نظر گرفتن آشوب در لقی‌ها را ارائه دادند که برای مکانیزم صفحه‌ای با دو جفت چرخشی دارای لقی توسعه یافت و پاسخ سیستم تحت بارهای متغیر زمانی با تغییر موقعیت، تعداد و مقدار لقی‌ها بررسی شد. چن و گائو [۳] تکنیک تحلیلی برای ارزیابی دقت و قابلیت اطمینان دینامیکی مکانیزم‌های چندلینکی پیچیده با مفاصل دوار دارای لقی پیشنهاد کردند. بای و سان [۴] پاسخ‌های دینامیکی سیستم‌های چندجسمی با چندین مفصل دوار دارای لقی را با مدل نیروی تماس پیوسته و مدل اصطکاک کولن اصلاح‌شده مطالعه کردند. جینگ و لیو [۸] ضریب سفتی غیرخطی و ضریب میرایی ویسکوز بهبودیافته با در نظر گرفتن فرسایش پوشش‌ها را برای توسعه مدل نیروی تماس هم‌راستا پیشنهاد نمودند. جیانگ و بای [۷] روش تحلیل دینامیکی با در نظر گرفتن ارتباط پارامترهای فضایی ارائه دادند و از مدل نیروی تماس پیوسته و اصطکاک اصلاح‌شده به روش لاگرانژ و مدل بیضی محدب برای عدم قطعیت‌های فاصله‌ای استفاده کردند. چن و همکاران [۶] ویژگی‌های تماس-ضربه مفاصل دارای لقی را با مدل نیروی تماس پیوسته غیرخطی بررسی کرده و دینامیک مکانیزم لنگ و لغزنده با چندین لقی و با در نظر گرفتن انعطاف‌پذیری اجزا را تحلیل نمودند و علل ارتعاش در سیستم چندجسمی را کاوش کردند. تان و همکاران [۱۰] معادلات دینامیکی را با تلفیق قوانین نیوتن-اولر، مدل نیروی تماس اصلاح‌شده، مدل اصطکاک کولن بهبودیافته و روش پایدارسازی بومگارت^۱ تدوین کردند. ماتکار و فولمیرکار [۹] تأثیر لقی مفاصل بر جابه‌جایی لغزنده را با آزمون تجربی و شبیه‌سازی در نرم‌افزار آدامز^۲ بررسی کردند. واردی و همکاران [۱۱] تأثیر لقی بر رفتار دینامیکی ربات موازی را مطالعه کرده و روش بهینه‌سازی همزمان سینماتیکی-دینامیکی را برای بهبود عملکرد و دقت پیشنهاد دادند. تان و همکاران [۱۲] با ترکیب معادله لاگرانژ نوع اول، مدل نیروی تماس، مدل اصطکاک لوگ-ری^۳ و پایدارسازی بومگارت^۱، دینامیک مکانیزم لنگ و لغزنده را بررسی و مدل را با شبیه‌سازی و آزمایش تأیید کردند.

برای درک تأثیر افزایش لقی بر عملکرد مکانیزم، شناسایی آن به عنوان نقص ضروری است؛ لذا روش‌های تشخیص این نقص اهمیت بالایی دارند. نظارت سلامت سازه^۴ شامل بررسی، پایش و نگهداری برای حفظ اقتصاد و پایداری مهندسی است و تحقیقات اخیر پیشرفت

^۱ Baumgarte

^۲ ADAMS

^۳ LuGre

^۴ Structural Health Monitoring (SHM)

روش‌های غیرمخرب^۱ را برای افزایش عمر سازه‌های پایش‌شده نشان داده است [۱۳]. روش‌های غیرخطی از ویژگی‌های دینامیکی غیرخطی سازه بهره می‌برند و حساسیت بیشتری نسبت به آسیب نسبت به روش‌های خطی دارند [۱۴]. غیرخطی بودن مکانیزم‌های موازی صفحه‌ای و معادلات حاکم بر آن‌ها نیز استفاده از روش‌های غیرخطی برای شناسایی عیوب لقی را ضروری می‌سازد. تولید هارمونیک/زیرهارمونیک بالاتر، اعوجاج شکل موج [۱۵]، تغییر فرکانس رزونانس تابعی از دامنه تحریک [۱۶] و مدولاسیون ارتعاشی-صوتی^۲ [۱۷] از روش‌های غیرخطی تشخیص آسیب به شمار می‌روند.

سپهری و همکاران [۱۸] روش المان طیفی فوریه^۳ را برای شبیه‌سازی پدیده VAM در سازه‌های تیرمانند با تکیه‌گاه گیردار ارائه دادند و سایدبندها را ناشی از مدولاسیون داخلی موج‌ها مبنای پایش مبتنی بر VAM دانستند. لی و همکاران [۱۹] روش جدیدی از VAM برای پایش ترک خستگی توسعه دادند و با دستگاه شبیه‌ساز ترک و مبدل پیزوالتریک^۴ و شاخص آسیب مبتنی بر آنتروپی پرموتاسیون چندمقیاس، عرض ترک را ارزیابی کردند. دونسکی و لیو [۲۰] روش VAM بدون پایه^۵ را پیشنهاد کردند که تفاوت مکانیزم‌های غیرخطی مواد سالم و آسیب‌دیده را مینا قرار می‌دهد. لیو و دونسکوی [۲۱] روش VAM بهبودیافته با یادگیری ماشین را برای آزمون غیرمخرب ارائه دادند و دامنه سایدبندها را به‌عنوان ویژگی برای تشخیص ترک خستگی بدون وابستگی به فرکانس پروب استفاده کردند. لیو و دونسکوی [۲۲] رویکرد همبستگی متقابل را برای پردازش سیگنال VAM اصلاح‌شده پیشنهاد کردند و عملکرد آن را با روش‌های موجود مقایسه نمودند. هی و همکاران [۲۳] اثرات غیرخطی آکوستیک تماس VAM در سازه‌های کامپوزیتی دلمینه‌شده را با سری فوریه و مدل گرین‌وود-ویلیامسون اصلاح‌شده در روش المان محدود بررسی کردند. وانگ و سونگ [۲۴] روش VAM را برای تشخیص لقی اتصال چندپیچی با سیگنال‌های سینوسی خطی سوئیپ گسترش دادند و روش VAM اصلاح‌شده را با مبدل پیزوسرامیکی و سیگنال سوئیپ برای حساسیت بالاتر ارائه کردند [۲۵]. نیک‌روش و گودرزی [۲۶] قابلیت VAM در تشخیص لقی اتصالات فلنجی را با دقت ۱۲/۵٪ در نمونه آزمایشگاهی تأیید کردند. کاروه و همکاران [۲۷] کارایی VAM در تشخیص و محلی‌سازی آسیب ناشی از واکنش قلیایی-سیلیسی در بتن را بررسی کرده و فرآیند فیوژن بیزی برای نقشه احتمال آسیب ارائه دادند. ما و همکاران [۲۸] فیوژن دوسطحی سیگنال‌های VAM برای تشخیص ترک پره فن سانتریفیوژ با روش درجه همبسته‌ی سیکلواستاتیوی^۶، استخراج ویژگی شبکه هرمی ویژگی تک‌بعدی^۸ و فیوژن شواهد دمپستر-شافر^۹ بهبودیافته را انجام دادند. سپهری و همکاران [۲۹] روش تشخیص آسیب با تحریک چیرپ و تحلیل تبدیل موجک کسری را برای شناسایی آسیب با وضوح بالا و مقاومت نویزی معرفی کردند.

