

Hybrid Deep Learning-Based Lifetime Prediction from Multiaxial Fatigue Mechanical Data

Behnam Anbarlooie*, Seyed Mohammad Mahdi Rouholamini

Faculty of Aerospace and New Technologies, Shahid Beheshti University, Tehran, Iran

ABSTRACT

Accurate prediction of fatigue life in materials is a fundamental challenge in mechanical design since it strongly affects the safety, reliability, and maintenance cost of engineering structures. Traditional empirical and analytical fatigue models, while widely applied, often fail to capture nonlinear and multiaxial effects arising under variable loading conditions. In this study, a hybrid deep-learning architecture is developed that integrates three complementary components: a fully connected (FC) network for static material features, a bidirectional long short-term memory (Bi-LSTM) network for sequential loading path, and a transformer encoder for multi-path feature fusion and high-level relational learning. Experimental stress-strain data were normalized and divided into training and testing sets, and the model was optimized using the Adam algorithm with a learning rate of 5×10^{-4} for 2000 epochs. Quantitative evaluation demonstrates that the proposed FC-Bidirectional LSTM-Transformer model achieves superior accuracy compared with five baseline networks, with $MSE = 0.335$, $MAE = 0.1385$, and $R^2 = 0.9470$. Physically, the model captures complex fatigue responses without empirical hypotheses, enabling data-driven representation of material behavior. The developed framework provides a reliable computational tool for fatigue life estimation and can be extended to complex materials and multiaxial loading conditions in aerospace and automotive applications.

KEYWORDS

Fatigue life prediction, deep learning, Bidirectional LSTM, transformer

* b_anbarloei@sbu.ac.ir

1. Introduction

Fatigue failure is one of the primary causes of structural damage in mechanical and industrial components subjected to cyclic loading[1]. Micro-crack initiation and propagation under repeated stresses eventually lead to catastrophic fracture, often without significant prior deformation. Accurate fatigue life prediction plays a critical role in ensuring structural safety, optimizing maintenance schedules, and reducing unexpected failures in aerospace, automotive, and energy industries[2].

Traditional fatigue prediction methods, including S–N curves and empirical energy-based formulations, require extensive experimental campaigns and often struggle to capture nonlinear interactions between material properties and complex multiaxial loading paths[3]. With the rapid development of artificial intelligence, deep learning techniques have emerged as promising alternatives for modeling nonlinear systems[4].

Most previous studies have relied on feedforward neural networks or convolutional architectures, which primarily process static features and are not inherently designed to capture temporal dependencies in sequential loading data[5]. Recurrent neural networks, particularly long short-term memory models, are capable of modeling long-term dependencies in time series; however, they may not effectively integrate static material characteristics. Consequently, there remains a gap in developing unified models capable of simultaneously learning static mechanical features and dynamic loading sequences[6].

To address this challenge, the present study proposes a hybrid deep learning architecture combining fully connected layers, a bidirectional long short-term memory network, and a Transformer encoder. The objective is to construct a unified data-driven framework capable of learning complex nonlinear relationships between mechanical properties, multiaxial loading paths, and fatigue life.

2. Methodology

The objective is to predict the fatigue life of metallic specimens subjected to multiaxial stress–strain loading histories. The dataset is extracted from the Metal Multiaxial Fatigue Dataset and includes experimental results for six metallic materials under 48 distinct loading paths grouped into eight categories as shown in Figure [7].

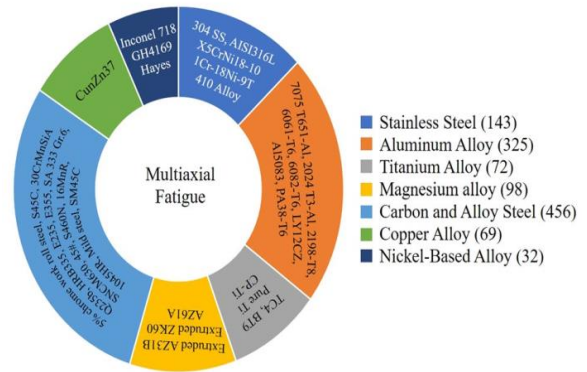


Figure 1. Composition of metallic materials included in the Multiaxial Fatigue Dataset.

Input features are divided into two main categories:

- Static material properties, including Young’s modulus, yield strength, ultimate tensile strength, and Poisson’s ratio.
- Temporal loading sequences, including axial strain and shear strain histories recorded throughout the loading cycles.[7].

The fatigue life, expressed as the number of cycles to failure, is used as the regression target. The dataset is normalized and randomly divided into training (80%) and testing (20%) subsets to evaluate generalization capability.

As illustrated in Figure-2, the overall architecture of the proposed hybrid deep learning model is designed to effectively integrate static material properties with temporal loading information in order to enhance the prediction capability of multiaxial fatigue life




Figure 2. Schematic representation of the hybrid deep learning model architecture, including the static feature pathway, the loading time-series pathway, the fully

connected network, the bidirectional LSTM network, and the Transformer encoder module for fatigue life prediction.

The proposed framework consists of three main components that work together to extract meaningful representations from both static and sequential data. By combining fully connected layers, a bidirectional long short-term memory network, and a Transformer encoder module, the model is able to capture complex nonlinear relationships between material properties, loading histories, and fatigue life.

In the first stage, a fully connected subnetwork processes the static mechanical properties of the material. A fully connected perceptron receives a four-dimensional input vector consisting of key mechanical parameters such as Young's modulus, yield strength, ultimate tensile strength, and Poisson's ratio. This subnetwork includes two fully connected layers with nonlinear activation functions, which transform the input features into a latent representation that reflects the intrinsic mechanical characteristics of the material.

In the second stage, a bidirectional long short-term memory (BiLSTM) network is used to model the temporal behavior of the loading sequences. The BiLSTM processes axial and shear strain histories simultaneously in both forward and backward directions, allowing the network to learn contextual information from past and future states within the loading cycle. This bidirectional processing significantly improves the model's ability to represent path-dependent fatigue behavior and capture temporal dependencies within multiaxial stress-strain histories.

Finally, the extracted representations are integrated through a Transformer encoder module equipped with a multi-head self-attention mechanism. This module enables the model to dynamically assign importance to different temporal segments of the loading sequence. As a result, the network can effectively capture long-range dependencies and complex correlations within the stress-strain data that may not be easily learned by recurrent structures alone.

After feature fusion, the combined representation is passed through a final regression layer to estimate the fatigue life of the material. In order to improve generalization and prevent overfitting, regularization techniques such as dropout and weight normalization are applied during the training process.

The proposed model was trained for 2000 epochs using the Adam optimization algorithm with a learning rate of 5×10^{-4} and a batch size of 128. The mean squared error (MSE) was employed as the loss function during the training process in order to minimize the

discrepancy between the predicted and actual fatigue life values.

The predictive performance of the model was evaluated using several commonly adopted regression metrics, including mean squared error (MSE), mean absolute error (MAE), root mean squared error (RMSE), and the coefficient of determination (R^2). These metrics provide complementary perspectives on the accuracy and robustness of the proposed model in estimating fatigue life.

As summarized in Table 1, the quantitative performance results of the model in terms of MSE, MAE, RMSE, and R^2 are reported.

Table 1. Performance evaluation results of the proposed FC-BiLSTM-Transformer hybrid model on the test dataset.

Metric	Value
MAE	0.1385
MSE	0.0335
RMSE	0.1830
R^2	0.9470

In addition, the main training and hyperparameter settings used in the proposed architecture are presented in Table 2.

Table 2. Final values of the training and hyperparameter settings of the FC-BiLSTM-Transformer hybrid model for multiaxial fatigue life prediction.

Parameter	Value/Name
Learning Rate	5×10^{-4}
Batch size	128
Training epoch	2000
Optimizer	Adam
Momentum coefficients	$\beta_1 = 0.9$ $\beta_2 = 0.999$
Dropout	0.1
Activation Function	ReLU
Hidden vector size	8
Number of attention	4

heads	
Encoder feature vector size	128

Bidirectional
LSTM +
Transformer

Results and Discussion As shown in Table 3, the proposed FC-BiLSTM-Transformer model demonstrates a significant improvement in predictive performance compared with the other models considered in this study. While the standalone models, including the fully connected network (MLP), unidirectional LSTM, and bidirectional LSTM, exhibit relatively higher prediction errors and lower coefficients of determination, the hybrid architectures provide noticeably better results.

In particular, integrating the fully connected network with the bidirectional LSTM substantially improves the prediction accuracy, indicating the importance of combining static material features with temporal loading information. Furthermore, the incorporation of the Transformer encoder in the proposed architecture leads to an additional performance gain.

As a result, the FC-BiLSTM-Transformer model achieves the lowest error values and the highest coefficient of determination among all evaluated models, with MSE = 0.0335, MAE = 0.1385, and $R^2 = 0.9470$. These results confirm that the proposed hybrid architecture is more effective in capturing complex nonlinear relationships between material properties, loading sequences, and multiaxial fatigue life.

Table 3. Comparison of the performance of different learning models, including the fully connected network (MLP), unidirectional long short-term memory network (LSTM), bidirectional long short-term memory network (BiLSTM), fully connected + bidirectional long sh

Model	MSE	MAE	(R^2)
Fully Connected Network	0.5017	0.5564	0.2064
Unidirectional LSTM Network	0.3007	0.3703	0.5243
Bidirectional LSTM Network	0.3140	0.3692	0.5033
Fully Connected + Bidirectional LSTM	0.0667	0.1723	0.8940
Fully Connected +	0.0335	0.1385	0.9470

The reduction in error confirms the effectiveness of integrating static mechanical features with dynamic loading information. Most predicted values fall within acceptable engineering error bands when compared to experimental fatigue life data.

Feature importance analysis indicates that Young's modulus has the most significant impact on prediction accuracy, followed by yield strength and ultimate tensile strength. This observation is consistent with established fatigue mechanics principles, where material stiffness and strength strongly influence crack initiation and propagation behavior.

The Transformer encoder enhances performance by capturing long-range temporal correlations beyond the capacity of conventional recurrent structures. The synergy among the three modules enables the network to model complex nonlinear interactions without relying on empirical fatigue formulas.

