

ارزیابی استحکام نهایی ورق‌های تقویت شده ترک‌دار با استفاده از روش بهینه شده XGBoost

محمد رضا زارعی^{۱*}، مهدی ایرانمنش^۲

^۱ استادیار، دانشکده مهندسی دریا، دانشگاه دریانوردی و علوم دریایی چابهار، mrzareei@cmu.ac.ir

^۲ دانشیار، دانشکده مهندسی دریا، دانشگاه صنعتی امیرکبیر imehdi@aut.ac.ir

چکیده

ارزیابی استحکام نهایی ورق‌های تقویت شده تشکیل‌دهنده سازه کشتی، اولین مرحله در ارزیابی استحکام نهایی آن است. باگذشت زمان و افزایش عمر سازه، خرابی‌هایی نظیر ایجاد ترک سبب کاهش ظرفیت باربری سازه کشتی می‌شوند. هدف اصلی این مقاله ارائه روشی مبتنی بر یادگیری ماشین با استفاده از الگوریتم XGBoost برای محاسبه استحکام نهایی فشاری ورق‌های تقویت‌شده با خرابی ترک با استفاده از نتایج تحلیل‌های متعدد المان محدود است. برای دستیابی به بهترین نتایج ممکن از الگوریتم XGBoost، بخشی هائپرپارامترهای موجود در این الگوریتم با استفاده از روش بهینه‌سازی بیزین، بهینه شده است. نتایج حاصل از این روش نشان می‌دهد که دقت استفاده از الگوریتم بهینه شده XGBoost بسیار بالاتر از روش‌های متداول بر مبنای رگرسیون خطی است.

اطلاعات مقاله

ناریخچه مقاله:

تاریخ دریافت مقاله: ۱۴۰۱/۰۲/۳۰

تاریخ پذیرش مقاله: ۱۴۰۱/۰۷/۰۲

کلمات کلیدی:

استحکام نهایی

ورق تقویت شده

ترک

یادگیری ماشین

XGBoost

بهینه‌سازی بیزین

Ultimate strength assessment of cracked stiffened plates using optimized XGBoost method

Mohammad Reza Zareei^{1*}, Mehdi Iranmanesh²

¹ Assistant Professor, Marine engineering faculty, Chabahar Maritime University (CMU), mrzareei@cmu.ac.ir

² Associate Professor, Marine engineering faculty, AmirKabir university of technology

ARTICLE INFO

Article History:

Received: 02 May 2022

Accepted: 24 Sep 2022

Keywords:

Ultimate strength

Stiffened plates

Crack

Machine learning

XGBoost

Bayesian optimization

ABSTRACT

Assessing the ultimate strength of the stiffened plates forming the ship structure is the first step in assessing its ultimate strength. Over time and increase the life of the structure, failures such as cracks reduce the load-bearing capacity of the structure. The main purpose of this paper is to present a machine learning method based on XGBoost algorithm to calculate the ultimate compressive strength of stiffened plates with crack failure using the results of multiple finite element analyzes. To achieve the best possible results from the XGBoost algorithm, some of the hyperparameters in this algorithm have been optimized using the Bayesian optimization method. The results of this method show that the accuracy of using the optimized XGBoost algorithm is much higher than conventional methods based on linear regression.

۱ - مقدمه

یکی از نکات مهم در طراحی سازه‌های کشتی، بررسی رفتار تیر بدنه کشتی تحت تأثیر خمش طولی و همچنین محاسبه دقیق ظرفیت باربری آن است. تیر بدنه کشتی در بخش‌های مختلف آن از ورق‌های تقویت‌شده و تقویت نشده تشکیل شده است. ظرفیت نهایی باربری سازه کشتی تحت خمش یا همان استحکام نهایی کشتی، کاملاً متأثر از استحکام نهایی اجزای تشکیل‌دهنده آن در شرایط کشش و فشار است. از دیدگاه طراحی بر اساس حالت حدی نهایی، محاسبه استحکام نهایی اجزای تشکیل‌دهنده بدنه کشتی، اولین قدم برای دستیابی به یک طراحی مناسب از سازه کشتی است.