در سال‌های اخیر، استفاده از شبکه‌های عصبی عمیق پیشرفت قابل توجهی در شناسایی و ارزیابی خودکار آسیب‌های سازه‌ای و زیرساختی ایجاد کرده است. فن [۳۰] با استفاده از ترکیب شبکه‌های عصبی کانولوشنی^{۱۰} و کاملاً کانولوشنی^{۱۱} روشی ارائه داد که قادر است تصاویر گرفته‌شده با گوشی هوشمند از سازه‌های بتن مسلح را به‌صورت خودکار پردازش کرده، انواع آسیب (مانند خوردگی میلگرد و ترک‌خوردگی بتن) را تشخیص دهد، طبقه‌بندی کند و بخش‌بندی^{۱۲} نماید و به دقت بسیار بالای ۹۸/۷۵ درصد در طبقه‌بندی و ۹۵/۹۸ درصد در بخش‌بندی دست یافت. از سوی دیگر، ومونتیرو و همکاران [۳۱] رویکردی مبتنی بر ارتعاشات و شبکه‌های عصبی

^۱ Non-destructive tests (NDT)

^۲ Vibro-Acoustic Modulation(VAM)

^۳ Fourier Spectral Element Method(FSEM)

^۴ Piezoelectric transducer (PZT)

^۵ baseline-free

^۶ Finite element method (FEM)

^۷ correlated degree of cyclostationarity (CDCS)

^۸ one-dimensional feature pyramid network (1D-FPN)

^۹ Dempster-Shafer evidence theory (DSE)

^{۱۰} Convolutional neural network (CNN)

^{۱۱} Full Convolutional Neural Network (FCN)

^{۱۲} Segmentation

مصنوعی^۱ پیشنهاد کردند که با استفاده از فرکانس‌های طبیعی و اشکال مودال، تنها در یک مرحله قادر به تشخیص، مکان‌یابی و کمی سازی میزان آسیب در سازه‌ها است و در آزمایش‌های واقعی (مانند پل زد-۲۴) عملکرد بسیار خوبی از خود نشان داد. همچنین جیانگ [۳۲]. با بهینه‌سازی مدل یولو-وی ۸ برای سیستم‌های جاسازی‌شده، روشی کارآمد برای تشخیص و طبقه‌بندی آسیب‌های جاده ارائه کرد که روی مجموعه داده‌های استاندارد به دقت متوسط ۶۵/۷ درصد دست یافت. این سه رویکرد در مجموع نشان‌دهنده توانایی بالای شبکه‌های عصبی در اتوماسیون، افزایش دقت و کاربرد عملی در حوزه‌های مختلف پایش سلامت سازه و زیرساخت هستند.

در این پژوهش، با استفاده از شبکه عصبی پرسپترون چندلایه^۲ به شناسایی و پیش‌بینی شاخص آسیب در مکانیزم لنگ-لغزنده دارای مفاصل لقی پرداخته می‌شود. علاوه بر این، به منظور دستیابی به شبکه‌ای با کمترین خطا، ساختار شبکه عصبی با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات^۳ بهینه می‌شود.

۲- مکانیزم لنگ و لغزنده

۲-۱- سینماتیک و دینامیک مکانیزم

در این بخش به ارائه معادلات حاکم بر مکانیزم لنگ و لغزنده مدنظر (شکل ۱) و ابعاد هندسی و مشخصات اینرسی آن در جدول ۱ آورده شده است.

جدول ۱ ویژگی‌های هندسی و اینرسی مکانیزم لغزنده-لنگ

Table 1. Geometric and inertial properties of the slider-crank mechanism

نام عضو	طول (m)	جرم (Kg)	ممان اینرسی ($Kg m^2$)	$u(m)$	$v(m)$
لنگ (L_2)	۰/۰۵	۰/۳	۰/۰۰۰۱	۰/۰۲۵	۰
میله رابط (L_3)	۰/۱۲	۰/۲۱	۰/۰۰۰۲۵	۰/۱۵	۰
لغزنده	-	۰/۱۴	۰/۰۰۰۱	۰	۰

که u و v به ترتیب مختصات مرکز جرم در راستای میله و عمود بر آن می‌باشد. لقی‌های موردبحث در اتصالات بین میله رابط با لنگ و میله رابط با لغزنده تعبیه شده است و میزان‌های لقی مورد مطالعه از ۱۰۰، ۲۰۰، ۴۰۰، ۶۰۰، ۸۰۰ و ۱۰۰۰ میکرومتر و شعاع مفصل ۱۰ میلی‌متر در نظر گرفته شده است. مشخصات ساختاری و موادی مطابق با جدول ۲ در نظر گرفته شده است. شکل ۲ نیز نحوه نمایش لقی و مشخصات ساختاری مکانیزم را نمایش می‌دهد.

جدول ۲ ویژگی‌های هندسی و مواد لقی مفاصل


Table 2. Geometric and material properties of the joint clearance

ضریب استرداد	مدول یانگ (Gpa)	ضریب پواسون	ضریب اصطکاک
۰/۹	۲۰۰	۰/۳	۰

^۱ Artificial Neural Networks (ANN)

^۲ Multilayer perceptron (MLP)

^۳ Particle Swarm Optimization (PSO)



شکل ۱ مکانیزم لنگ و لغزنده با دو مفصل دورانی لق

Fig. 1. Slider-crank mechanism with two clearance revolute joints

۲-۱-۱- معادلات حاکم بر مکانیزم دارای مفاصل لق

معادلات حرکت برای حالت وجود لقی در مفصل‌های مکانیزم لنگ و لغزنده محاسبه می‌شود. مدل مکانیزم می‌تواند دارای یک مفصل دارای لقی (مفصل A) و یا دو مفصل دارای لقی (شکل ۱) بین لینک‌های متحرک (مفاصل A و B) مدل‌سازی شود و لینک‌ها صلب فرض شده است. با توجه این نکته که مفصل دورانی لق، دو درجه آزادی به سیستم اضافه خواهد کرد، به تعداد درجات آزادی سیستم دارای مختصات تعمیم‌یافته کلی خواهد بود و به صورت مختصات (۱) و (۲) تعریف می‌شوند [۲]:

$$q_j = \{\theta_2, x_4, \theta_3\}, \quad j=1, 2, \dots \quad (1)$$

$$q_j = \{\theta_2, x_{G_3}, y_{G_3}, \theta_3, x_4\}, \quad j=1, 2, \dots \quad (2)$$

برای حالت دارای دو لقی با توجه به مختصات (۲)، x_{G_3} و y_{G_3} مختصات مرکز جرم میله رابط و x_4 مختصات لغزنده است و برای محاسبه معادلات حرکت از لاگرانژ استفاده می‌شود [۲]. بدین صورت که:

$$\frac{d}{dt} \left(\frac{\partial T}{\partial \dot{q}_j} \right) - \frac{\partial T}{\partial q_j} + \frac{\partial U}{\partial q_j} = Q_j, \quad j=1, 2, 3 \quad (3)$$