3. Conclusions

The proposed FC-BiLSTM-Transformer model achieves a mean squared error of 0.0335 and a coefficient of determination of 0.9470 on the test dataset. Compared with standalone fully connected networks, unidirectional long short-term memory models, and hybrid fully connected-bidirectional long short-term memory architectures, the proposed model demonstrates significantly improved predictive accuracy.

The reduction in error confirms the effectiveness of integrating static mechanical features with dynamic loading information. Most predicted values fall within acceptable engineering error bands when compared to experimental fatigue life data.

Feature importance analysis indicates that Young's modulus has the most significant impact on prediction accuracy, followed by yield strength and ultimate tensile strength. This observation is consistent with established fatigue mechanics principles, where material stiffness and strength strongly influence crack initiation and propagation behavior.

The Transformer encoder enhances performance by capturing long-range temporal correlations beyond the capacity of conventional recurrent structures. The synergy among the three modules enables the network to model complex nonlinear interactions without relying on empirical fatigue formulas.

4. References

- [1] J.A. Bannantine, J.J. Comer, J.L. Handrock, Fundamentals of Metal Fatigue Analysis, Prentice Hall, 1990.
- [2] S. Suresh, Fatigue of materials, Cambridge university press, 1998.
- [3] T. Harris, W.K. Yu, Lundberg-Palmgren fatigue theory: considerations of failure stress and stressed volume, *Journal of Tribology*, 121(1) (1999) 85–89.
- [4] J. Yang, G. Kang, Y. Liu, Q. Kan, A novel method of multiaxial fatigue life prediction based on deep learning, *International Journal of Fatigue*, 151 (2021) 106356.
- [5] Y. Mizuno, A. Hosoi, H. Koshita, D. Tsunoda, H. Kawada, Fatigue life prediction of composite materials using strain distribution images and a deep convolution neural network, *Scientific reports*, 14(1) (2024) 25418.
- [6] C.M. Bishop, H. Bishop, *Deep Learning: Foundations and Concepts*, Springer International Publishing, 2023.
- [7] S. Chen, Y. Bai, X. Zhou, A. Yang, A deep learning dataset for metal multiaxial fatigue life prediction, *Scientific Data*, 11(1) (2024) 1027.

پیش‌بینی طول عمر با استفاده از مدل یادگیری عمیق ترکیبی بر مبنای داده‌های مکانیکی

خستگی چندمحوره

بهنام انبارلویی*، سید محمد مهدی روح‌الامینی

دانشکده هوافضا و فناوری‌های نوین، دانشگاه شهید بهشتی، تهران، ایران

* b_anbarloei@sbu.ac.ir

چکیده

پیش‌بینی عمر خستگی مواد از چالش‌های بنیادی در طراحی سازه‌های مهندسی است و نقشی کلیدی در ارتقای ایمنی و کاهش هزینه‌های نگهداری دارد. روش‌های تجربی و مکانیکی کلاسیک، علیرغم کاربرد گسترده، در توصیف رفتارهای غیرخطی ناشی از بارگذاری‌های متغیر با مشکلات متعددی مواجه هستند. در این پژوهش، مدلی ترکیبی بر پایه یادگیری عمیق برای مطالعه طول عمر خستگی توسعه داده شده که از سه بخش اصلی تشکیل می‌شود: شبکه کاملاً متصل برای ویژگی‌های عددی مواد، شبکه بازگشتی دوطرفه برای استخراج الگوهای زمانی بارگذاری و مازول ترنسفورمر برای ادغام اطلاعات دو مسیر و یادگیری روابط سطح بالا. داده‌های آزمایشگاهی شامل مشخصات مکانیکی و مسیر تنش- کرنش، پس از نرمال‌سازی و تفکیک داده‌ها به مجموعه آموزش و آزمون، مجموعه آموزش با الگوریتم بهینه‌سازی آدم به تعداد ۲۰۰۰ تکرار آموزش داده شد. نتایج حاکی از دقت بالا و ضریب تعیین قابل قبول مدل پیشنهادی بر روی مجموعه آزمون و برتری آن نسبت به رویکردهای پایه است. برخلاف پژوهش‌های پیشین که عمدتاً بر تک‌مدل‌های یادگیری عمیق متکی بودند، نوآوری اصلی این پژوهش در هم‌افزایی میان لایه‌های تمام‌متصل، شبکه عصبی حافظه کوتاه‌مدت طولانی دوطرفه و مکانیزم توجه در ترنسفورمر نهفته است که امکان یادگیری هم‌زمان ویژگی‌های هندسی مواد و وابستگی‌های زمانی پیچیده در تاریخچه بارگذاری را فراهم می‌آورد. این چارچوب چندمسیره قابلیت بالایی برای کاربرد در سامانه‌های پایش سلامت و طراحی بهینه سازه‌ها دارد.

کلمات کلیدی

عمر خستگی، یادگیری عمیق، شبکه‌ی عصبی بازگشتی، ترنسفورمر، بارگذاری تنش-کرنش.

پدیده خستگی یکی از مهم‌ترین عوامل شکست در اجزای مکانیکی و سازه‌های صنعتی است. خستگی^۱ ناشی از اعمال بارهای تناوبی یا سیکلی است که در طول زمان موجب شکل‌گیری ترک‌های میکروسکوپی و در نهایت شکست کامل ماده می‌شود [۱]. پیش‌بینی دقیق عمر خستگی نقشی کلیدی در طراحی ایمن قطعات، بهینه‌سازی فرآیندهای نگهداری و جلوگیری از خرابی‌های ناگهانی در صنایع مختلف ایفا می‌کند [۲].

اهمیت پایش و تخمین عمر خستگی در حوزه‌های گسترده‌ای از جمله هوافضا، خودروسازی و صنایع نفت و گاز مشهود است [۳]. زیرا قطعات در این کاربردها تحت بارهای متناوب و متغیر قرار گرفته و شکست آن‌ها می‌تواند خسارات مالی و انسانی سنگینی به همراه داشته باشد [۴]. به همین دلیل، توسعه‌ی مدل‌هایی که بتوانند رفتار خستگی را با دقت بالا پیش‌بینی کنند، یکی از چالش‌های اصلی علوم مکانیک و مواد محسوب می‌شود [۵].

رفتار خستگی مواد به عوامل متعددی از جمله خواص مکانیکی ماده، دامنه‌ی تنش، نرخ کرنش و دمای محیط وابسته است [۲]. روش‌های کلاسیک مانند منحنی‌های S-N و مدل‌های مبتنی بر انرژی، علی‌رغم کاربرد وسیع، مستلزم انجام آزمایش‌های تجربی متعدد، پرهزینه و زمان‌بر هستند و معمولاً در تخمین روابط پیچیده و غیرخطی میان پارامترهای ورودی و عمر خستگی عملکرد ضعیفی دارند [۶]. در سال‌های اخیر، مطالعات متعددی با بهره‌گیری از الگوریتم‌های یادگیری عمیق برای مطالعه رفتار خستگی انجام شده است [۷].

بیشتر این پژوهش‌ها از شبکه‌های عصبی پیش‌خور^۲ یا مدل‌های کانولوشنی^۳ برای پیش‌بینی استفاده کرده‌اند [۸] اما این مدل‌ها قادر به ثبت وابستگی‌های زمانی در توالی‌های بارگذاری نیستند و معمولاً تنها جنبه‌ی ویژگی‌های مکانیکی مسئله را پردازش می‌کنند زیرا در مدل‌های پیش‌خور، با ترکیب ویژگی‌ها، ویژگی جدید استخراج می‌شود و در مدل‌های کانولوشنی استخراج ویژگی به صورت مکانی از داده‌های مجاور است. [۹]. از سوی دیگر، شبکه‌های بازگشتی و به‌ویژه نوع واحد حافظه کوتاه‌مدت طولانی^۴ در تحلیل داده‌های ترتیبی و قابلیت یادآوری وابستگی‌های بلندمدت عملکرد بهتری دارند [۱۰]، اما به دلیل تمرکزشان بر جنبه‌ی زمانی، در استخراج ویژگی‌های ایستای مرتبط با خواص مواد یا هندسه‌ی قطعه کارایی کمتری نشان می‌دهند [۱۱]. در نتیجه، خلأ اصلی در این حوزه به نبود مدلی بازمی‌گردد که بتواند به صورت هم‌زمان هر دو نوع ویژگی ایستا^۵ (ویژگی‌های مکانیکی ماده) و مسیر بارگذاری^۶ را با دقت کافی یاد بگیرد و تلفیق کند.

در پاسخ به این چالش، پژوهش حاضر با تلفیق مزایای سه معماری قدرتمند، یعنی شبکه کاملاً متصل، شبکه بازگشتی و ساختار ترنسفورمر، یک مدل ترکیبی یادگیری عمیق ارائه می‌دهد. هدف این مدل، استخراج هم‌زمان الگوهای آماری و زمانی از داده‌های چندمحوره‌ی خستگی و بهبود دقت پیش‌بینی طول عمر قطعات تحت بارگذاری‌های ترکیبی است. بدین ترتیب، این رویکرد ضمن کاهش نیاز به آزمون‌های تجربی فیزیکی، مسیری نو برای تحلیل مبتنی بر داده در مطالعه خستگی را فراهم می‌سازد و می‌تواند زمینه‌ساز توسعه‌ی سامانه‌های هوشمند پایش عمر سازه‌ها در کاربردهای صنعتی پیشرفته باشد.