ترک‌ها یکی از ضعف‌های طبیعی در اجزای سازه‌ای هستند. در زمان ساخت سازه و یا در زمان کاربری سازه ممکن است ترک‌های مختلفی ایجاد شده و در طول عمر سازه گسترش یابند. ترک‌ها می‌توانند بر روی ظرفیت باربری یک سازه تأثیرگذار باشند، لذا باید تأثیر ترک بر روی استحکام نهایی اجزای تشکیل‌دهنده تیر بدنه کشتی مورد بررسی قرار گیرد. با توجه به تغییر طول ترک‌ها در سازه کشتی، لازم است تا روابطی برای محاسبه استحکام نهایی اجزای تشکیل‌دهنده سازه با لحاظ ترک ارائه گردد.

تاکنون تحقیقات متعددی بر روی استحکام نهایی ورق‌های تقویت‌شده و تقویت نشده با خرابی ترک ارائه شده است. هدف عمده این تحقیقات بررسی رفتار ورق‌های تقویت‌شده ترک‌دار تحت نیروهای فشاری و محاسبه استحکام فشاری آن‌ها است. پایک و تایامبلی در سال ۲۰۰۲ [1] استحکام نهایی کشتی‌های سالخورده را مورد بررسی قرار دادند. در این تحقیق تأثیر خوردگی و ترک روی استحکام نهایی کشتی بررسی شده است. در بخشی از این تحقیق نتایج آزمایشی روی استحکام کششی ورق‌های ترک‌دار با ترک مرکزی و ترک گوشه گزارش شده است. در انتها روابط ساده‌ای برای محاسبه استحکام نهایی ورق تقویت شده متناسب با نسبت سطح مقطع باقیمانده به سطح مقطع اولیه ارائه دادند پایک و کومار در سال ۲۰۰۶ [2] از همین رابطه برای محاسبه استحکام نهایی ورق‌های تقویت‌شده تحت کشش استفاده کردند. در واقع در این مقاله نتایج ارائه شده برای محاسبه استحکام نهایی کششی از مقاله قبل تکرار شده است. در سال ۲۰۰۴ هو و همکارانش [3] تأثیر خوردگی و ترک را روی قابلیت اطمینان استحکام نهایی بدنه کشتی بررسی نمودند. برای انجام این کار ابتدا روابطی را برای محاسبه استحکام نهایی ورق‌های تقویت‌شده تحت کشش و فشار ارائه شده بود. برای این کار آن‌ها یکسری تحلیل‌های المان محدود را بر روی ورق‌های ترک‌دار انجام دادند. در انتها روابطی را برای ورق‌های ترک‌دار به صورت تابعی از نسبت طول ترک به عرض ورق با استفاده از روش رگرسیون خطی ارائه نمودند. بای در سال ۲۰۰۶

[4] در رساله دکتری خود بر اساس روندی مشابه با هو و همکارانش، ورق تقویت‌شده را به صورت تلفیقی از ورق و تقویت‌کننده در نظر گرفت و با انجام تحلیل‌های المان محدود، روابطی را برای محاسبه استحکام نهایی ورق‌های ترک‌دار با ترک مرکزی و گوشه ارائه داد. در سال‌های اخیر تحقیقات متعددی بر روی ورق‌های تقویت‌شده بدون ترک انجام شده و روابط مختلفی نیز در این زمینه ارائه شده است. با وجود این همان‌طور که ارائه شد، روابط موجود برای ورق تقویت‌شده ترک‌دار بسیار محدود است. در همه روابط ارائه شده ساده‌سازی‌های گسترده‌ای در نظر گرفته شده است. به عنوان مثال در دو رابطه اخیر که توسط هو و همکاران [3] و بای [4] ارائه شده ورق تقویت‌شده به صورت دو جزء مجزا در نظر گرفته شده و از تقابل بین آن‌ها در کشش و فشار صرف نظر شده است. با توجه به این موارد ارائه یک رابطه جدید برای محاسبه استحکام نهایی ورق‌های تقویت‌شده ترک‌دار الزامی به نظر می‌رسد. در سال ۲۰۱۸ زارعی و ایرانمنش [5]، نویسندگان مقاله، در تحقیقی با انجام تحلیل‌های متعدد المان محدود روابطی را برای محاسبه استحکام نهایی ورق‌های تقویت شده سالم و ترک‌دار تحت بارگذاری محوری کششی و فشاری ارائه دادند. در این مقاله از روش رگرسیون خطی برای ارائه رابطه استفاده شده است.