که T و U به ترتیب انرژی‌های جنبشی و پتانسیل اجزا است و Q_j نیروهای تعمیم‌یافته ناشی از نیروهای خارجی می‌باشد که از رابطه (۹) به دست می‌آید [۲]:

$$Q_j = \sum_{i=1}^3 \left(F_i \cdot \frac{\partial \dot{r}_{F_i}}{\partial \dot{q}_j} + M_i \cdot \frac{\partial \dot{\omega}_i}{\partial \dot{q}_j} \right), \quad j=1, 2, 3 \quad (4)$$

F_i نیروی برآیند خارجی وارد بر مرکز جرم جسم آام و M_i گشتاور خارجی وارد بر لینک آام و $\dot{r}_{F_i}$ سرعت خطی لینک آام و ω_i سرعت زاویه‌ای لینک آام هستند. بنابراین، معادله (۳) را می‌توان به راحتی برای هر پیوند توسعه داد و برای مجموعه یک رابطه لاگرانژی جداگانه نوشته شود. برای میل‌لنگ، انرژی‌های جنبشی و پتانسیل را می‌توان به صورت رابطه (۵) نوشت:

$$T_2 = \frac{1}{2} I_2 \dot{\theta}_2^2 + \frac{1}{2} m_2 (a_2 L_2 \dot{\theta}_2)^2$$

$$U_2 = m_2 g a_2 L_2 \sin(\theta_2 + \gamma_2)$$
(۵)

که در آن I_2 ، m_2 ، L_2 و به ترتیب طول، جرم و ممان اینرسی میل‌لنگ و g شتاب گرانشی هستند. علاوه بر این، γ_2 و a_2 از رابطه (۶) محاسبه می‌شود [۲]:

$$a_2 = \frac{\sqrt{u_2^2 + v_2^2}}{L_2}, \quad \gamma_2 = \tan^{-1} \left(\frac{u_2}{v_2} \right)$$
(۶)

که در آن u_2 و v_2 مختصات مرکز جرم لنگ می‌باشد. با ساده‌سازی و جایگذاری‌ها و قراردادن مقدار $q_1 = \theta_2$ و $M_2 = \tau_{in}$ داریم [۲]:

$$(I_2 + m_2 a_2^2 L_2^2) \ddot{\theta}_2 + m_2 g a_2 L_2 \cos(\theta_2 + \gamma_2) = Q_{CA} L_2 \sin(\theta_2 - \psi_A) + \tau_{in}$$

$$M_2 =$$
(۷)

$$(I_2 + m_2 a_2^2 L_2^2) \ddot{\theta}_2 + m_2 g a_2 L_2 \cos(\theta_2 + \gamma_2) - Q_{CA} L_2 \sin(\theta_2 - \psi_A)$$

که τ_{in} گشتاور ورودی به سیستم است. برای میله رابط هم همانند لنگ، انرژی‌های جنبشی و پتانسیل به صورت رابطه (۸) تعریف عنوان می‌گردد [۲]:

$$T_3 = \frac{1}{2} I_3 \dot{\theta}_3^2 + \frac{1}{2} m_3 (\dot{x}_{G3}^2 + \dot{y}_{G3}^2)$$
(۸)

$$U_3 = m_3 g y_{G3}$$

که در آن I_3 ، m_3 ، L_3 و به ترتیب طول، جرم و ممان اینرسی و با ساده‌سازی و جایگذاری، برای معادلات حرکت میله رابط داریم [۲]:

$$m_3 x_{G3} = Q_{CA} \cos \psi_A + Q_{CB} \cos \psi_B$$
(۹)

$$m_3 y_{G3} + m_3 g = Q_{CA} \sin \psi_A + Q_{CB} \sin \psi_B$$
(۱۰)

$$I_3 \ddot{\theta}_3 = Q_{CA} a_3 L_3 \sin(\theta_3 + \gamma_3 - \psi_A)$$
(۱۱)

$$+ Q_{CB} a_3 L_3 \sin(\theta_3 + \gamma_3 - \psi_A) - Q_{CB} L_3 \sin(\theta_3 - \psi_B)$$

در نهایت برای لغزنده، رابطه (۱۲) صادق خواهد بود [۲]:

$$U_4 = 0, T_4 = \frac{1}{2} m_4 \dot{x}_4^2$$
(۱۲)


و لذا با ساده‌سازی معادله حرکت لغزنده برابر است با [۲]:
(۱۳)

$$m_4 \ddot{x}_4 = -Q_{CB} \cos \varphi_B$$

۲-۲- پایش سلامت و استخراج شاخص عیب

۲-۲-۱- روش‌های پایش سلامت

روش VAM به عنوان یکی از روش‌های عملی و کارآمد، بدون نیاز به تجهیزات سخت‌افزاری گران‌قیمت رایج در سایر رویکردهای غیرخطی، قادر است رشد آسیب را از طریق همبستگی سطح غیرخطی با شدت یا تراکم آسیب شناسایی کند. در این روش، سیگنال‌های فرکانس پایین (ارتعاشی) و فرکانس بالا (فراصوتی) همزمان به نمونه اعمال می‌شود و سیگنال تلفیقی خروجی برای استخراج اطلاعات آسیب پایش می‌گردد. اگر چه تکنیک‌های محلی نظیر آزمون اولتراسونیک^۱ و آزمون جریان گردابی^۲ از دقت محلی‌سازی بالاتری برخوردارند، اما VAM در سرعت تشخیص و حساسیت کلی به آسیب‌های اولیه برتری دارد [۳۳]. در مطالعه حاضر، شاخص مدولاسیون^۳ به عنوان معیاری آسیب‌شناختی محاسبه می‌شود و تحلیل تکامل سیگنال تلفیقی در طیف توان، به ویژه مشاهده نوارهای جانبی ناشی از تداخل موج‌ها، مبنای تشخیص آسیب قرار می‌گیرد؛ MI در محدوده مناسب هر چرخه اندازه‌گیری میانگین‌گیری شده و اصول اساسی این تکنیک به صورت شماتیک در شکل‌های ۲-الف تا ۲-ه نشان داده شده است [۳۳].



شکل ۲ روش تلفیق ارتعاشی-صوتی: (الف) سیگنال‌های (f_1 فرکانس بالا و f_0 فرکانس پایین) به نمونه، (ب) نمونه آزمایشی معیوب، (ج) سیگنال‌های خروجی، (د) طیف توان اولیه در حوزه فرکانس، و (ه) طیف توان خروجی [۳۳].

Fig. 2. Vibro-acoustic modulation technique: (a) high-frequency (f_1) and low-frequency (f_0) signals applied to the specimen, (b) defective test specimen, (c) output signals, (d) initial power spectrum in the frequency domain, and (e) output power spectrum [33].

