



Application of Machine Learning in Predicting the Durability of Marine Composites

Seyed Amir Aboulghasem-Hosseini¹, Mohammad Latifi^{2*}

¹ Ph.D. Student, Department of Mechanical Engineering, Imam Hossein University, Tehran, Iran, s.a.hosseini1378@ihu.ac.ir

² Assistant Professor, Department of Mechanical Engineering, Imam Hossein University, Tehran, Iran, m.latifi@ihu.ac.ir

ARTICLE INFO

Article History:

Received: 16 May 2025

Last modification: 29 Jul 2025

Accepted: 30 Jul 2025

Available online: 30 Jul 2025

Article type:

Research paper

Keywords:

Composite

Moisture Absorption

Artificial Intelligence

Hygrothermal Aging

ABSTRACT

Fiber-reinforced polymer (FRP) composites are widely used in marine structures due to their high strength-to-weight ratio and good corrosion resistance. However, long-term exposure to humid and thermal environmental conditions can lead to a reduction in the mechanical properties of these materials. Traditional durability prediction models, such as the Arrhenius and Fick models, despite their widespread use, are limited in capturing the complex synergistic effects of environmental conditions due to their simplified assumptions. In this regard, the use of artificial intelligence models, especially machine learning (ML), has gained attention in recent years. This article examines the application of various machine learning algorithms in predicting the lifespan of polymer composites under humid and thermal conditions. Various studies have shown that different AI algorithms can accurately predict the degradation of mechanical properties in composites under various environmental conditions. Furthermore, input sensitivity analyses in different models have highlighted the greater importance of factors such as exposure time, temperature, pH level, and fiber volume in the degradation of mechanical properties. Despite the progress made, challenges such as the lack of field data and differences in model performance remain significant obstacles to accurately predicting the service life of composites.

ISSN: 2645-8136



DOI:

Copyright: © 2025 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license [<https://creativecommons.org/licenses/by/4.0/>]



کاربرد یادگیری ماشین در پیش بینی طول عمر کامپوزیت های دریایی

سیدامیر ابوالقاسم حسینی^۱، محمد لطیفی^۲

^۱ دانشجوی دکتری، گروه مهندسی مکانیک، دانشکده فنی و مهندسی، دانشگاه جامع امام حسین (ع)، s.a.hoseini1378@ihu.ac.ir

^۲ استادیار، گروه مهندسی مکانیک، دانشکده فنی و مهندسی، دانشگاه جامع امام حسین (ع)، m.latifi@ihu.ac.ir

چکیده

کامپوزیت های پلیمری تقویت شده با الیاف (FRP) به دلیل نسبت بالای مقاومت به وزن و مقاومت مناسب در برابر خوردگی، به طور گسترده ای در سازه های دریایی مورداستفاده قرار می گیرند. با این حال، قرارگیری طولانی مدت در شرایط محیطی رطوبتی گرمایی می تواند منجر به کاهش خواص مکانیکی این مواد شود. مدل های سنتی پیش بینی دوام نظیر مدل های آرنیوس و فیک، با وجود کاربرد گسترده، به دلیل مفروضات ساده سازی شده قادر به درک پیچیدگی اثرات هم افزایی شرایط محیطی نیستند. در این راستا، استفاده از مدل های هوش مصنوعی به ویژه یادگیری ماشین (ML) در سال های اخیر مورد توجه قرار گرفته است. این مقاله به بررسی کاربرد الگوریتم های مختلف یادگیری ماشین در پیش بینی عمر کامپوزیت های پلیمری در شرایط رطوبتی گرمایی می پردازد. مطالعات مختلف نشان می دهند که الگوریتم های مختلف هوش مصنوعی توانسته اند پیش بینی های دقیقی از کاهش خواص مکانیکی کامپوزیت تحت شرایط مختلف محیطی ارائه دهند. همچنین تحلیل حساسیت ورودی ها در مدل های مختلف، اهمیت بیشتر عواملی مانند زمان قرارگیری، دما، مقدار PH و حجم الیاف را در کاهش خواص مکانیکی نشان داده است. با وجود پیشرفت های صورت گرفته، محدودیت هایی چون کمبود داده های میدانی و تفاوت عملکرد مدل ها به عنوان چالش هایی جدی در مسیر پیش بینی دقیق عمر مفید کامپوزیت ها محسوب می شوند.