در دهه‌های اخیر استفاده از روش‌های نوین محاسباتی رواج روز افزونی داشته است. یادگیری ماشین^۱ و یادگیری عمیق^۲ دسته‌ای از این روش‌های نوین هستند. از جمله تحقیقات انجام شده در این حوزه می‌توان مقالات [10]–[6] در ارزیابی استحکام کمانشی و نهایی را نام برد. هدف از این مقاله ارائه روشی مبتنی بر یادگیری ماشین با استفاده از الگوریتم XGBoost برای محاسبه استحکام نهایی فشاری ورق‌های تقویت‌شده با خرابی ترک است. برای این منظور از داده‌های بررسی استحکام نهایی ورق تقویت شده حاوی ترک که پیشتر در مرجع [5] ارائه شده است، استفاده می‌شود. در بخش دوم، مجموعه داده‌های ورق تقویت شده حاوی ترک بررسی می‌شود. در بخش سوم، مراحل روش یادگیری ماشین و معیارهای ارزیابی کیفیت خروجی بیان می‌شود. برای دستیابی به نتایج بهینه از برازش بوسیله یادگیری ماشین، از الگوریتم بهینه‌سازی بیزین استفاده شده که در این بخش بطور مختصر بیان خواهد شد. در بخش چهارم، روش کارکرد الگوریتم XGBoost به صورت مختصر بررسی می‌شود. در بخش نتایج نیز ارزیابی استحکام نهایی با استفاده از الگوریتم XGBoost بهینه ارائه می‌شود. در بخش انتهایی نیز نتیجه گیری مقاله ارائه خواهد شد.

۲ - توصیف مجموعه داده‌های ورق‌های تقویت شده ترک‌دار

¹ Machine Learning² Deep Learning

³ ULtimate Strength

شکل ۲- ضریب همبستگی پارامترهای ورق تقویت شده ترک‌دار

مرحله ۲، تقسیم‌بندی داده‌ها و مقیاس: در این مرحله باید مجموعه داده‌ها به دودسته آموزش^۴ و تست تقسیم‌بندی شوند. داده‌های ورودی و خروجی هر مسئله دارای واحد و محدوده تغییرات متفاوتی هستند. برای دستیابی به نتایج مناسب در الگوریتم‌های یادگیری ماشین، باید مجموعه داده‌ها به یک محدوده مشخص مقیاس شوند. در اینجا مجموعه داده‌ها به محدوده صفر تا یک، [۰-۱]، مقیاس شده‌اند.

مرحله ۳، آموزش داده‌ها: در این مرحله باید مجموعه داده‌های آموزش با استفاده از الگوریتم مدنظر آموزش داده‌شده تا مدلی برای برازش و دستیابی به مقادیر استحکام نهایی فراهم گردد. در اینجا از الگوریتم XGBoost استفاده خواهد شد.

مرحله ۴، ارزیابی عملکرد مدل: در مرحله آخر با استفاده از مجموعه داده‌های تست، عملکرد مدل ارائه شده ارزیابی می‌شود. برای ارزیابی عملکرد مدل‌های مختلف یادگیری ماشین معیارهای مختلفی ارائه شده است که مهم‌ترین آنها شامل خطای جذر میانگین مربعات^۵، خطای میانگین مربعات^۶، میانگین قدرمطلق خطا^۷ و ضریب همبستگی خطی^۸ هستند [11]. در اینجا برای بررسی عملکرد مدل از دو معیار MSE و مجذور R (R²) استفاده شده که به صورت زیر می باشند:


$$MSE = \frac{1}{n} \sum_{i=1}^n (y_e - y_p)^2 \quad (1)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_e - y_p)^2}{\sum_{i=1}^n (y_e - \bar{y})^2} \quad (2)$$


در این روابط y_e برای نشان دادن مقدار استحکام نهایی به دست آمده از روش المان محدود و y_p برای نشان دادن مقدار استحکام نهایی به دست آمده از مدل یادگیری ماشین و n برای نشان دادن تعداد نمونه است. $\bar{y}$ نیز مقدار متوسط y_e است. یک مدل مناسب باید مقدار MSE پایین و مقدار R² نزدیک به یک داشته باشد.