یکی دیگر از روش‌های غیرخطی در پایش سلامت سازه‌ها، تولید هارمونیک مرتبه بالاتر^۴ است. هنگامی که موج فراصوت سینوسی با دامنه کافی در محیط جامد غیرخطی منتشر می‌شود، به دلیل ویژگی‌های غیرخطی ماده، HHG از فرکانس اصلی شکل می‌گیرند. با


^۱ Ultrasonic test (UT)

^۲ Eddy current test (ET)

^۳ Modulation index (MI)

^۴ Higher Harmonic Generation (HHG)

پیشرفت آسیب‌های ریزساختاری (مانند میکروتُرک‌ها یا خستگی اولیه)، ناپیوستگی‌ها سبب افزایش قابل‌توجه رفتار غیرخطی موج الاستیک می‌گردند و تولید هارمونیک‌های مرتبه دوم، سوم یا بالاتر را تسهیل می‌کنند؛ این پدیده در مدل سیستم غیرخطی مرتبه دوم یا بالاتر، با ورودی سینوسی، به صورت HHG در خروجی ظاهر می‌شود [۳۴]. در سازه سالم، پاسخ فرکانسی حس‌گر عمدتاً شامل فرکانس(های) ورودی است (شکل ۳)، اما در حضور آسیب، علاوه بر فرکانس اصلی، HHG (به صورت مضرب صحیح فرکانس ورودی) در طیف پاسخ مشاهده می‌گردد که از سری فوریه تبعیت می‌کنند. این تشکیل HHG، شاخص حساس و مؤثری برای تشخیص و ارزیابی شدت آسیب‌های اولیه ریزساختاری به شمار می‌رود، زیرا با افزایش تراکم یا گستردگی نقص‌ها، میزان غیرخطی بودن و شدت هارمونیک‌های تولیدشده به طور قابل‌توجهی افزایش می‌یابد [۳۵].



شکل ۳ روش هارمونی مرتبه بالاتر در سیستم خطی

Fig. 3. Higher-order harmonic generation in a linear (healthy) system

۲-۲-۲- شاخص آسیب (عیب)

شاخص آسیب^۱ به صورت نسبت میانگین دامنه نوارهای جانبی^۲ به دامنه فرکانس پروب (فرکانس ورودی) و بهره آنالوگ^۳ تعریف می‌شود؛ این نسبت، معیاری کمی برای شدت مدولاسیون فراهم می‌آورد. شاخص آسیب برای الف) روش VAM و ب) ترکیب روش‌های VAM و تولید HHG، بر اساس معادله (۱۴) محاسبه می‌گردد.

$$DI = \frac{1}{\omega G} \cdot \sum_{f_c \in F_{SB}} A(f_c) \quad (14)$$

در این معادله، $A(f_c)$ نشان‌دهنده دامنه‌های نوارهای جانبی در فرکانس‌های مربوطه و همچنین دامنه‌های نوارهای جانبی مرتبط با هارمونیک‌های مرتبه بالاتر است؛ ω دامنه پروب (فرکانس حامل یا سرعت ورودی) در فرکانس به منظور کمی‌سازی شدت مدولاسیون را بیان می‌کند؛ G بهره آنالوگ و F_{SB} مجموعه فرکانس‌های نوارهای جانبی^۴ می‌باشد. بنابراین، شاخص آسیب برای روش VAM و ترکیب آن با HHG بر پایه رابطه (۱۴) محاسبه می‌گردد.

۲-۳- جمع‌آوری داده برای آموزش شبکه

^۱ Damage Index(DI)

^۲ sideband amplitudes

^۳ analog gain


^۴ set of sideband frequencies

به منظور جمع‌آوری داده‌ها برای آموزش شبکه عصبی از روش المان محدود استفاده شده است. روش المان محدود یک روش تحلیلی-عددی قدرتمند است که در طیف وسیعی از مسائل مهندسی و فیزیکی به کار گرفته می‌شود که به کمک فرآیند گسسته‌سازی^۱، امکان حل تحلیلی-عددی معادلات دیفرانسیل جزئی حاکم بر پدیده‌های فیزیکی را فراهم می‌آورد. روش المان محدود به دلیل کارایی بالای خود در حل مسائل دارای هندسه‌های پیچیده، خواص مواد متنوع و شرایط مرزی گوناگون، از جایگاه ویژه‌ای برخوردار است. تحلیل گذرا^۲ به منظور بررسی تأثیر لقی مفصل بر سرعت و شتاب لغزنده صورت پذیرفته است. در این پژوهش تحلیل با بهره‌گیری از نرم‌افزار کامسول^۳ (شکل ۴) انجام گرفته است. بدین صورت که مدل‌سازی مکانیزم در حالات سالم و دارای یک و دو لقی با انتخاب تعداد مش ۶۸۶۰ عدد در مدت زمان شبیه‌سازی ۱/۲ ثانیه انجام گرفته است. نتایج مدل‌سازی نیز به کمک تبدیل فوریه سریع تجزیه و تحلیل شده در نهایت شاخص آسیب به کمک رابطه (۱۴) محاسبه در هر لقی، سرعت و فرکانس ورودی خاص محاسبه گردیده است. در فرآیند تولید داده‌های آموزشی، پارامترهای «وجود یا عدم وجود لقی»، «اندازه لقی»، «فرکانس تحریک» و «سرعت زاویه‌ای ورودی» به صورت ترکیبی در نظر گرفته شدند. به گونه‌ای که هر نمونه داده حاصل یک ترکیب مشخص از این پارامترها در فرآیند شبیه‌سازی است. بنابراین، اثر متقابل این پارامترها در فرآیند تولید داده‌ها به صورت ضمنی لحاظ شده و شبکه عصبی در مرحله آموزش با ترکیب‌های مختلف آن‌ها مواجه شده است.

جدول ۳ پارامترهای ورودی مساله و سطوح تغییرات آن‌ها برای تولید داده

Table 3. Input parameters of the problem and their variation levels for data generation

سطوح تغییرات پارامترها	پارامترهای ورودی مساله
یک لقی (مفصل A)، دو لقی (مفاصل A و B)	وجود لقی
۱۰۰، ۲۰۰، ۴۰۰، ۶۰۰، ۸۰۰ و ۱۰۰۰ میکرومتر	اندازه لقی (C)
۲۳۳ و ۵۳۳ هرتز	فرکانس تحریک (f_{pr})
۴۰۰، ۱۰۰۰، ۲۰۰۰، ۳۰۰۰، ۴۰۰۰ و ۵۰۰۰ دور بر دقیقه	دامنه سرعت ورودی (ω)




^۱ discretization

^۲ transient analysis

^۳ COMSOL Multiphysics

شکل ۴ محیط شبیه‌سازی نرم‌افزار کامسول

Fig. 4. COMSOL simulation environment




شکل ۵ تبدیل فوریه سریع از شتاب لغزنده در الف) روش تحلیلی ب) روش المان محدود

Fig. 5. Fast Fourier transform of the slider acceleration obtained from (a) the analytical method and (b) the finite-element method

شکل ۵ مقایسه نتایج تبدیل فوریه حاصل از حل تحلیلی-عددی معادلات ۱ تا ۱۳ به کمک نرم‌افزار متلب (شکل ۵-الف) و نرم‌افزار کامسول (شکل ۵-ب) را در یافتن بیشینه مقادیر مربوط به فرکانس‌های حاصل از روش VAM نشان می‌دهد. مقایسه این دو نمودار به خوبی صحت مدل‌سازی مکانیزم در کامسول را تایید می‌کند. در استخراج این دو نمودار، مکانیزم بصورت دو لقی و با فرکانس ۲۳۳ هرتز و سرعت ۴۰۰ دور بر دقیقه فرض شده است.