¹ Fatigue

² Feedforward Neural Network

³ Convolutional Neural Network

⁴ Long Short-Term Memory

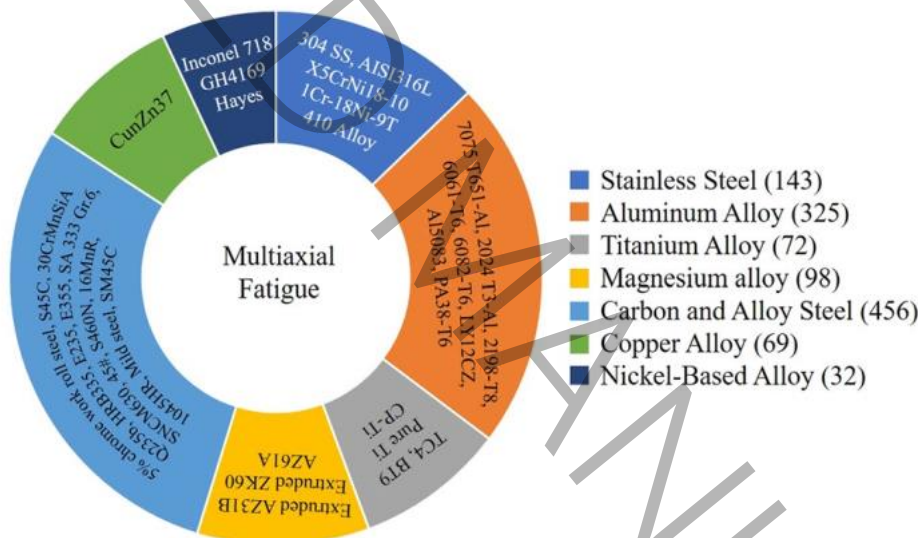
⁵ Static features

⁶ Loading path

۲- مدلسازی یادگیری عمیق ترکیبی

۲-۱- تعریف مسئله و داده‌های ورودی

پدیده‌ی خستگی چندمحوره، به دلیل تنوع جهت‌ها و میزان تنش اعمالی، رفتاری پیچیده و غیرخطی در مواد مهندسی ایجاد می‌کند و پیش‌بینی دقیق عمر آن تنها با استفاده از روابط مکانیکی کلاسیک ممکن نیست [۲]. هدف این پژوهش، تخمین عمر خستگی نمونه‌های فلزی تحت بارگذاری‌های چندمحوره با بهره‌گیری از ترکیب داده‌های مکانیکی و توالی‌های بارگذاری تنش- کرنش است. داده‌های مورد استفاده شامل مشخصات مکانیکی مواد (مدول یانگ، نسبت پواسون، و تنش‌های اصلی در راستاهای مختلف) و نیز داده‌های بارگذاری تنش-کرنش ثبت‌شده در طول سیکل‌های بارگذاری می‌باشند. داده‌های مورد استفاده در این پژوهش از پایگاه داده‌ی خستگی چندمحوره فلزات^۱ استخراج شده‌اند. این دیتاست شامل اطلاعات آزمایشگاهی برای شش نوع ماده فلزی (فولاد، آلومینیوم، تیتانیوم، نیکل، مس و منیزیم) مطابق شکل ۱ است که هر کدام تحت مسیره‌های بارگذاری مختلف آزمایش شده‌اند. اطلاعات کلی مواد و مسیره‌های بارگذاری در پایگاه داده با ساختار مطابق جدول ۱ جمع‌بندی شده و خروجی اصلی آزمایش‌ها، یعنی عمر خستگی، به‌عنوان برچسب^۲ پایانی مدل یادگیری عمیق استفاده گردیده است [۱۲].



شکل ۱- ترکیب مواد فلزی مورد استفاده در پایگاه داده‌ی خستگی چندمحوره فلزات [۱۲].

Fig 1. The composition of the metallic materials used in the multiaxial fatigue database of metals.

¹ Metal Multiaxial Fatigue Dataset

² Label

در این پایگاه، رفتار خستگی مواد فلزی تحت انواع مختلف الگوهای بارگذاری چندمحوره ثبت شده است که هر مسیر معرف نسبت مؤلفه‌های محوری و برشی در طول زمان می‌باشد. مطابق شکل ۲، مسیرهای بارگذاری به ۸ دسته‌ی اصلی تقسیم شده‌اند و در مجموع، دیتاست شامل ۴۸ مسیر بارگذاری است که هر مسیر به صورت سری زمانی در فایل‌های سی‌اس‌وی ذخیره شده است [۱۲]. پایگاه داده‌ی خستگی چندمحوره فلزات قابل دسترسی هستند [۱۳]. این مجموعه داده شامل فایل‌های سی‌اس‌وی^۱ و اکسل^۲ از مسیرهای بارگذاری و ویژگی‌های مکانیکی مواد بوده و در مخزن متریال کلاد^۳ با شناسه‌ی دیجیتال منتشر شده است. این پایگاه داده به صورت آزاد و بر اساس مجوز^۴ در دسترس پژوهشگران قرار دارد و می‌تواند به عنوان مرجع برای مطالعات تکمیلی در زمینه‌ی پیش‌بینی عمر خستگی چندمحوره مواد فلزی به کار رود.

جدول ۱- ساختار نمونه‌ای از داده‌های بارگذاری چندمحوره در پایگاه داده خستگی چندمحوره فلزات [۱۲].

Table 1-Illustration of sample data structure for multiaxial loading in the multiaxial fatigue database of metals [12]

نام مسیرهای بارگذاری	مدول یانگ (گیگاپاسکال)	استحکام کششی نهایی (مگاپاسکال)	استحکام تسلیم (مگاپاسکال)	ضریب پواسون	لگاریتم عمر خستگی
q235b-0.002.CSV	۲۰۶	۴۱۲	۲۳۵	۰/۳۰۴۰۰	۴/۴۲۷۵۸۳۴۷۳
q235b-0.003.CSV	۲۰۶	۴۱۲	۲۳۵	۰/۳۰۴۰۰	۴/۴۲۷۵۸۳۴۷۳
SNCM630-TA05.CSV	۱۹۶	۱۱۰۳	۹۵۱	۰/۲۷۳۰۰	۳/۲۸۷۱۲۹۶۲۱

¹ CSV

² Excel

³ Materials Cloud

⁴ Creative Commons BY 4.0

Loading paths	Diagrams
Uniaxial:	
Proportional:	
Nonproportional I:	
Nonproportional II:	
Nonproportional III:	
Nonproportional IV:	
Nonproportional V:	
Nonproportional VI:	

شکل ۲- انواع مسیرهای بارگذاری چندمحوره در دیتاست خستگی چندمحوره فلزات؛ هر مسیر نمایانگر نسبت متفاوتی از کرنش محوری و کرنش برشی در طول زمان است [۱۳].


Fig 2.Types of multiaxial loading paths in the multiaxial fatigue dataset of metals; each path represents a different ratio of axial strain to shear strain over time

پیش از آموزش مدل، داده‌ها تحت فرآیند پاک‌سازی و استانداردسازی قرار گرفتند تا از وجود داده‌های پرت جلوگیری شود و همگرایی مدل در مراحل یادگیری تسریع گردد [۱۳]. سپس مجموعه داده‌ها به دو بخش آموزش و آزمون تقسیم شدند، به گونه‌ای که حدود ۲۰٪ از کل نمونه‌ها به عنوان مجموعه‌ی آزمون و برای بررسی توانایی تعمیم مدل در شرایط ناشناخته اختصاص یافت. این تقسیم‌بندی به صورت تصادفی انجام شد تا توزیع مناسبی از مواد مختلف و مسیرهای بارگذاری در هر دو مجموعه حفظ شود. هدف از استفاده از مجموعه آزمون مستقل، بررسی قابلیت تعمیم مدل در پیش‌بینی عمر خستگی برای نمونه‌هایی است که در فرآیند آموزش مشاهده نشده‌اند. از آنجا که داده‌ها شامل مواد فلزی مختلف و مسیرهای بارگذاری متنوع هستند، این ارزیابی می‌تواند توانایی مدل در یادگیری روابط کلی بین ویژگی‌های مکانیکی، مسیرهای تنش-کرنش و عمر خستگی را نشان دهد. نتایج به دست آمده بر روی مجموعه آزمون نشان می‌دهد که مدل پیشنهادی قادر است الگوهای کلی رفتار خستگی چندمحوره را از داده‌های آموزشی استخراج کرده و آن‌ها را برای نمونه‌های جدید نیز تعمیم دهد. این ویژگی برای کاربردهای مهندسی که در آن شرایط بارگذاری یا ترکیب مواد ممکن است متفاوت باشد، اهمیت قابل توجهی دارد.

جدول ۲- ویژگی‌های مکانیکی ماده مورد استفاده در نمونه‌های تحلیل خستگی [۱۲].

Table 2. Mechanical characteristics of the material employed in the fatigue analysis samples [12].

ضریب پواسون	استحکام تسلیم (مگاپاسکال)	استحکام کششی نهایی (مگاپاسکال)	مدول یانگ (گیگاپاسکال)
۰٫۳۵	۱۹۱٫۵	۲۲۹٫۱	۶۸٫۳



شکل ۳- ساختار داده‌های ورودی شامل مسیرهای بارگذاری چندمحوره (تنش-کرنش) در قالب فایل‌های سی اس وی، نمودار سری زمانی مؤلفه‌های کرنش و منحنی حاصل در صفحه کرنش [۱۲].

Fig 3. The structure of the input data, including multiaxial loading paths (stress-strain) in CSV format, time-series plots of strain components, and the resulting strain-path curves [12].

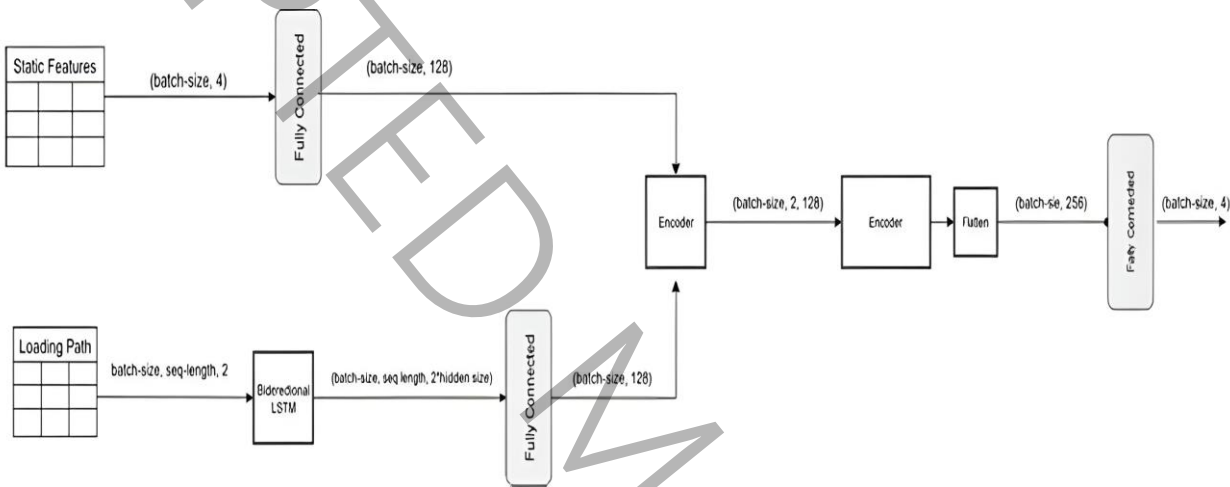
۲-۲- توصیف مفهومی فرآیند پیش‌بینی عمر خستگی چندمحوره

از دیدگاه مهندسی سازه، هدف اصلی این پژوهش تبدیل داده‌های مکانیکی آزمایش خستگی به مدلی تحلیلی است که بتواند رفتار شکست را در بارگذاری‌های مرکب پیش‌بینی کند. داده‌های ورودی شامل مشخصه‌های پایه‌ی مواد (مدول یانگ، تنش تسلیم، تنش کششی نهایی، نسبت پواسون) و مسیرهای تنش-کرنش چندمحوره ثبت‌شده در پایگاه داده خستگی چندمحوره فلزات هستند. این اطلاعات بازتاب‌دهنده واکنش مواد تحت بارهای ترکیبی و تناوبی‌اند.