۴ - الگوریتم XGBoost^۹

در طی سالان اخیر مدل‌های متنوعی از یادگیری ماشین ارائه شده است. الگوریتم XGBoost در سال ۲۰۱۶ توسط چن و گاسترین [12] پیشنهاد شده است. این روش یک الگوریتم تقویت گرادیان بر مبنای روش درخت تصمیم است که در بسیاری از



شکل ۳ مقایسه نتایج استحکام نهایی بدون بعد بین خروجی تحلیل المان محدود و رابطه تجربی



شکل ۴ توزیع درصد اختلاف نتایج المان محدود و رابطه تجربی

۳ - مراحل یادگیری ماشین و روش ارزیابی کیفیت

یادگیری ماشین یکی از شاخه‌های علم برنامه‌نویسی کامپیوتر است. بر اساس وجود داده‌های برچسب‌دار، یادگیری ماشین را می‌توان به سه دسته نظارت شده، بدون نظارت و تقویتی تقسیم‌بندی کرد. در یادگیری ماشین نظارت شده، هدف دسته‌بندی یا برازش بر اساس داده‌های ارائه شده به مدل است. مراحل انجام برازش به کمک الگوریتم‌های یادگیری ماشین در این مقاله به صورت زیر است که در شکل ۵ نیز نشان داده شده است.

مرحله ۱، جمع‌آوری داده‌ها: در این مرحله باید مجموعه داده‌های لازم برای انجام برازش یا دسته‌بندی به کمک الگوریتم‌های یادگیری ماشین آماده شود. برای مقاله حاضر، این مرحله در بخش قبل توضیح داده شده است. در این مرحله باید مجموعه داده‌های ورودی و خروجی تفکیک شوند. در مطالعه حاضر مقادیر استحکام نهایی داده‌های خروجی مدل بوده و ابعاد ورق تقویت شده و ترک داده‌های ورودی مدل هستند.

⁴ Training

⁵ Root Mean Square Error: RMSE


⁶ Mean Square Error: MSE

⁷ Mean Absolute Error: MAE

⁸ Linear Correlation Coefficient: R

⁹ eXtreme Gradient BOOSTing

زمینه های مهندسی بکار گرفته شده و بدلیل منظم سازی و پردازش موازی عملکرد بسیار خوبی داشته است.



شکل ۵- مراحل یادگیری ماشین

فرض می‌کنیم که مجموعه داده‌ای به صورت $D = \{(x_i, y_i) : i = 1, \dots, n\}$ داریم که دارای n نمونه و m ویژگی $(x_i \in R^m, y_i \in R)$ است. مدل درختی پیشنهاد شده در این روش Z تابع اضافی را برای تقریب خروجی مدل به صورت زیر بکار می‌برد [13].

$$y_p = \phi(x_i) = \sum_{z=1}^Z f_z(x_i), \quad f_z \in F \quad (3)$$

در این رابطه F فضای مسئله شامل درخت‌های تصمیم برازش است که به صورت رابطه زیر تعریف می‌شود [13]:

$$F = \{f(x) = w_{q(x)}\} \quad (q: R^m \longrightarrow T, w \in R^T) \quad (4)$$

در رابطه فوق q نشان‌دهنده ساختمان درخت تصمیم، w وزن هر برگ در درخت تصمیم و T نشان‌دهنده تعداد برگ‌ها در درخت تصمیم است. در این رابطه f تابعی است که به مقادیر q وابسته است و وزن‌های w به هر کدام از درخت‌های تصمیم وابسته هستند. برای بهینه‌سازی مجموعه درخت‌ها تصمیم و کاهش خطا، وظیفه الگوریتم XGBoost کمینه کردن تابع هدف به صورت زیر است [13]:

$$L(t) = \sum_{i=1}^n l(y_e, y_p^{(t-1)} + f_t(x_i)) + (f_t) \quad (5)$$

در رابطه فوق l تابع زیان برای محاسبه اختلاف بین y_e و y_p و t شماره تکرار برای کمینه کردن خطا است. در رابطه فوق (f_t) نیز تابع پنالتی برای کاهش پیچیدگی برازش مدل است. در مقاله حاضر برای اجرای الگوریتم XGBoost از کتابخانه رایگان

XGBoost [14] که برای زبانهای برنامه نویسی مختلف نوشته شده، استفاده شده است.