به‌منظور مشاهده عملی تفاوت نوارهای جانبی ناشی از مدولاسیون، طیف توان خروجی مکانیزم برای دو حالت سالم و دارای لقی، برای لغزنده در سرعت ورودی ۴۰۰ دور بر دقیقه، به‌ترتیب در شکل‌های ۶-الف و ۶-ب ارائه شده است.



شکل ۶ تبدیل فوریه شتاب لغزنده در سرعت ورودی ۴۰۰ دور بر دقیقه در الف) در حالت سالم، ب) دارای لقی ۰/۱ میلی متر

Fig. 6. Fourier transform of the slider acceleration at an input speed of 400 rpm for (a) the healthy case and (b) the case with 0.1 mm clearance

هدف استفاده از شبکه عصبی، ایجاد رابطه بین پارامترهای ورودی و خروجی مساله مورد بررسی است. شکل ۷ ساختار این مساله را نشان می‌دهد.



شکل ۷ ساختار کلی مساله مورد بررسی
Fig. 7. General structure of the problem under study

۳- طراحی شبکه عصبی بهینه

۳-۱- ساختار شبکه عصبی

برای شبیه‌سازی سیستم تعریف شده در بخش قبل با استفاده از الگوریتم‌های یادگیری ماشین، از یک شبکه MLP مبتنی بر لایه‌های پنهان مختلف استفاده شده است. تعداد نورون‌ها در لایه‌های ورودی و خروجی شبکه با توجه به تعداد ورودی‌ها و خروجی‌های سیستم تعریف می‌شوند (شکل ۷). اما ساختار شبکه از نظر تعداد لایه‌های مخفی، تعداد نرون در هر لایه مخفی، نوع توابع تحریک در هر لایه و همچنین نوع الگوریتم آموزشی را می‌توان به صورت دلخواه انتخاب کرد. طبیعتاً این انتخاب‌ها باید به گونه‌ای انجام شوند تا بهترین شبکه با کمترین خطا بدست آید. بنابراین، می‌توان ساختار شبکه را برای ایجاد یک شبکه بهینه و دستیابی به بهترین عملکرد، بهینه کرد. در تحقیق حاضر، یک مسئله بهینه‌سازی برای طراحی شبکه MLP با ساختار بهینه تعریف شده است. این مسئله براساس موارد زیر ایجاد می‌شود:

- متغیرهای طراحی مسئله شامل تعداد نورون‌ها، نوع تابع تحریک برای هر لایه مخفی و همچنین نوع الگوریتم آموزشی است (جدول ۴).
- محدوده تغییرات برای تعداد نورون‌ها در هر لایه مخفی بین ۱ تا ۳۰ انتخاب می‌شود.
- سه نوع تابع تحریک مختلف لاگسیگ^۱، تانسینگ^۲ و الیوتسینگ^۳ مورد استفاده قرار می‌گیرد (جدول ۵).
- ۱۱ نوع الگوریتم آموزشی مختلف مورد استفاده قرار می‌گیرد (جدول ۶).
- فرآیند بهینه‌سازی برای شبکه‌هایی با تعداد لایه‌های مخفی مختلف حل می‌شود و جواب بهینه برای هر کدام استخراج می‌شود.
- تابع هزینه بر اساس میانگین مربعات خطا^۴ شبکه تعریف می‌شود.

^۱ logsig

^۲ tansig

^۳ ellotsig

^۴ Mean Squared Error (MSE)

جدول ۴ لیست متغیرهای طراحی در هر مساله بهینه‌سازی

Table 4. List of design variables in each optimization problem

نوع	تعداد	لیست متغیرهای طراحی
شبکه عصبی پرسپترون چندلایه		
شبکه عصبی با یک لایه مخفی (1HL)	۳	$[N_1, F_1, F_{cn}]$
شبکه عصبی با دو لایه مخفی (2HL)	۵	$[N_1, N_2, F_1, F_2, F_{cn}]$
شبکه عصبی با سه لایه مخفی (3HL)	۷	$[N_1, N_2, N_3, F_1, F_2, F_3, F_{cn}]$
شبکه عصبی با چهار لایه مخفی (4HL)	۹	$[N_1, N_2, N_3, N_4, F_1, F_2, F_3, F_4, F_{cn}]$
شبکه عصبی با پنج لایه مخفی (5HL)	۱۱	$[N_1, N_2, N_3, N_4, N_5, F_1, F_2, F_3, F_4, F_5, F_{cn}]$

جدول ۵ انواع توابع تحریک مورد استفاده در فرایند بهینه‌سازی

Table 5. Types of transfer functions used in the optimization process

نام تابع تحرک	معادله تابع
Log-sigmoid transfer function (<i>Logsig</i>)	$F_{logsig}(x) = \frac{1}{1+e^{-x}} = \frac{1}{1+e^{-x}}$
Hyperbolic tangent sigmoid transfer function (<i>Tansig</i>)	$F_{tansig}(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
Elliot symmetric sigmoid transfer function (<i>Elliotsg</i>)	$F_{elliotsg}(x) = \frac{x}{1+ x }$

جدول ۶ انواع الگوریتم‌های آموزشی مورد استفاده در فرایند بهینه‌سازی

Table 6. Types of training algorithms used in the optimization process

عبارت در متلب	نام الگوریتم آموزشی
'trainlm'	Levenberg-Marquardt
'traingd'	Gradient Descent
'traingdm'	Gradient Descent with Momentum
'trainscg'	Scaled Conjugate Gradient
'trainoss'	One Step Secant
'traingdx'	Variable Learning Rate Backpropagation
'trainbfg'	BFGS Quasi-Newton
'trainrp'	Resilient Backpropagation
'traincgb'	Conjugate Gradient with Powell/Beale Restarts
'traincgb'	Fletcher-Powell Conjugate Gradient
'traincgp'	Polak-Ribière Conjugate Gradient

خطای MSE شبکه براساس رابطه زیر محاسبه می‌شود:

$$MSE = \frac{1}{n} \sum (Y_d - Y_p)^2 \quad (15)$$

در این رابطه n تعداد نمونه‌های آموزشی است و Y_d و Y_p به ترتیب خروجی‌های واقعی و پیش‌بینی شده هستند. همچنین معیاری دیگری، بنام ضریب همبستگی^۱ (R)، می‌تواند برای بررسی کارایی شبکه مورد استفاده قرار گیرد:

$$R = \sqrt{1 - \frac{\sum (Y_d - Y_p)^2}{\sum (Y_d - \bar{Y}_d)^2}} \quad (16)$$

که $\bar{Y}_d$ مقدار میانگین Y_d است. در واقع کمینه خطای $MSE = 0$ معادل است با $R = 1$.