در مرحله مدل‌سازی، فرآیند یادگیری عمیق به گونه‌ای تنظیم شد که میان این پارامترهای مکانیکی و پاسخ نهایی ماده (تعداد سیکل شکست) ارتباطی غیرخطی برقرار کند. دقت پیش‌بینی مدل مستقیماً به گستره‌ی نوع مواد و تعداد مسیرهای بارگذاری بستگی دارد، به عبارت دیگر، هرچه تنوع داده‌ها بیشتر باشد مدل قادر است طیف وسیع‌تری از رفتارهای خستگی را بازنمایی کند. از این دیدگاه، نقش یادگیری عمیق تنها استخراج پارامترهای عددی نیست، بلکه شبیه‌سازی رفتار ماده در قالب روابط آماری است. نتیجه‌ی این فرآیند، مدلی است که می‌تواند در طراحی ایمن‌تر و ارزیابی دوام قطعات فلزی کاربرد عملی داشته باشد.

۲-۳- ساختار مدل یادگیری عمیق ترکیبی

به منظور برآورد دقیق عمر خستگی چندمحوره مواد فلزی، در این پژوهش یک معماری ترکیبی مبتنی بر یادگیری عمیق توسعه داده شده است که توانایی هم‌زمان درک ویژگی‌های مکانیکی ماده (ویژگی‌های ایستا) و الگوهای دینامیکی مسیر بارگذاری را دارا است. این مدل از سه زیرساختار اصلی شامل شبکه‌ی کاملاً متصل، حافظه کوتاه‌مدت طولانی دو جهته^۱ و ماژول انکودر^۲ تشکیل شده است. ساختار کلی مدل ترکیبی پیشنهادی در شکل ۴ نمایش داده شده است. هدف از این ترکیب، مدل‌سازی روابط پیچیده میان خواص ذاتی ماده و پاسخ زمانی آن تحت بارگذاری چندمحوره است تا تابعی غیرخطی از آن برای پیش‌بینی تعداد چرخه‌های شکست استخراج شود. این مدل ترکیبی به دلیل وجود سلول حافظه کوتاه‌مدت طولانی، وابسته‌ی به مسیر بارگذاری و در نتیجه، مناسب برای خستگی چندمحوره است و از تحلیل نوع داده‌های ورودی پیشنهاد شده است. همچنین، ماژول اینکودر در ساختار مذکور، به دلیل ادغام دو مسیر ویژگی‌های استاتیک و مسیر بارگذاری تعبیه شده است.



شکل ۴- نمای شماتیک معماری مدل یادگیری عمیق ترکیبی شامل مسیر ویژگی‌های ایستا، مسیر سری زمانی بارگذاری، شبکه کاملاً متصل، شبکه دو جهته حافظه کوتاه‌مدت طولانی، و ماژول انکودر ترنسفورمر برای پیش‌بینی عمر خستگی.

Fig 4. Schematic representation of the hybrid deep learning model architecture, including the static-feature pathway, the loading time-series pathway, a fully connected network, a bidirectional long short-term memory (BiLSTM) network, and a Transformer encoder module for fatigue life prediction.

۲-۳-۱- زیرمدل کاملاً متصل برای ویژگی‌های ایستا

ورودی این زیرمدل مطابق شکل ۴ شامل چهار ویژگی مکانیکی ماده است: مدول یانگ (E)، تنش تسلیم (σ_y)، تنش کششی نهایی (σ_u) و نسبت پواسون (ν). برای نگاشت این بردار چهاربعدي به فضای ویژگی‌های نهفته^۳، از دو لایه‌ی کاملاً متصل استفاده شده که هر یک به ترتیب اندازه‌های $100 \rightarrow 4 \rightarrow 20 \rightarrow 100$ دارند. خروجی هر لایه با تابع فعال‌سازی رلو^۴ مشخص می‌شود:

$$h^{(d)} = \text{ReLU}(W^{(d)}x^{(d-1)} + b^{(d)}) \quad (1)$$

¹ Bidirectional long short-term memory

² Encoder module

³ Latent Feature Space

⁴ ReLU Activation Function

که در آن $W^{(0)}$ و $b^{(1)}$ به ترتیب وزن‌ها و بایاس‌های لایه‌ی l و $h^{(1)}$ خروجی لایه هستند. در پایان، بردار ویژگی نهفته $z_{stat} \in \mathbb{R}^{20}$ به عنوان نماینده‌ی خواص ایستا وارد مرحله‌ی ادغام می‌شود. این ساختار باعث مدل‌سازی روابط غیرخطی میان خواص فیزیکی و مقاومت ماده در برابر شکست می‌شود.

۲-۳-۲- زیرمدل شبکه حافظه‌دار دوجته برای داده‌های سری‌زمانی بارگذاری

شکل ۵ ساختار سلول حافظه‌دار بلندمدت را نشان می‌دهد که برای حفظ وابستگی‌های بلندمدت در توالی‌ها استفاده شده است. ورودی و بردار پنهان^۱ خروجی پیشین وارد سه دروازه^۲ می‌شوند. دروازه فراموشی^۳ برای حذف اطلاعات غیرضروری از زمان قبلی، دروازه ورودی^۴ که مشخص می‌کند چه مقدار از ورودی فعلی به حافظه افزوده شود و دروازه خروجی^۵ که تعیین می‌کند چه بخش از اطلاعات جدید به خروجی منتقل گردد. این سه دروازه از اعمال سیگموید و تانژانت هیپربولیک برای کنترل جریان اطلاعات استفاده می‌کنند تا مشکل ناپدیدشدن گرادیان در شبکه بازگشتی ساده را کاهش دهند و یادگیری توالی‌های طولانی مدت تر را ممکن سازند.

داده‌های بارگذاری شامل دو مؤلفه‌ی کرنش محوری $\epsilon_x(t)$ و کرنش برشی $\gamma_{xy}(t)$ در طول مسیر بارگذاری هستند. به منظور بررسی از شبکه حافظه‌دار دوجته با اندازه‌ی بردار پنهان $H = 8$ استفاده شد. این شبکه در هر زمان t خروجی دوجته زیر را تولید می‌کند.

$$\begin{aligned} h_t^{\rightarrow} &= LSTM_{fwd}(x_t), \\ h_t^{\leftarrow} &= LSTM_{bwd}(x_t), \end{aligned} \quad (2)$$

که h_{t-1}^{\rightarrow} و h_{t+1}^{\leftarrow} به ترتیب بردار پنهان شبکه پیش‌رونده^۶ در گام قبل و بردار پنهان شبکه پس‌رونده^۷، x_t ورودی در گام فعلی است.

مطابق شکل ۶ پس از محاسبه خروجی هر شبکه، برای تولید خروجی نهایی از رابطه زیر استفاده شده است.

$$h_t = [h_t^{\rightarrow}; h_t^{\leftarrow}] \quad (3)$$

که h_t خروجی کل توالی است و با اعمال لایه‌ی تراکم به بردار نهفته $z_{dyn} \in \mathbb{R}^{16}$ تبدیل می‌شود. شبکه‌ی دوجته باعث درک هم‌زمان اثر توالی‌های پیش‌رو و پس‌رو در چرخه‌ی بارگذاری می‌شود [۱۴].

¹ Hidden State

² Gate


³ Forget Gate

⁴ Input Gate

⁵ Output Gate

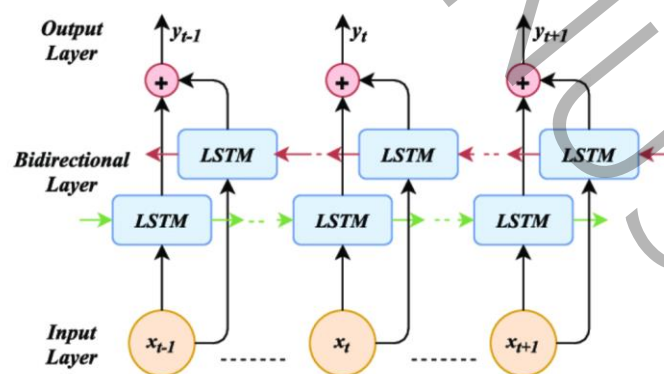
⁶ Forward network

⁷ Backward Network



شکل ۵ - ساختار درونی سلول حافظه کوتاه‌مدت طولانی شامل واحدهای فراموشی، ورودی و خروجی، به همراه مسیر جریان اطلاعات بین حالت پنهان و حافظه سلول [۱۵].

Fig 5. Internal structure of a long short-term memory (LSTM) cell, including the forget, input, and output gates, along with the information flow between the hidden state and the cell state.



شکل ۶- طرح شماتیک شبکه‌ی حافظه کوتاه‌مدت طولانی دوجهته مورد استفاده در مسیر سری زمانی مدل، شامل پردازش هم‌زمان توالی‌های پیش‌رو و پس‌رو برای استخراج وابستگی‌های زمانی بلندمدت از داده‌های بارگذاری چندمحوره [۱۱].

Fig 6. Schematic diagram of the bidirectional long short-term memory (BiLSTM) network used in the time-series pathway of the model, illustrating the simultaneous processing of forward and backward sequences for extracting long-term temporal dependencies from multiaxial loading data.