در الگوریتم‌های یادگیری ماشین دودسته متغیر وجود دارد که معمولاً به نام‌های پارامترها و هایپرپارامترها شناخته می‌شوند. پارامترها متغیرهایی هستند که در طول اجرای الگوریتم و با استفاده از مجموعه داده‌های آموزش در طول کمینه‌سازی تابع هدف به دست می‌آیند. از جمله این متغیرها می‌توان متغیر w در رابطه ۴ را نام برد. هایپرپارامترها متغیرهایی هستند که باید پیش از اجرای الگوریتم توسط کاربر تعیین شوند. با تغییر هایپرپارامترها توسط کاربر می‌توان عملکرد مدل یادگیری ماشین را ارتقا داد. برای تعیین هایپرپارامترها روش‌های مختلفی ارائه شده است که از جمله آنها می‌توان جستجوی شبکه‌ای^{۱۰}، جستجوی تصادفی^{۱۱} و استفاده از روش‌های بهینه‌سازی را نام برد. بهینه‌سازی بیزین یکی از روش‌های بهینه‌سازی است که در تحقیقات مختلفی نظیر [15]–[17] برای تنظیم هایپرپارامترهای الگوریتم‌های یادگیری ماشین بکار رفته است. در مقاله حاضر برای اجرای بهینه‌سازی بیزین از کتابخانه رایگان Bayes_opt [18] که برای زبان برنامه نویسی پایتون نوشته شده، استفاده شده است.

۵- ارزیابی استحکام نهایی

در این بخش نتایج ارزیابی استحکام نهایی ورق تقویت شده حاوی ترک با استفاده از الگوریتم XGBoost بهینه شده آورده خواهد شد. یکی از مشکلات روش‌های یادگیری ماشین امکان بیش برازش^{۱۲} الگوریتم است. در این حالت باید همان‌طور که در شکل ۵ نشان داده شده است، مجموعه داده‌ها به طور تصادفی به دودسته آموزش و تست تقسیم‌بندی شوند. در اینجا ۸۰ درصد از داده‌ها برای آموزش و ۲۰ درصد برای تست در نظر گرفته شده است. پیش از انجام بهینه‌سازی باید هایپرپارامترهای مهم الگوریتم شناسایی شده و محدوده تغییرات آنها برای انجام بهینه‌سازی مشخص شود. الگوریتم XGBoost در کل ۳۵ هایپرپارامتر دارد [14]. سه دسته از مهمترین هایپرپارامترهای این الگوریتم انتخاب شده و در جدول ۱ مقادیر پیش‌فرض آن آورده شده است. این سه هایپرپارامتر عبارت از تعداد درخت‌های تصمیم^{۱۳}، حداکثر عمق درخت‌های تصمیم^{۱۴} و نرخ یادگیری^{۱۵} هستند. معمولاً در طول بهینه‌سازی هایپرپارامترها از روش اعتبارسنجی متقابل^{۱۶} برای

¹⁰ Grid search

¹¹ Random Search

¹² Overfitting

¹³ N_estimators

¹⁴ Max_Depth

¹⁵ Learning_rate


¹⁶ Cross validation

جدول ۲ مقایسه کرد. داده های ارائه شده در جدول ۲ به کمک شکل های ۷ و ۸ به خوبی عملکرد مطلوب روش XGBoost با مقادیر بهینه شده هایپرپارامتر را نشان میدهند.


جدول ۱ - هایپرپارامترهای در نظر گرفته شده برای الگوریتم

XGBoost، مقادیر پیش فرض و فضای بهینه سازی


Hyperparameter	Default value	Search space
N_estimator	100	100-3000
Max_Depth	none	2-7
learning_rate	0.1	0.005-0.5



شکل ۶ - بهینه سازی با روش اعتبارسنجی متقابل با ۵ دسته [19]



شکل ۷ - محدوده تغییرات مقادیر R^2 با استفاده از الگوریتم XGBoost با اعتبارسنجی متقابل با ۱۰ دسته



شکل ۸ - محدوده تغییرات مقادیر MSE با استفاده از الگوریتم XGBoost با اعتبارسنجی متقابل با ۱۰ دسته

مقایسه نتایج استحکام نهایی بدون بعد بین خروجی تحلیل المان محدود و XGBoost بهینه شده در شکل ۹ نشان داده شده است.