براساس توضیحات فوق، خلاصه مساله بهینه‌سازی به صورت رابطه زیر خواهد بود:

$$\begin{aligned} & \text{Min } MSE(X_j), \\ & X_j : \{N_i, F_i, F_{CN}\} \\ & \text{S.t: } 1 < N_i < 30 \\ & F_i \in \{\text{logsig, tansig, ellotsig}\} \\ & F_{CN} \in \left\{ \begin{array}{l} \text{trainlm, traingd, traingdm, trainscg, trainoss, traingdx,} \\ \text{trainbfg, trainrp, traincgb, traincgf, traincgp} \end{array} \right\} \\ & \bullet \quad HL=1: j=1, \quad i=1 \\ & \bullet \quad HL=2: j=2, \quad i=1,2 \\ & \bullet \quad HL=3: j=3, \quad i=1,2,3 \\ & \bullet \quad HL=4: j=4, \quad i=1,\dots,4 \\ & \bullet \quad HL=5: j=5, \quad i=1,\dots,5 \end{aligned} \quad (17)$$

که در آن N_i تعداد نوروها در لایه مخفی i ام، F_i نوع تابع تحریک در لایه مخفی i ام و F_{CN} الگوریتم آموزشی شبکه عصبی را نشان می‌دهد. علاوه بر این، بردار متغیرهای طراحی برای بهینه‌سازی شبکه‌ای است که تعداد لایه‌های مخفی آن برابر با j است (مطابق جدول ۳).

بر اساس داده‌های جمع‌آوری شده، مشخص شد که در مجموع ۱۴۴ نمونه وجود دارد و این سیستم دارای چهار ورودی (جدول ۳) و یک خروجی (DI) است. برای اجرای فرآیند آموزش شبکه عصبی، داده‌های تجربی استخراج شده به سه بخش به صورت تصادفی تقسیم


^۱ Correlation Coefficient

می‌شوند: ۷۰٪ برای مجموعه آموزش^۱، ۱۵٪ برای مجموعه اعتبارسنجی^۲ و ۱۵٪ باقی‌مانده برای مجموعه تست^۳. لازم به توضیح است که در فرآیند آموزش شبکه در این پژوهش، از دو مکانیزم استاندارد برای کنترل و پیشگیری از بیش‌برازش استفاده شده است: نخست، تقسیم تصادفی داده‌ها به سه مجموعه مجزای آموزش، اعتبارسنجی و تست، که مجموعه اعتبارسنجی به‌طور مستقل در حین آموزش برای پایش روند خطا و جلوگیری از حفظ‌کردن داده‌ها (به‌جای یادگیری الگو) استفاده شده است؛ دوم، به‌کارگیری روش توقف زودهنگام که در آن فرآیند آموزش شبکه پیش از افزایش مستمر خطای مجموعه اعتبارسنجی متوقف می‌شود. نتایج ارایه شده در بخش بعد، تاثیر بکارگیری این تدابیر در جلوگیری از بیش‌برازش را بخوبی نشان می‌دهند.

۲-۳- بهینه‌سازی شبکه

در این بخش، به استخراج ساختار بهینه شبکه عصبی MLP در حالات مختلف، براساس تعداد لایه‌های مخفی، پرداخته می‌شود. برای اجرای فرآیند بهینه‌سازی، از PSO استفاده شده است. تعداد جمعیت پرندگان در هر مساله، دو برابر تعداد متغیرهای طراحی در نظر گرفته شده و حداکثر تعداد تکرارها برای اجرای الگوریتم بهینه‌سازی نیز ۱۰۰ می‌باشد.

شکل ۸ منحنی همگرایی الگوریتم PSO را برای بهینه‌سازی شبکه با تعداد لایه‌های مخفی مختلف نشان می‌دهد. این نمودار نشان می‌دهد شبکه با سه لایه مخفی دارای بهترین نتیجه و کمترین مقدار خطا بوده است. جدول ۷ نیز جزییات نتایج مربوط به شبکه‌های بهینه در حالات مختلف را نشان می‌دهد.



شکل ۸ منحنی همگرایی الگوریتم PSO را برای بهینه‌سازی ساختار شبکه MLP

Fig. 8. Convergence curve of the PSO algorithm for optimizing the MLP network structure

^۱ Training Set

^۲ Validation Set



^۳ Test set

جدول ۷ مقادیر بهینه متغیرهای طراحی در حالت‌های مختلف

Table 7. Optimal values of the design variables in different cases

شبکه	N_i	F_i	F_{CN}	MSE	R
1HL	۹	logsig	trainlm	۴۹/۶۷۴۱	۰/۹۷۰۳
2HL	{۹,۲۶}	[tansig, tansig]	trainrp	۴۷/۱۹۹۲	۰/۹۷۱۴
3HL	{۲۶,۲۷,۷}	[tansig, elliosig, logsig]	trainlm	۲۷/۸۱۴۵	۰/۹۸۴۰
4HL	{۲۵,۲۴,۲۲,۵}	[tansig, logsig, tansig, logsig]	trainbfg	۳۶/۸۶۰۰	۰/۹۷۷۶
5HL	{۲۵,۱۷,۵,۱۹,۲۱}	[poslin, poslin, logsig, logsig, elliosig]	trainlm	۴۶/۲۵۰۹	۰/۹۷۲۹

برای مقایسه‌ها شبکه‌ها با تعداد لایه‌های مختلف، شکل‌های ۹ مقادیر خطای MSE و ضریب R را برای حالات مختلف با هم مقایسه کرده‌اند. مقایسه این نمودارها نشان می‌دهد افزایش تعداد لایه‌های مخفی تا محدوده خاصی موجب بهبود کارایی شبکه و کم‌شدن خطا می‌شود، اما افزایش تعداد لایه‌ها پس از آن موجب افزایش خطا خواهد شد. در مقایسه بین حالات مختلف برای مساله مورد بررسی، شبکه MLP با سه لایه مخفی دارای بهترین پاسخ و کمترین خطا بوده است.




ب- ضریب همبستگی R

شکل ۹ مقایسه شبکه‌های بهینه در حالات مختلف

Fig. 9. Comparison of the optimal networks in different cases: (a) MSE error, (b) correlation coefficient R

۴- نتایج مربوط به شبکه بهینه


با توجه به نتایج ارائه شده در بخش قبل، بهترین شبکه طراحی شده از فرآیند بهینه‌سازی، شبکه‌ای با سه لایه مخفی بوده است. شکل ۱۰ ساختار کلی این شبکه بهینه را نشان می‌دهد. در ادامه، تحلیل خطای این شبکه بهینه انجام خواهد شد.



شکل ۱۰ ساختار شبکه MLP بهینه

Fig. 10. Structure of the optimal MLP network

شکل ۱۱ نمودار همگرایی فرایند آموزش شبکه بهینه را دیتاهای آموزشی، اعتبارسنجی و تست نشان می‌دهد. همانطور که در این نمودار پیداست فرایند آموزشی در اپوک ۱۳ برای جلوگیری از بیش‌آموزش^۱ و بیش‌برازش^۲ متوقف شده است. شکل ۱۲ هم نمودار ضریب همبستگی R را برای شبکه بهینه نشان می‌دهد. در این شکل، ضریب R برای داده‌های آموزشی، اعتبارسنجی، تست و کل داده‌ها بطور مجزا ارایه شده است. مقادیر R نشان‌دهنده آموزش مناسب شبکه برای شبیه‌سازی ضریب DI در مساله مورد بررسی می‌باشد.