۳-۲-۳- مازول ترنسفورمر

برای بهبود شناسایی الگوهای وابستگی غیرمحملی در داده‌های زمانی، خروجی شبکه حافظه دار به مازول انکدر ترنسفورمر با پارامترهای $d_{model} = 128$ و تعداد سرهای توجه $n_{head} = 4$ وارد می‌شود. مکانیزم توجه چندسری بر مبنای محاسبات پرس‌وجو^۲ کلید^۳ و مقدار^۴ تعریف می‌شود:

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (۴)$$

که در آن Q, K, V ماتریس‌هایی ناشی از تبدیل خطی داده‌های ورودی هستند [۱۶]. این فرآیند با وزن‌دهی ورودی باعث تمرکز مدل بر بخش‌هایی از توالی می‌شود که بیشترین تأثیر را در تخمین عمر خستگی دارند. افزون بر آن، کدگذاری مکانی^۵ به کمک توابع سینوسی زیر انجام می‌شود تا مدل نسبت به موقعیت گام‌های زمانی حساسیت پیدا کند:

$$PE_{(t, \tau_i)} = \sin\left(\frac{t}{1, \dots, d_{model}} \frac{\tau_i}{d_{model}}\right), \quad (۵)$$

$$PE_{(t, \tau_i+1)} = \cos\left(\frac{t}{1, \dots, d_{model}} \frac{\tau_i}{d_{model}}\right).$$

که t شاخص زمانی یا موقعیت در توالی ورودی، d_{model} ابعاد فضای امبدینگ^۶ است.

d_{model} وظیفه‌ی تنظیم مقیاس فرکانسی را دارد تا هر بعد از بردار ویژگی، اطلاعات موقعیت زمانی را در بازه‌ای متفاوت از دامنه‌ها کدگذاری کند. این باعث می‌شود ترنسفورمر قادر به تشخیص الگوهای محلی و کلی در توالی داده‌ی خستگی باشد [۱۷].

۳-۲-۴- ادغام ویژگی‌ها و تابع پیش‌بینی عمر خستگی

در گام نهایی، بردارهای ویژگی استخراج‌شده از سه بخش فوق به‌صورت:

$$\mathbf{z}_{att} = \text{TransformerEncoder}(\text{Stack}[\mathbf{h}_t, \mathbf{h}_e]) \quad (۶)$$

ترکیب می‌شوند و سپس از یک لایه‌ی پیش‌خور نهایی عبور می‌کنند تا مقدار پیش‌بینی‌شده‌ی عمر خستگی یعنی \hat{N}_f محاسبه شود:

$$\hat{N}_f = W_o z + b_o. \quad (۷)$$

این لایه به‌صورت خطی عمل می‌کند زیرا هدف نهایی یک مسئله‌ی رگرسیون است و خروجی آن نمایانگر پیش‌بینی تعداد چرخه‌های شکست \hat{N}_f است.

به‌منظور جلوگیری از بیش‌برازش^۱، از نرمال‌سازی وزن‌ها برای کنترل مقیاس پارامترها و حذف تصادفی^۲ در مراحل آموزشی بهره گرفته شد. ترکیب این دو تکنیک باعث شده مدل بدون کاهش ظرفیت یادگیری، از حفظ الگوها در داده‌های آموزش جلوگیری کند.

^۱ Head attention

^۲ Query

^۳ Key

^۴ Value

^۵ Positional Encoding

^۶ Embedding

۲-۴- ویژگی علمی و مزیت مدل ترکیبی

مدل ترکیبی پیشنهادی با ادغام سه ساختار یادگیری مختلف، قادر است همزمان هم ویژگی‌های ذاتی ماده و هم الگوهای زمانی وابسته به بارگذاری را در قالب فضای ویژگی مشترک مدل کند. این هم‌افزایی ساختاری، باعث می‌شود شبکه بتواند روابط غیرخطی میان رفتارهای کشسان، پلاستیک و خستگی را بدون نیاز به مدل‌های تجربی کلاسیک، به صورت داده‌محور پیش‌بینی کند.

بر اساس تحلیل ساختار مدل، تابع پیش‌بینی نهایی پیشنهادی $f(E, \sigma_y, \sigma_u, \nu, \epsilon_x(t), \gamma_{xy}(t)) \rightarrow N_f$ دقت بالاتری نسبت به سامانه‌های منفرد مانند شبکه‌های حافظه دار بلند مدت دارد [۱۲].

جدول ۳- مشخصات طراحی و پیکربندی زیرمدل‌های شبکه ترکیبی کاملاً متصل، حافظه کوتاه‌مدت طولانی و ترنسفورمر پیشنهادی برای پیش‌بینی عمر خستگی چندمحوره.

Table 3. Design specifications and configuration of the proposed hybrid submodels—fully connected network, long short-term memory (LSTM), and Transformer—for multiaxial fatigue life prediction.

توجیه طراحی	اندازه خروجی	ورودی	زیربخش مدل
استخراج ویژگی‌های عددی	۱۶	ویژگی‌های ایستا ماده ۴ بعدی	شبکه کاملاً متصل
استخراج ویژگی‌های بارگذاری	۱۲۸	کرنش محوری $\epsilon_x(t)$ و کرنش برشی $\gamma_{xy}(t)$ سایز (۲*۲۴۱)	شبکه حافظه دار بلند مدت + شبکه خطی
ادغام ویژگی‌های دو مسیر فوق	۲۵۶	Stack [$\mathbf{h}_r, \mathbf{h}_\ell$] سایز (۲*۱۲۸)	شبکه ترنسفورمر
پیش‌بینی نهایی	۱	256 → 128 → 64 → 1	شبکه چندلایه پرسپترون

۲-۵- پارامترهای یادگیری و بهینه‌سازی و معیارهای ارزیابی

۲-۵-۱- پارامترهای یادگیری

در فرایند آموزش مدل، پارامترهای بهینه بر اساس بررسی‌های تجربی و پایش روند کاهش خطا انتخاب گردیدند. مقادیر نهایی پارامترها به شرح زیر است:

¹ Overfitting

² Dropout

جدول ۴ - مقادیر نهایی پارامترهای آموزشی و تنظیمی مدل ترکیبی شبکه کاملاً متصل، حافظه کوتاه‌مدت طولانی و ترنسفورمر برای پیش‌بینی عمر خستگی چندمحوره.

Table 4. Final training parameters and hyperparameter settings of the proposed hybrid fully connected-LSTM-Transformer model for multiaxial fatigue life prediction.

پارامتر	مقدار / نام
نرخ یادگیری	4×10^{-5}
بج سایز	۱۲۸
دفعات آموزش	۲۰۰۰
بهینه ساز	Adam
ضرایب مومنوم	$\beta_1 = 0.9$ $\beta_2 = 0.999$
دراپ‌اوت ^۱	۰.۱
تابع هزینه مجموع مربعات خطا	$\mathcal{L}_{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
تابع فعالسازی	ReLU
سایز بردار نهان	۸
تعداد سر توجه	۴
سایز بردار ویژگی	۱۲۸
انکودر	

معادلات مربوط به به‌روزرسانی وزن‌ها در الگوریتم بهینه‌سازی آدام به‌صورت زیر تعریف می‌شوند:

$$\begin{aligned}
 g_t &= \nabla_{\theta} \mathcal{L}(\theta_t), \\
 m_t &= \beta_1 m_{t-1} + (1 - \beta_1) g_t, \\
 v_t &= \beta_2 v_{t-1} + (1 - \beta_2) g_t^2, \\
 \hat{m}_t &= \frac{m_t}{1 - \beta_1^t}, \\
 \hat{v}_t &= \frac{v_t}{1 - \beta_2^t}, \\
 \theta_{t+1} &= \theta_t - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon}
 \end{aligned} \tag{۸}$$

که g گرادیان، $\mathcal{L}(\theta_t)$ تابع خطا، β_1 و β_2 ضرایب اول و دوم ممان، η نرخ یادگیری، ϵ عدد کوچک برای جلوگیری از تقسیم بر صفر و \hat{m}_t و \hat{v}_t نسخه‌های اصلاح‌شده بایاس و وزن‌های به‌روز شده هستند [۱۸].

^۱ Drop Out

^۲ Adam Optimization Algorithm

۲-۵-۲- معیارهای ارزیابی

برای ارزیابی عملکرد مدل، از سه معیار عددی میانگین مجموع مربع خطا^۱، میانگین مجموع قدرمطلق خطا^۲ و ضریب تعیین^۳ استفاده شد که رابطه‌ی آنها به ترتیب به صورت زیر تعریف می‌شود:

میانگین مجموع مربع خطا:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

میانگین مجموع قدرمطلق خطا:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

ضریب تعیین:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (11)$$

که n تعداد نمونه ها، y_i مقدار حقیقی نمونه‌ی i ام، \hat{y}_i مقدار پیش بینی شده‌ی نمونه i ام توسط مدل و \bar{y} میانگین مقادیر واقعی هستند [۱۹].

جدول ۵- نتایج معیارهای ارزیابی عملکرد مدل ترکیبی شبکه کاملاً متصل، حافظه کوتاه‌مدت طولانی و ترنسفورمر در مجموعه‌آزمون.

Table 5. Evaluation metrics results of the hybrid fully connected-LSTM-Transformer model on the test set.

مقدار	معیار ارزیابی
۰/۰۳۳۵	میانگین مجموع مربع خطا
۰/۱۳۸۵	میانگین مجموع قدرمطلق خطا
۰/۹۴۷۰	ضریب تعیین

بر اساس داده‌های آزمون، مقادیر ثبت‌شده در جدول ۵ نشان‌دهنده تطابق قابل قبول بین خروجی مدل پیشنهادی و مقادیر واقعی طول عمر خستگی مواد هستند.

۲-۶- نتایج و بحث

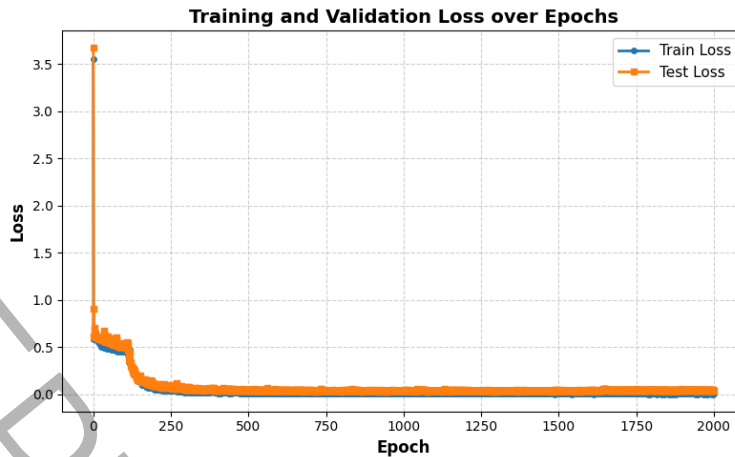
۲-۶-۱- نتایج آموزش و روند همگرایی مدل

فرآیند آموزش مدل ترکیبی پیشنهادی با استفاده از بهینه‌ساز آدام مطابق رابطه (۸) در تعداد ۲۰۰۰ دوره آموزشی^۱ و نرخ یادگیری و سایر دسته^۲ مطابق جدول ۴ است. شکل ۷ روند تغییرات خطای آموزش و آزمون را در طول دوره‌های مختلف نشان می‌دهد.