افزایش دقت استفاده می شود. در این روش که در شکل ۶ برای حالت ۵ دسته نشان داده شده، مجموعه داده های لازم برای بهینه سازی به k دسته تقسیم بندی شده و k بار الگوریتم اجرا می شود. در هر بار اجرای الگوریتم یک دسته از k دسته انتخاب شده به عنوان داده تست و سایر دسته ها به عنوان داده آموزش فرض می شوند. در هر بار تکرار بهینه سازی، ابتدا با $k-1$ دسته الگوریتم آموزش داده شده و سپس با استفاده از یک دسته باقیمانده معیار عملکرد الگوریتم (مثلاً MSE) محاسبه می شود. در نهایت معیار عملکرد خروجی الگوریتم در هر بار تکرار بهینه سازی، مقدار متوسط k بار تکرار الگوریتم است. این کار برای کم کردن تاثیر انتخاب داده ها در تکرارهای بهینه سازی است. در این مقاله مقدار k برابر با ۵ در نظر گرفته شده است. روش اعتبارسنجی متقابل فارغ از بحث بهینه سازی، برای هر بار استفاده از الگوریتم یادگیری ماشین جهت بررسی دقت تحلیل نیز قابل انجام است.


با بررسی شکل های ۳ و ۴ می توان دید که با استفاده از روش رگرسیون خطی در مرجع [5]، مقادیر معیارهای R^2 و MSE بترتیب برابر با ۰/۸۵۹۷ و ۰/۰۰۱۶۵ بوده، بطوریکه حداکثر اختلاف مقادیر استحکام نهایی بدست آمده از رابطه ارائه شده در مرجع [5] با مقادیر المان محدود برابر با ۱۷/۰۲ درصد است. در ادامه در دو مرحله ارزیابی استحکام نهایی ورق تقویت شده ترکدار با استفاده از الگوریتم XGBoost بر اساس نتایج ۱۰۰۸ تحلیل المان محدود انجام شده است. در مرحله اول بر اساس مقادیر پیش فرض هایپرپارامترهای الگوریتم XGBoost مقادیر استحکام نهایی محاسبه شده و ارزیابی انجام شده است. در مرحله دوم نیز ابتدا مقادیر هایپرپارامترهای در نظر گرفته شده در محدوده تغییرات آنها در جدول ۱، بهینه شده و پس از آن مقادیر استحکام نهایی محاسبه شده است. مقادیر بهینه شده سه هایپرپارامتر تعداد درخت های تصمیم، حداکثر عمق و نرخ یادگیری بترتیب برابر با ۲۷۰۵، ۳ و ۰/۱۵۸۷۵ بدست آمده است.

برای بررسی تأثیر بهینه سازی پارامترها، دو حالت الگوریتم XGBoost با هایپرپارامترهای پیش فرض و بهینه شده در شکل های ۷ و ۸ بر اساس معیارهای خروجی روش اعتبارسنجی متقابل مقایسه شده است. مقادیر معیارهای R^2 و MSE نیز در سه مدل ارائه شده در این مقاله در جدول ۲ آورده شده است. مقادیر معیارهای ارزیابی عملکرد ارائه شده در این جدول مربوط به داده های تست هستند. در جدول ۲ دیده می شود که مقادیر R^2 از مقدار ۰/۸۵۹۷ مربوط به روش رگرسیون خطی در مرجع [5] به مقادیر ۰/۹۸۸۰ و ۰/۹۹۵۰ برای الگوریتم XGBoost با هایپرپارامترهای پیش فرض و بهینه شده افزایش یافته است. مقادیر معیار MSE را نیز میتوان برای سه مدل ارائه شده در


هر دودسته نتایج کاملاً نزدیک به خط نیمساز بوده که نشان‌دهنده دقت بالای این روش در تقریب مقادیر استحکام نهایی است. توزیع درصد اختلاف نتایج المان محدود و XGBoost بهینه شده در شکل ۱۰ آورده شده است. با مقایسه شکل‌های ۳ و ۴ با شکل‌های ۹ و ۱۰ می‌توان به‌خوبی کیفیت نتایج عددی به‌دست‌آمده از الگوریتم XGBoost بهینه شده را مشاهده کرد.