شکل ۱۱ نمودار همگرایی فرایند آموزش شبکه بهینه


Fig. 11. Convergence plot of the training process of the optimal network

^۱ Overtraining


^۲ Overfitting




الف- داده‌های آموزشی



ب- داده‌های اعتبارسنجی



ج- داده‌های تست



د- کل داده‌ها

شکل ۱۲ نمودار ضریب همبستگی R در فرایند آموزش شبکه بهینه

Fig. 12. Correlation coefficient (R) plots during training of the optimal network: (a) training data, (b) validation data, (c) test data, (d) all data

اطلاعات مربوط به ساختار شبکه بهینه و تحلیل خطای آن را می‌توان به شرح زیر خلاصه کرد:

- شبکه MLP بهینه دارای سه لایه مخفی است که در لایه‌های مخفی اول، دوم و سوم آن به ترتیب ۲۶، ۲۷ و ۷ نورون وجود دارد.
- توابع انتقال شبکه MLP بهینه در لایه‌های مخفی اول، دوم و سوم آن به ترتیب از نوع tansig ، elliosig و logsig هستند.
- الگوریتم آموزشی بدست آمده برای آموزش شبکه بهینه از نوع trainlm است.

- مقادیر MSE و R برای شبکه MLP بهینه‌شده به ترتیب برابر با ۲۷/۸۱۴۵ و ۰/۹۸۴ است.
- همچنین مقدار MAE برابر ۲/۶۲ است که مقایسه این مقدار با خطای MSE نشان‌دهنده وجود تعداد محدودی نمونه با خطای نسبتاً بزرگ در کنار اکثریت نمونه‌های با خطای بسیار کوچک است.

۵- نتیجه‌گیری

در این پژوهش به استفاده از شبکه عصبی MLP جهت شناسایی و پیش‌بینی مقدار شاخص آسیب (لقی در مفاصل) در مکانیزم لنگ و لغزنده پرداخته شده است. هدف استفاده از شبکه عصبی، ایجاد رابطه بین پارامترهای ورودی و خروجی مساله مورد بررسی است. براساس داده‌های جمع‌آوری‌شده، در مجموع ۱۴۴ نمونه وجود دارد و این سیستم دارای چهار ورودی و یک خروجی شاخص آسیب است. به منظور استخراج یک شبکه بهینه و دستیابی به بهترین عملکرد جهت کاهش خطا، از روش بهینه‌سازی PSO استفاده شده و ساختار شبکه شامل تعداد لایه‌ها، تعداد نرون‌ها، تابع تحریک و الگوریتم آموزشی بهینه شده است. برای مقایسه‌ها شبکه‌ها با تعداد لایه‌های مختلف، مقادیر خطای MSE و ضریب R برای حالات مختلف با هم مقایسه شده است که نشان می‌دهد افزایش تعداد لایه‌های مخفی تا محدوده خاصی موجب بهبود کارایی شبکه و کم‌شدن خطا می‌شود، اما افزایش تعداد لایه‌ها پس از آن موجب افزایش خطا خواهد شد. در مقایسه بین حالات مختلف برای مساله مورد بررسی، شبکه MLP با سه لایه مخفی دارای بهترین پاسخ و کمترین خطا در تشخیص شاخص آسیب بوده است.

۶- فهرست علائم

علائم انگلیسی	
C	لقی
L_i	طول لینک شماره i
m_i	جرم لینک شماره i
M_i	گشتاور وارد شده به جرم M_i
q_j	متغیر مستقل q_j
Q_j	نیروی کلی اعمالی به لینک Q_j
R_j	شعاع ژورنال
R_B	شعاع مفصل
$\dot{r}_{F_i}$	سرعت انتقالی لینک $\dot{r}_{F_i}$
T	انرژی جنبشی
U	انرژی پتانسیل
v_T	سرعت مماسی نسبی
DI	شاخص آسیب
علائم یونانی	
α_i	شتاب زاویه‌ای لینک α_i
ω_i	سرعت زاویه‌ای پیوند ω_i

۷- تشکر و قدردانی

این اثر تحت حمایت مادی بنیاد علم ایران (INSF) برگرفته شده از طرح شماره "۴۰۳۸۷۵۳" انجام شده است.

۸- مراجع و منابع

- [1] S.M. Varedi, H.M. Daniali, M. Dardel, A. Fathi, Optimal dynamic design of a planar slider-crank mechanism with a joint clearance, *Mechanism and Machine Theory*, 86 (2015) 191–200.
- [2] S.M. Varedi, H.M. Daniali, M. Dardel, Dynamic synthesis of a planar slider–crank mechanism with clearances, *Nonlinear Dynamics*, 79(2) (2015) 1587–1600.
- [3] X. Chen, S. Gao, Dynamic accuracy reliability modeling and analysis of planar multi-link mechanism with revolute clearances, *European Journal of Mechanics - A/Solids*, 90 (2021) 104317.
- [4] Z.F. Bai, Y. Sun, A study on dynamics of planar multibody mechanical systems with multiple revolute clearance joints, *European Journal of Mechanics - A/Solids*, 60 (2016) 95–111.
- [5] X. Chen, S. Jiang, Dynamic response and chaos in planar multi-link mechanism considering revolute clearances, *Archive of Applied Mechanics*, 90(9) (2020) 1919–1941.
- [6] Y. Chen, K. Wu, X. Wu, Y. Sun, T. Zhong, Kinematic accuracy and nonlinear dynamics of a flexible slider-crank mechanism with multiple clearance joints, *European Journal of Mechanics - A/Solids*, 88 (2021) 104277.
- [7] X. Jiang, Z. Bai, Dynamic analysis for mechanical system with clearance joint considering dependent interval parameters, *Mechanics Based Design of Structures and Machines*, 52(5) (2024) 2726–2748.
- [8] Q. Jing, H. Liu, Dynamic analysis and wear calculation of space deployable mechanism considering spherical joints with clearance and coating, *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 237(12) (2023) 2729–2752.
- [9] S.B. Matekar, A.M. Fulambarkar, Displacement analysis of slider in slider-crank mechanism with joint clearance, *Australian Journal of Mechanical Engineering*, 20(4) (2022) 949–958.
- [10] H. Tan, Y. Hu, L. Li, A continuous analysis method of planar rigid-body mechanical systems with two revolute clearance joints, *Multibody System Dynamics*, 40(4) (2017) 347–373.
- [11] S.M. Varedi-Koulaei, H.M. Daniali, M. Farajtabar, B. Fathi, M. Shafiee-Ashtiani, Reducing the undesirable effects of joints clearance on the behavior of the planar 3-RRR parallel manipulators, *Nonlinear Dynamics*, 86(2) (2016) 1007–1022.
- [12] H. Tan, Y. Hu, L. Li, Effect of friction on the dynamic analysis of slider-crank mechanism with clearance joint, *International Journal of Non-Linear Mechanics*, 115 (2019) 20–40.
- [13] P. Kot, M. Muradov, M. Gkantou, G.S. Kamaris, K. Hashim, D. Yeboah, Recent Advancements in Non-Destructive Testing Techniques for Structural Health Monitoring, in: *Applied Sciences*, 2021, pp. 2750.
- [14] I.Y. Solodov, N. Krohn, G. Busse, CAN: an example of nonclassical acoustic nonlinearity in solids, *Ultrasonics*, 40(1) (2002) 621–625.
- [15] M.Á. Climent-Llorca, M. Miró-Oca, P. Poveda-Martínez, J. Ramis-Soriano, Use of Higher-Harmonic and Intermodulation Generation of Ultrasonic Waves to Detecting Cracks due to Steel Corrosion in Reinforced Cement Mortar, *International Journal of Concrete Structures and Materials*, 14(1) (2020) 52.
- [16] D.M. Donskoy, A.M. Sutin, Vibro-Acoustic Modulation Nondestructive Evaluation Technique, *Journal of Intelligent Material Systems and Structures*, 9(9) (1998) 765–771.
- [17] A. Klepka, K. Dziedzic, J. Mrówka, J. Górski, Experimental investigation of modulation effects for contact-type interfaces in vibro-acoustic modulation tests, *Structural Health Monitoring*, 20(3) (2019) 917–930.
- [18] N. Sepehry, M. Ehsani, S. Asadi, M. Shamsheersaz, F.B. Nejad, Fourier spectral element for simulation of vibro-acoustic modulation caused by contact nonlinearity in the beam, *Thin-Walled Structures*, 174 (2022) 109112.
- [19] N. Li, F. Wang, G. Song, New entropy-based vibro-acoustic modulation method for metal fatigue crack detection: An exploratory study, *Measurement*, 150 (2020) 107075.