¹ Mean Squared Error

² Mean Absolute Error

³ Coefficient of Determination



شکل ۷- منحنی تغییرات خطای آموزش و آزمون مدل ترکیبی پیشنهادی در طول دوره آموزشی ۲۰۰۰ دوره آموزشی.

Fig 7. Plot of the training and testing error variations of the proposed hybrid model over 2000 training epochs.

در نمودار فوق، روند کاهش خطای مجموعه تست و آموزش در طول ۲۰۰۰ دور آموزش نمایان است. هر دو منحنی پس از نوسانات اولیه به مقدار پایدار نزدیک و به صفر همگرا شده‌اند که نشان‌دهنده‌ی نبود بیش‌برازش و عملکرد منظم بهینه‌ساز در کاهش خطاهای رگرسیونی است. افت ناگهانی خطا در حوالی تکرار ۳۰۰ مرتبط با تنظیم نرخ یادگیری تطبیقی و بهبود وزن‌دهی در مازول انکودر است. این رفتار پله‌ای تثبیت‌شده نشان می‌دهد مدل توانسته وابستگی‌های زمانی در داده‌های کرنش-تنش را به‌صورت پایدار یاد بگیرد.

¹ Learning Epochs

² Batch Size

۲-۷- مقایسه با مدل‌های دیگر و تحلیل بهبود عملکرد

به منظور ارزیابی اثربخشی مدل پیشنهادی، عملکرد آن با چند مدل مقایسه گردید. تمامی مدل‌ها با داده‌های یکسان و پارامترهای آموزشی مشابه، ۲۰۰۰ دور آموزش دیدند تا مقایسه از نظر شرایط هم‌سطح انجام شود.

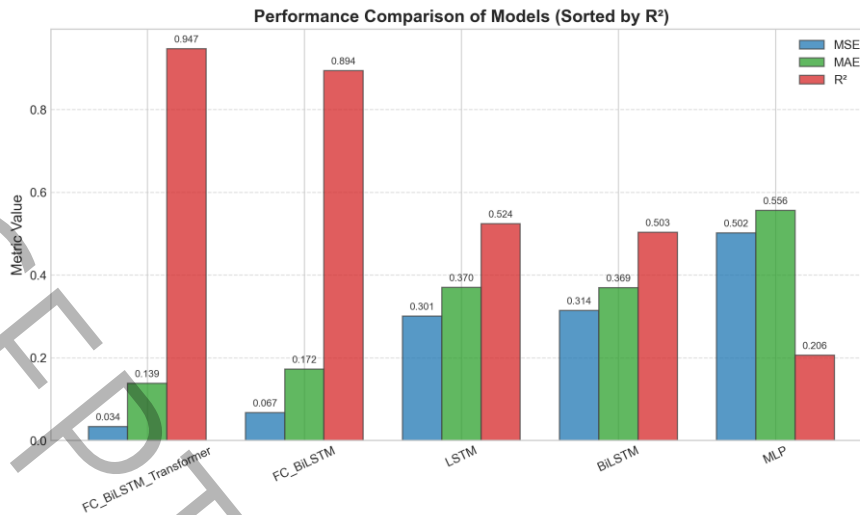
جدول ۶- مقایسه عملکرد مدل‌های یادگیری مختلف شامل شبکه کاملاً متصل، شبکه حافظه‌دار یک‌جهته، شبکه حافظه‌دار دو‌جهته، شبکه کاملاً متصل با شبکه حافظه‌دار دو‌جهته و مدل پیشنهادی شبکه کاملاً متصل، حافظه کوتاه‌مدت طولانی و ترنسفورمر بر اساس سه معیار کمی میانگین مجموع مربع خطا، میانگین مجموع قدرمطلق خطا و ضریب تعیین

Table 6. Comparison of the performance of different learning models—including fully connected networks (FCNs), unidirectional LSTMs, bidirectional LSTMs (BiLSTMs), the hybrid FCN-BiLSTM model, and the proposed FCN-LSTM-Transformer architecture—based on three quantitative metrics: Mean Squared Error (MSE), Mean Absolute Error (MAE), and the Coefficient of Determination

مدل	میانگین مجموع مربع خطا	میانگین مجموع قدرمطلق خطا	ضریب تعیین
شبکه کاملاً متصل	۰/۵۰۱۷	۰/۵۵۶۴	۰/۲۰۶۴
شبکه حافظه دار یک جهته	۰/۳۰۰۷	۰/۳۷۰۳	۰/۵۲۴۳
شبکه حافظه دار دو جهته	۰/۳۱۴۰	۰/۳۶۹۲	۰/۵۰۳۳
شبکه کاملاً متصل + شبکه حافظه دار دو جهته	۰/۰۶۶۷	۰/۱۷۲۳	۰/۸۹۴۰
شبکه کاملاً متصل + شبکه حافظه دار دو جهته + ترنسفورمر	۰/۰۳۳۵	۰/۱۳۸۵	۰/۹۴۷۰

جدول ۶ نتایج کمی آزمون مدل‌ها را بر اساس معیارهای میانگین مجموع مربع خطا MSE ، میانگین مجموع قدرمطلق خطا MAE و ضریب تعیین R^2 نمایش می‌دهد.

نتایج جدول ۶ به روشنی نشان می‌دهد که تلفیق سه سطح پردازش ویژگی‌ها، یعنی استخراج ویژگی‌های ایستا توسط شبکه کاملاً متصل اولیه، مدل‌سازی وابستگی‌های زمانی توسط شبکه حافظه‌دار بلندمدت دو‌جهته و ادغام ویژگی‌ها با ترنسفورمر، سبب افزایش قابل توجه ضریب R^2 و کاهش معنی‌دار خطا شده است. به صورت نمودار میله ای، شکل ۸ نمودار مقایسه مقادیر مورد ارزیابی چهار مدل را نمایش می‌دهد که برتری مدل ترکیبی پیشنهادی نسبت به سایر مدل‌ها در آن مشهود است.



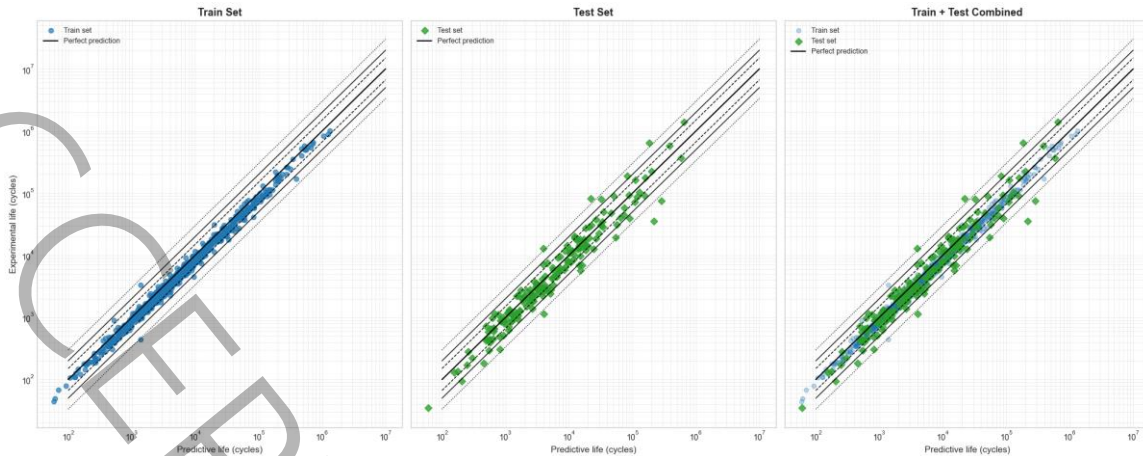
شکل ۸- مقایسه عملکرد مدل‌های یادگیری عمیق در پیش‌بینی عمر خستگی چندمحوره، شامل شبکه کاملاً متصل، شبکه حافظه‌دار تک‌جهته، شبکه حافظه‌دار دوجته، مدل ترکیبی شبکه کاملاً متصل با شبکه حافظه‌دار دوجته و مدل پیشنهادی شبکه کاملاً متصل، حافظه کوتاه‌مدت طولانی و ترنسفورمر؛ ستون‌های نمودار معیارهای میانگین مجموع مربع خطا، میانگین مجموع قدرمطلق خطا و ضریب تعیین هستند.

Fig 8. Performance comparison of deep learning models in predicting multiaxial fatigue life—including the fully connected network, unidirectional LSTM, bidirectional LSTM (BiLSTM), the hybrid FCN-BiLSTM model, and the proposed FCN-BiLSTM-Transformer model; the chart columns represent Mean Squared Error (MSE), Mean Absolute Error (MAE), and the Coefficient of Determination.

۸-۲- بررسی خطای پیش‌بینی و مطابقت داده‌های واقعی با نتایج مدل

به منظور ارزیابی دقت مدل ترکیبی پیشنهادی در تخمین عمر خستگی چندمحوره، توزیع نقاط مربوط به مجموعه داده آزمون در شکل ۹ N_f^{true} ، که مقدار واقعی سیکل است، در برابر N_f^{pred} ، که نتیجه پیش‌بینی مدل است، رسم شده است. در این نمودار، خط ایده‌آل $y = x$ نمایانگر پیش‌بینی کاملاً صحیح بوده و باندهای خطای ۰.۵، ۱، ۲ و ۳ به ترتیب محدوده‌های مقبولیت در ارزیابی‌های انجمن ASTM E739 را مشخص می‌کنند.