جدول ۲- مقایسه معیارهای عملکرد مدل‌های ارائه شده

معیار عملکرد			
مدل	هایپرپارامتر	R ²	MSE
رگرسیون خطی	-	۰/۸۵۹۷	۰/۰۰۱۶۵
XGBoost-Free	پیش فرض	۰/۹۸۸۰	۰/۰۰۰۳۶
XGBoost-Opt	بهینه شده	۰/۹۹۶۹	۰/۰۰۰۱۵



شکل ۹- مقایسه نتایج استحکام نهایی بدون بعد بین خروجی تحلیل المان محدود و XGBoost بهینه شده



شکل ۱۰- توزیع درصد اختلاف نتایج المان محدود و XGBoost بهینه شده

۶- نتیجه‌گیری

خوردگی و ترک دو عامل مهم در کاهش استحکام سازه‌های فلزی نظیر ورق تقویت شده هستند. در طول سالیان اخیر روابط متعددی برای ارزیابی استحکام نهایی ورق‌های تقویت شده ارائه شده است. در عمده تحقیقات انجام شده رابطه تجربی بر مبنای رگرسیون خطی ارائه شده است. یادگیری ماشین دسته‌ای از روش‌های نوین محاسباتی است که به طور وسیع در زمینه‌های مختلف مهندسی مورد استفاده قرار گرفته است. در این مقاله محاسبه استحکام نهایی با استفاده از یکی از مدل‌های یادگیری ماشین، الگوریتم XGBoost، انجام شده است. برای دستیابی به بهترین نتایج، سه دسته از هایپرپارامترهای موجود در این الگوریتم به‌وسیله روش بهینه‌سازی بیزین بهینه شده است. برای ساخت مدل ریاضی از نتایج تحلیل‌های متعدد المان محدود ورق تقویت شده ترک‌دار استفاده شده است. عملکرد روش ارائه شده با استفاده از معیارهای MSE و R² بررسی شده و با نتایج حاصل از روش رگرسیون خطی مقایسه شده است. مقدار MSE و R² روش رگرسیون خطی برابر با ۰/۰۰۱۶۵ و ۰/۸۵۹۷ بوده است که با استفاده از روش XGBoost بدون بهینه‌سازی هایپرپارامترها به ترتیب به مقادیر ۰/۰۰۰۳۶ و ۰/۹۸۸۰ بهبود یافته است. با بهینه‌سازی هایپرپارامتر موجود در الگوریتم XGBoost نیز این مقادیر به ترتیب به ۰/۰۰۰۱۵ و ۰/۹۹۵۰ بهبود یافته‌اند. دو مقدار اخیر به‌خوبی کیفیت بالای استفاده از الگوریتم XGBoost در محاسبه استحکام نهایی ورق تقویت شده را نشان می‌دهند. از نتایج این روش می‌توان با دقت بیشتری در ارزیابی استحکام نهایی ورق‌های تقویت شده در شرایط ترک برای محاسبه قابلیت اطمینان و ریسک استفاده کرد.

۶- مراجع

- [1] J. K. Paik and A. K. Thayamballi, "Ultimate strength of ageing ships," *Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment*, vol. 216, no. 1, pp. 57–77, Jun. 2002, doi: 10.1243/147509002320382149.
- [2] J. K. Paik and Y. V. Satish Kumar, "Ultimate Strength of Stiffened Panels With Cracking Damage Under Axial Compression or Tension," *Journal of Ship Research*, vol. 50, no. 03, pp. 231–238, Sep. 2006, doi: 10.5957/jsr.2006.50.3.231.
- [3] Y. Hu, W. Cui, and P. Terndrup Pedersen, "Maintained ship hull xcgrxcder ultimate