- [20] D. Donskoy, D. Liu, Vibro-acoustic modulation baseline-free non-destructive testing, *Journal of Sound and Vibration*, 492 (2021) 115808.
- [21] D. Liu, D. Donskoy, Vibroacoustic modulation method with arbitrary probe wave frequency based on machine learning algorithms, *Nondestructive Testing and Evaluation*, 38(5) (2023) 845–860.
- [22] D. Liu, D. Donskoy, Cross-correlation vibro-acoustic modulation method for damage detection, *Structural Health Monitoring*, 23(2) (2023) 836–855.
- [23] Y. He, Y. Xiao, Z. Su, Y. Pan, Z. Zhang, Contact acoustic nonlinearity effect on the vibro-acoustic modulation of delaminated composite structures, *Mechanical Systems and Signal Processing*, 163 (2022) 108161.
- [24] F. Wang, G. Song, Monitoring of multi-bolt connection looseness using a novel vibro-acoustic method, *Nonlinear Dynamics*, 100(1) (2020) 243–254.
- [25] F. Wang, G. Song, Bolt early looseness monitoring using modified vibro-acoustic modulation by time-reversal, *Mechanical Systems and Signal Processing*, 130 (2019) 349–360.
- [26] S.M.Y. Nikraves, M. Goudarzi, Experimental and numerical looseness detection and assessment in flanged joints using vibro-acoustic modulation method, *Mechanics Based Design of Structures and Machines*, 50(4) (2022) 1400–1416.
- [27] P. Karve, S. Miele, K. Neal, S. Mahadevan, V. Agarwal, E.R. Giannini, P. Kyslinger, Vibro-acoustic modulation and data fusion for localizing alkali-silica reaction-induced damage in concrete, *Structural Health Monitoring*, 19(6) (2020) 1905–1923.
- [28] T. Ma, J. Shen, D. Song, F. Xu, A two-level fusion model of vibro-acoustic signals for centrifugal fan blade crack detection, *Structural Health Monitoring*, 23(6) (2024) 3800–3813.
- [29] N. Sepehry, M. Ehsani, A. Chavoshi, H. Amindavar, Fractional wavelet synchrosqueezed transform for linear chirp signal: theory and damage detection by the electromechanical impedance based nonlinear wave modulation, *Reliability Engineering & System Safety*, 262 (2025) 111203.
- [30] C.-L. Fan, Deep neural networks for automated damage classification in image-based visual data of reinforced concrete structures, *Heliyon*, 10(19) (2024) e38104.
- [31] D. Kautz Monteiro, L.F.F. Miguel, G. Zeni, T. Becker, G. Souza de Andrade, R. Rodrigues de Barros, Detection, Localization, and Quantification of Damage in Structures via Artificial Neural Networks, *Shock and Vibration*, 2023(1) (2023) 8829298.
- [32] Y. Jiang, Road damage detection and classification using deep neural networks, *Discover Applied Sciences*, 6(8) (2024) 421.
- [33] G. Behnoush, G.R. Majid, D. Dimitri, S. Hossain, Vibro-acoustic modulation technique comparison with conventional nondestructive evaluation methods, in: *Proc.SPIE*, 2020, pp. 113811W.
- [34] K.-Y. Jhang, Nonlinear ultrasonic techniques for nondestructive assessment of micro damage in material: A review, *International Journal of Precision Engineering and Manufacturing*, 10(1) (2009) 123–135.
- [35] S. Sony, S. Laventure, A. Sadhu, A literature review of next-generation smart sensing technology in structural health monitoring, *Structural Control and Health Monitoring*, 26(3) (2019) e2321.

Modeling the Damage Index in a Slider-Crank Mechanism with Clearance Joints Using Optimized MLP Neural Networks

Seyed Hesam Zahabi Baboukani^a, Seyed Mojtaba Varedi-Koulaei^{1b}, Naserodin Sepehry^c

^a PhD Student, Faculty of Mechanical Engineering, Shahrood University of Technology

^b Associate Professor, Faculty of Mechanical Engineering, Shahrood University of Technology

^c Assistant Professor, Faculty of Mechanical Engineering, Shahrood University of Technology

ABSTRACT

Mechanisms typically have clearance in their joints due to manufacturing and assembly requirements, and this clearance tends to increase during operation. If the clearance exceeds the allowable limit, it can lead to decreased accuracy, increased vibrations and noise, and reduced system efficiency. Therefore, timely identification of the increase in the amount of clearance in the joints is essential to prevent destructive effects and increased maintenance costs. In recent years, the use of health monitoring methods has gained considerable attention due to their effectiveness and cost efficiency. In this study, the time history of the acceleration of the slider link due to the operation of a slider-crank mechanism with radial clearance in revolute joints is investigated. To identify defects, we present a novel index based on nonlinear monitoring methods, including vibration-acoustic modulation (VAM) and high-order harmonic generation (HHG), which can help predict the presence or absence of clearance in the mechanism. Then, using the collected data, we trained a multilayer perceptron (MLP) neural network to address the study problem and predict the index value. Also, the structure of the neural network was optimized using the particle swarm algorithm (PSO). The results demonstrate that the optimized network can accurately predict the desired index based on the input values.

KEYWORDS

Slider-crank mechanism, Structural health monitoring, Vibro-acoustic modulation, Higher harmonic generation, MLP neural network.

¹ Corresponding author e-mail: varedi@shahroodut.ac.ir