همان‌طور که مشاهده می‌شود، اکثر نمونه‌ها درون باند ۲ برابر خطا قرار گرفته‌اند و تراکم نقاط پیرامون خط ایده‌آل بیانگر هم‌ترازی مناسب مقادیر پیش‌بینی‌شده با نتایج آزمایشگاهی است. این هم‌پوشانی به‌ویژه در نواحی کم‌چرخه برجسته‌تر بوده و نشان‌دهنده‌ی توان مدل در استخراج الگوهای دینامیکی بارگذاری است. انحرافات جزئی در عمرهای بالا (بیش از 10^6 سیکل) عمدتاً به اثرات خستگی حرارتی و عدم قطعیت‌های تجربی در داده‌های مرجع بازمی‌گردد.

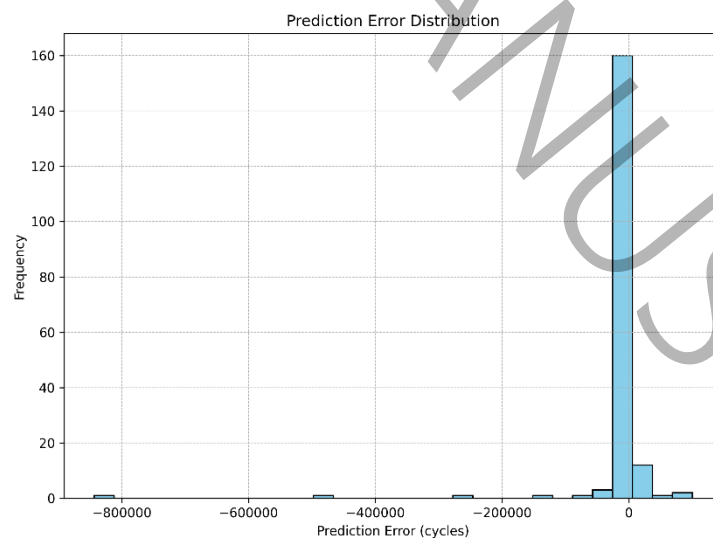


شکل ۹- مقایسه مقادیر عمر خستگی پیش‌بینی‌شده و مقادیر تجربی برای داده‌های آموزش، آزمون و ترکیبی در مدل پیشنهادی شبکه کاملاً متصل، حافظه کوتاه‌مدت طولانی و ترنسفورمر.

Fig 9. Comparison of predicted fatigue life values and experimental values for the training, testing, and combined datasets in the proposed fully connected-LSTM-Transformer model.

۹-۲- تحلیل توزیع خطاهای پیش‌بینی

برای بررسی رفتار آماری مدل پیشنهادی در مجموعه آزمون، توزیع خطای پیش‌بینی به صورت هیستوگرام رسم شده است. همان‌گونه که در شکل ۱۰ مشاهده می‌شود، تمرکز غالب داده‌ها در نزدیکی محور صفر بیانگر همگرایی مناسب و عدم جهت‌گیری نظام‌مند^۱ در خروجی مدل است. در مجموع، تراکم غالب خطاها پیرامون محور صفر نشان‌دهنده‌ی همگرایی مطلوب و انطباق مناسب پیش‌بینی‌های مدل با داده‌های آزمایشگاهی می‌باشد.



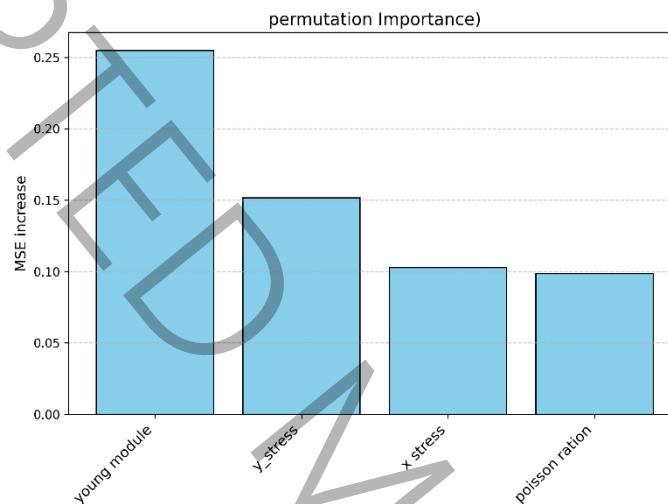
شکل ۱۰ توزیع خطای پیش‌بینی عمر خستگی در داده‌های آزمون مدل پیشنهادی.

Fig 10. Distribution of fatigue life prediction errors for the test dataset of the proposed model.

^۱ Bias

۲-۱۰- تحلیل اهمیت ویژگی‌های ورودی

برای درک سهم هر یک از ویژگی‌های مکانیکی در عملکرد مدل ترکیبی، از روش اهمیت جایگشتی^۱ ویژگی‌ها استفاده شد. در این تحلیل، اثر حذف یا جابه‌جایی تصادفی هر ویژگی بر میزان افزایش میانگین مجموع مربعات خطا اندازه‌گیری می‌شود. نتایج مطابق شکل ۱۱ نشان می‌دهند که مدول یانگ بیشترین اثر را بر دقت مدل دارد و حذف آن موجب افزایش قابل توجه خطا تا حدود ۲۵٪ می‌شود؛ به عبارت دیگر، سختی ماده نقش اصلی را در تعیین طیف عمر خستگی چندمحوره ایفا می‌کند. پس از آن، تنش تسلیم و تنش نهایی نیز تأثیر مهمی دارند، در حالی که سهم نسبت پواسون به نسبت کمتر است اما همچنان در رفتارهای مکانیکی چرخه‌های بلندمدت مؤثر واقع می‌شود. این نتایج با مبانی مواد مکانیکی سازگارند، زیرا مدول یانگ تعیین‌کننده ظرفیت باربری و تمرکز تنش در فرآیند خستگی است.



شکل ۱۱-میزان اهمیت ویژگی‌های مکانیکی ورودی مدل بر پایه روش اهمیت جایگشتی

Fig11.Importance of the model input mechanical features based on the permutation importance method.

۲-۱۱- تفسیر فیزیکی نتایج

مدل ترکیبی پیشنهادی با تلفیق سه مکانیسم استخراج ویژگی توانست به دقت بالایی در تخمین عمر خستگی چندمحوره دست یابد.

در بخش‌های پیشین نشان داده شد که مقدار ضریب تعیین ۰/۹۴۷۰ و میانگین مجموع مربعات خطا ۰/۰۳۳۵ است که بیانگر هم‌خوانی بسیار خوب پیش‌بینی‌ها با داده‌های تجربی هستند. این سطح دقت نه تنها از مدل‌های سنتی شبکه‌ی کاملاً متصل و واحد حافظه دار بلند مدت بهتر است، بلکه موجب کاهش چشمگیر خطا شده است.

در تحلیل کلی، ماژول حافظه‌دار بلندمدت توانست وابستگی‌های بین تنش و کرنش را مدل کند، در حالی که انکودر ترنسفورمر^۲ با سازوکار خودتوجهی^۳ وابستگی‌های بلندمدت را در طول ۵۱۲ گام زمانی استخراج نمود. همچنین لایه‌ی کاملاً متصل ابتدایی نقش کاهش ابعاد و نرمال‌سازی ورودی‌های عددی را بر عهده داشت که موجب پایداری شبکه در فرآیند آموزش شد.

¹ Permutation Importance

² Transformer Encoder

³ Self-Attention

مطابق تحلیل حساسیت ویژگی‌ها شکل ۱۱، بیشترین سهم خطا ناشی از تغییرات مدول یانگ است که بیانگر تأثیر مستقیم سختی ماده بر عمر خستگی چندمحوره است. تنش‌های تسلیم و نهایی نیز به صورت مکمل رفتار ناحیه پلاستیک را کنترل می‌کنند. بنابراین، مدل توانسته وابستگی چندبعدی بین خواص مکانیکی و توالی بارگذاری را با دقت قابل قبول بازنمایی کند. در مجموع، رفتار مدل نشان می‌دهد که ترکیب ساختار پیشنهادی، رویکردی مؤثر برای مسائل مهندسی چندمحوره با داده‌های سری زمانی است، رویکردی که ظرفیت تعمیم‌پذیری آن قابل توسعه به سایر مواد فلزی و کامپوزیتی تحت بارگذاری‌های چرخه‌ای پیچیده می‌باشد.

۱۲-۲- نتیجه‌گیری

در این پژوهش، مدلی ترکیبی مبتنی بر یادگیری عمیق برای پیش‌بینی عمر خستگی چندمحوره مواد پیشنهاد و پیاده‌سازی شد. ساختار مدل از سه مسیر مجزا شامل شبکه کاملاً متصل برای ویژگی‌های عددی، شبکه بازگشتی واحد حافظه کوتاه مدت طولانی دوطرفه برای داده‌های زمانی، و ماژول ترنسفورمر جهت ادغام هوشمند اطلاعات تشکیل شده است. این ترکیب قابلیت تحلیل هم‌زمان ویژگی‌های ایستا و پویا را فراهم می‌سازد و نسبت به رویکردهای کلاسیک وابسته به منحنی‌های S-N دقت بالاتری دارد. نتایج ارزیابی عددی نشان داد که ضریب تعیین 0.9470 و میانگین مربعات خطا در حداقل مقدار ممکن نسبت به مدل‌های پایه ثبت شده است. مدل پیشنهادی توانست وابستگی‌های زمانی بلندمدت را با کمک مکانیزم توجه به شکل مؤثری یاد بگیرد و خطا را کاهش دهد.

از دیدگاه فیزیکی، مدل توانست رفتار پیچیده ماده تحت بارگذاری‌های چندمحوره را با ساختاری داده‌محور بازنمایی کند، بدون نیاز به فرضیات تجربی یا روابط تحلیلی خاص. این ویژگی، آن را برای کاربرد در طراحی قطعات صنعتی پیچیده مانند اجزای هواضا و مکانیک مناسب می‌سازد.

علاوه بر ارزیابی آماری عملکرد مدل، بررسی نتایج از منظر فیزیکی نیز نشان می‌دهد که پیش‌بینی‌های مدل با رفتار شناخته شده خستگی چندمحوره سازگار است. در بسیاری از مسیرهای بارگذاری، افزایش همزمان مؤلفه‌های کرنش محوری و برشی موجب افزایش دامنه تنش معادل و در نتیجه کاهش عمر خستگی می‌شود. نتایج پیش‌بینی مدل نیز همین روند را نشان می‌دهد؛ به طوری که برای مسیرهای بارگذاری با دامنه کرنش بزرگ‌تر، مقدار پیش‌بینی شده عمر خستگی به طور سیستماتیک کاهش یافته است.