- [11] M. Steurer, R. J. Hill, and N. Pfeifer, "Metrics for evaluating the performance of machine learning based automated valuation models," *Journal of Property Research*, vol. 38, no. 2, pp. 99–129, Apr. 2021, doi: 10.1080/09599916.2020.1858937.
- [12] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco California USA, Aug. 2016, pp. 785–794. doi: 10.1145/2939672.2939785.
- [13] V.-H. Truong, G. Papazafeiropoulos, Q.-V. Vu, V.-T. Pham, and Z. Kong, "Predicting the patch load resistance of stiffened plate girders using machine learning algorithms," *Ocean Engineering*, vol. 240, p. 109886, Nov. 2021, doi: 10.1016/j.oceaneng.2021.109886.
- [14] "xgboost.readthedocs.io."
- [15] J. Guo *et al.*, "An XGBoost-based physical fitness evaluation model using advanced feature selection and Bayesian hyper-parameter optimization for wearable running monitoring," *Computer Networks*, vol. 151, pp. 166–180, Mar. 2019, doi: 10.1016/j.comnet.2019.01.026.
- [16] W. Zhang, C. Wu, H. Zhong, Y. Li, and L. Wang, "Prediction of undrained shear strength using extreme gradient boosting and random forest based on Bayesian optimization," *Geoscience Frontiers*, vol. 12, no. 1, pp. 469–477, Jan. 2021, doi: 10.1016/j.gsf.2020.03.007.
- [17] Y. Xia, C. Liu, Y. Li, and N. Liu, "A boosted decision tree approach using Bayesian hyper-parameter optimization for credit scoring," *Expert Systems with Applications*, vol. 78, pp. 225–241, Jul. 2017, doi: 10.1016/j.eswa.2017.02.017.
- [18] "https://github.com/fmfn/BayesianOptimization."
- [19] J. Zhou, Y. Qiu, S. Zhu, D. J. Armaghani, M. Khandelwal, and E. T. Mohamad, "Estimation of the TBM advance rate under hard rock conditions using XGBoost and Bayesian optimization," *Underground Space*, vol. 6, no. 5, pp. 506–515, Oct. 2021, doi: 10.1016/j.undsp.2020.05.008.
- strength reliability considering corrosion and fatigue," *Marine Structures*, vol. 17, no. 2, pp. 91–123, Mar. 2004, doi: 10.1016/j.marstruc.2004.06.001.
- [4] J. Bai, "Time-variant ultimate strength reliability assessment of ship hulls considering corrosion and fatigue," PhD thesis, University of California, Berkeley, 2006.
- [5] M. R. Zareei and M. Iranmanesh, "Ultimate strength formulation of stiffened panels under in-plane compression or tension with cracking damage," *J. nav. arch. mar. engg.*, vol. 15, no. 1, pp. 1–16, Jun. 2018, doi: 10.3329/jname.v15i1.31668.
- [6] M. R. Zareei, M. R. Khedmati, and P. Rigo, "Application of artificial neural networks to the evaluation of the ultimate strength of uniaxially compressed welded stiffened aluminium plates," *Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment*, vol. 226, no. 3, pp. 197–213, Aug. 2012, doi: 10.1177/1475090212445865.
- [7] Z. ul R. Tahir and P. Mandal, "Artificial neural network prediction of buckling load of thin cylindrical shells under axial compression," *Engineering Structures*, vol. 152, pp. 843–855, Dec. 2017, doi: 10.1016/j.engstruct.2017.09.016.
- [8] Z. ul R. Tahir, P. Mandal, M. T. Adil, and F. Naz, "Application of artificial neural network to predict buckling load of thin cylindrical shells under axial compression," *Engineering Structures*, vol. 248, p. 113221, Dec. 2021, doi: 10.1016/j.engstruct.2021.113221.
- [9] Z. Sun *et al.*, "Prediction of compression buckling load and buckling mode of hat-stiffened panels using artificial neural network," *Engineering Structures*, vol. 242, p. 112275, Sep. 2021, doi: 10.1016/j.engstruct.2021.112275.
- [10] A. Kaveh, A. Dadras Eslamlou, S. M. Javadi, and N. Geran Malek, "Machine learning regression approaches for predicting the ultimate buckling load of variable-stiffness composite cylinders," *Acta Mech*, vol. 232, no. 3, pp. 921–931, Mar. 2021, doi: 10.1007/s00707-020-02878-2.