همچنین مشاهده می‌شود که تغییر در خواص مکانیکی مواد، نظیر تنش تسلیم و استحکام کششی نهایی، تأثیر قابل توجهی بر مقدار عمر خستگی پیش‌بینی شده دارد. مواد با استحکام بالاتر در شرایط بارگذاری مشابه، عموماً عمر خستگی بیشتری نشان می‌دهند که این رفتار با اصول شناخته شده مکانیک خستگی مطابقت دارد. از آنجا که در مدل پیشنهادی ویژگی‌های مکانیکی ماده به صورت مستقیم در شاخه شبکه کاملاً متصل وارد می‌شوند، مدل قادر است اثر این پارامترها را در کنار الگوهای زمانی بارگذاری در پیش‌بینی عمر خستگی لحاظ نماید.

نتایج نشان می‌دهد که مدل یادگیری عمیق ترکیبی نه تنها قادر به تقریب روابط آماری بین داده‌ها است، بلکه الگوهایی را استخراج می‌کند که با تفسیرهای فیزیکی رفتار خستگی چندمحوره نیز سازگار هستند. این موضوع بیانگر آن است که ترکیب اطلاعات مربوط به مسیرهای بارگذاری و خواص مکانیکی مواد می‌تواند چارچوب مناسبی برای پیش‌بینی رفتار خستگی فراهم آورد.

به طور کلی، پژوهش حاضر ثابت کرد که تلفیق مسیرهای عددی و زمانی با مکانیزم توجه، می‌تواند به توسعه‌ی نسل جدیدی از مدل‌های داده‌محور برای پیش‌بینی عمر خستگی چندمحوره منجر شود. این دستاورد نه تنها موجب افزایش دقت در طراحی خستگی می‌گردد، بلکه نوآوری قابل توجهی در استفاده از شبکه‌های ترکیبی در حوزه مکانیک مواد محسوب می‌شود.

از دیدگاه مهندسی، این مدل قادر است در فرآیند طراحی و ارزیابی دوام سازه‌های فلزی تحت بارگذاری‌های پیچیده، به عنوان ابزاری هوشمند برای پیش‌بینی شکست خستگی مورد استفاده قرار گیرد. علاوه بر آن، قابلیت تعمیم معماری پیشنهادی به سایر مواد (آلیاژی، کامپوزیتی، پلیمرهای مهندسی) قابل انتظار است. در مطالعات آینده می‌توان شبکه را با داده‌های بزرگ‌تر، توزیع تنش گسترده‌تر، و مکانیزم‌های حرارتی خستگی ترکیب کرد تا مدل از نظر دقت و پایداری همگرایی بیش‌تر بهینه شود و قابلیت تعمیم‌پذیری آن افزایش یابد.

با وجود عملکرد مناسب مدل پیشنهادی، برخی محدودیت‌ها نیز وجود دارد که باید مورد توجه قرار گیرند. نخست آنکه مدل ارائه‌شده یک مدل داده‌محور است و عملکرد آن به کیفیت و تنوع داده‌های آموزشی وابسته است. در صورتی که داده‌های آموزشی همه حالات ممکن بارگذاری یا انواع مواد را پوشش ندهند، دقت پیش‌بینی مدل برای شرایط خارج از محدوده داده‌های آموزش ممکن است کاهش یابد زیرا دقت مدل وابسته به تنوع و دامنه داده‌ها می‌باشد.

علاوه بر این، اگرچه مدل یادگیری عمیق قادر به استخراج الگوهای پیچیده از داده‌ها است، اما تفسیر مستقیم پارامترهای داخلی آن نسبت به مدل‌های مکانیکی کلاسیک دشوارتر است. بنابراین استفاده از چنین مدل‌هایی بهتر است در کنار دانش فیزیکی انجام شود.

در تحقیقات آینده می‌توان با گسترش مجموعه داده‌ها، استفاده از روش‌های ترکیبی فیزیک-محور و داده‌محور، و بررسی عملکرد مدل برای مواد و مسیرهای بارگذاری جدید، قابلیت تعمیم و تفسیرپذیری این چارچوب را بیشتر بهبود داد. همچنین با تولید داده‌های آزمایشگاهی مناسب می‌توان مقایسه با معیارهای کلاسیک نیز انجام شود.

۱۳-۲- دسترسی به کدها

کدهای مربوط به پیاده‌سازی مدل یادگیری عمیق ارائه‌شده در این پژوهش در حال حاضر به صورت عمومی منتشر نشده‌اند. پژوهشگران علاقه‌مند می‌توانند در صورت نیاز برای دسترسی به کدها با نویسنده مکاتبه نمایند. در صورت ارسال درخواست از طریق پست الکترونیکی، دسترسی به کدها برای اهداف پژوهشی و علمی در اختیار متقاضیان قرار خواهد گرفت.

¹ b_anbarloei@sbu.ac.ir

۹-۲- فهرست علائم

علائم انگلیسی

الگوریتم بهینه‌ساز Adam	<i>Adam</i>
نرخ حذف تصادفی نورون‌ها جهت جلوگیری از بیش‌برازش	<i>Dropout</i>
مدول یانگ یا الاستیسیته N/m^2	<i>E</i>
تعداد دوره‌های آموزش مدل	<i>Epoch</i>
شبکه کاملاً متصل (Fully-Connected)	<i>FC</i>
برداری حالت نهان (Hidden State Vector)	<i>h</i>
واحد حافظه کوتاه‌مدت طولانی	<i>LSTM</i>
میانگین قدرمطلق خطا	<i>MAE</i>
میانگین مربع خطا	<i>MSE</i>
شبکه چندلایه پرسپترون	<i>MLP</i>
تعداد نمونه‌ها در مجموعه داده	<i>n</i>
تعداد سرهای توجه در ماژول ترنسفورمر	<i>nhead</i>
رمزگذاری مکانی	<i>PE</i>
ضریب تعیین	R^2
تابع فعال‌سازی خطی اصلاح‌شده	<i>ReLU</i>
وزن‌ها و بایاس لایه خروجی مدل	W_o, b_o
برداری ویژگی ترکیب‌شده پس از ترنسفورمر	z, z_{att}

علائم یونانی

کرنش در راستای X در لحظه t	$\epsilon_x(t)$
کرنش برشی بین محورهای X و Y در لحظه t	$\gamma_{xy}(t)$
نرخ یادگیری	η
نسبت پواسون	ν
تنش‌های اصلی در راستاهای X و Y ، و تنش نهایی شکست	$\sigma_x, \sigma_y, \sigma_u$
زیرنویس	
حاصل فرآیند توجه ترنسفورمر	<i>att</i>

ACCEPTED MANUSCRIPT

- [1] J.A. Bannantine, J.J. Comer, J.L. Handrock, *Fundamentals of Metal Fatigue Analysis*, Prentice Hall, 1990.
- [2] S. Suresh, *Fatigue of materials*, Cambridge university press, 1998.
- [3] Luke Pollock, Ayah Khalid Abdelwahab, John Murray, and Graham Wild. “The Need for Aerospace Structural Health Monitoring: A Review of Aircraft Fatigue Accidents”. *International Journal of Prognostics and Health Management*, ISSN 2153-2648, 2021
- [4] S. Tavares, P. De Castro, An overview of fatigue in aircraft structures, *Fatigue & Fracture of Engineering Materials & Structures*, 40(10) (2017) 1510–1529.
- [5] S.R. Hursh, D.P. Redmond, M.L. Johnson, D.R. Thorne, G. Belenky, T.J. Balkin, W.F. Storm, J.C. Miller, D.R. Eddy, Fatigue models for applied research in warfighting, Aviation, space, and environmental medicine, 75(3) (2004) A44–A53.
- [6] T. Harris, W.K. Yu, Lundberg-Palmgren fatigue theory: considerations of failure stress and stressed volume, *Journal of Tribology*, 121(1) (1999) 85–89.
- [7] J. Yang, G. Kang, Y. Liu, Q. Kan, A novel method of multiaxial fatigue life prediction based on deep learning, *International Journal of Fatigue*, 151 (2021) 106356.
- [8] Y. Mizuno, A. Hosoi, H. Koshita, D. Tsunoda, H. Kawada, Fatigue life prediction of composite materials using strain distribution images and a deep convolution neural network, *Scientific reports*, 14(1) (2024) 25418.
- [9] C.M. Bishop, H. Bishop, *Deep Learning: Foundations and Concepts*, Springer International Publishing, 2023.
- [10] A. Graves, Long short-term memory, *Supervised sequence labelling with recurrent neural networks* (2012). Springer, ISBN: 978-3-642-24796-5.
- [11] F. Chollet, F. Chollet, *Deep Learning with Python*, Second Edition, Manning, 2021.
- [12] S. Chen, Y. Bai, X. Zhou, A. Yang, A deep learning dataset for metal multiaxial fatigue life prediction, *Scientific Data*, 11(1) (2024) 1027.
- [13] K.P. Murphy, *Machine Learning: A Probabilistic Perspective*, MIT Press, 2012.
- [14] Z. Huang, W. Xu, K. Yu, Bidirectional LSTM-CRF models for sequence tagging, *arXiv preprint arXiv:1508.01991*, (2015).
- [15] D. GODOY, *DEEP LEARNING WITH PYTORCH STEP-BY-STEP: A Beginner's Guide*, INDEPENDENTLY PUBLISHED, 2022.
- [16] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A.N. Gomez, Ł. Kaiser, I. Polosukhin, Attention is all you need, *Advances in neural information processing systems*, 30 (2017).
- [17] A. Kazemnejad, I. Padhi, K. Natesan Ramamurthy, P. Das, S. Reddy, The impact of positional encoding on length generalization in transformers, *Advances in Neural Information Processing Systems*, 36 (2023) 24892–24928.
- [18] K.D.B.J. Adam, A method for stochastic optimization, *arXiv preprint arXiv:1412.6980*, 1412(6) (2014).
- [19] G. James, D. Witten, T. Hastie, R. Tibshirani, *An Introduction to Statistical Learning: with Applications in R*, Springer New York, 2013.