اطلاعات مقاله

ناریخچه مقاله:

تاریخ دریافت مقاله: ۱۴۰۴/۰۲/۲۶

تاریخ اصلاح مقاله: ۱۴۰۴/۰۵/۰۷

تاریخ پذیرش مقاله: ۱۴۰۴/۰۵/۰۸

تاریخ انتشار مقاله: ۱۴۰۴/۰۵/۰۸

نوع مقاله:

مقاله پژوهشی

کلمات کلیدی:

کامپوزیت

جذب رطوبت

هوش مصنوعی

پیرشدگی رطوبتی گرمایی

DOI:

حق نشر: © ۲۰۲۵ توسط نویسندگان. این اثر برای انتشار با دسترسی آزاد، تحت شرایط و ضوابط مجوز (CC BY) ارسال شده است.

ISSN: 2645-8136



۱ - مقدمه

پیش‌بینی دوام کامپوزیت‌ها در محیط‌های خورنده مورد استفاده قرار گرفته‌اند. این مطالعات بر روی مجموعه‌ای شامل بیش از ۷۰۰ داده‌ی تجربی صورت گرفت و تأثیر عواملی همچون زمان قرارگیری، دما، PH محیط، حجم الیاف و ضخامت صفحه بررسی شد و مشخص گردید که زمان و دما از مؤثرترین عوامل کاهش خواص مکانیکی هستند [۶-۸].

مدل‌های ML قابلیت شناسایی روابط غیرخطی چندمتغیره را دارند. باین حال انتخاب الگوریتم مناسب، کیفیت داده‌های ورودی و انجام تحلیل حساسیت، تأثیر بسزایی در دقت پاسخ‌ها دارند. علاوه بر آن، نبود داده‌های میدانی بلندمدت از عملکرد کامپوزیت‌ها در محیط واقعی از چالش‌های جدی در توسعه این مدل‌ها به شمار می‌رود.

۲ - پیرشدگی^۱

پیرشدگی در کامپوزیت‌های دریایی، مفهومی است که به کاهش تدریجی عملکرد مکانیکی، فیزیکی و شیمیایی این مواد در گذر زمان اشاره دارد. این فرآیند می‌تواند منجر به افت کارایی کلی سازه، افزایش هزینه‌های نگهداری، و حتی وقوع خرابی‌های خطرناک در شرایط بحرانی گردد [۳]؛ در نتیجه، شناخت عمیق و دقیق از انواع مکانیزم‌های مؤثر در پیرشدگی، بررسی رفتار زمان‌مند مصالح و توسعه راهکارهای مهندسی برای مقابله با فرسودگی، از الزامات کلیدی در طراحی سازه‌های دریایی پایدار و ایمن است.

به‌طور کلی پیرشدگی با سه مکانیزم اصلی طبقه‌بندی می‌شود: شیمیایی، فیزیکی و مکانیکی. اندرکنش بین این سه حوزه بستگی زیادی به دو متغیر دارد: مشخصات مصالح و محیط پیرشدگی. پیرشدگی مواد می‌تواند موجب تغییرات ساختاری در اجزای قطعات اصلی شود که می‌تواند آثار فاجعه‌باری بر روی سازه‌ها داشته باشد. با توجه به نوع مواد، محیط و نوع بارگذاری، مکانیزم‌های سه‌گانه فوق‌الذکر می‌توانند اثرات کاهنده و یا افزایش‌دهنده‌ای بر روی پیرشدگی داشته باشند. به‌عنوان مثال برخی از نمونه‌های کامپوزیتی هنگام قرارگیری در معرض پیرشدگی حرارتی پخته می‌شوند و استحکام آن‌ها افزایش پیدا می‌کند؛ اما در زمان پیرشدگی بیشتر، استحکام آن‌ها در طول زمان یک روند کاهشی را طی می‌کند. [۹].

۲-۱ پیرشدگی شیمیایی

پیرشدگی شیمیایی به تغییرات غیرقابل بازگشت در ساختار شیمیایی پلیمرها اطلاق می‌شود. این نوع تخریب عمدتاً از تعاملات شیمیایی با محیط پیرامونی ناشی می‌گردد، از جمله واکنش با اکسیژن (اکسیداسیون)، جذب و تجزیه توسط آب (هیدرولیز) و آسیب ناشی از تابش فرابنفش. در محیط‌های دریایی، حضور

کامپوزیت‌های پلیمری تقویت‌شده با الیاف به دلیل نسبت بالای استحکام به وزن، مقاومت در برابر خوردگی و مقاومت بالا در محیط‌های خورنده مانند محیط‌های دریایی، مورد توجه روزافزون قرار گرفته‌اند [۱]. این مواد گزینه‌ای بسیار کارآمد برای استفاده در بدنه کشتی‌ها، زیردریایی‌ها، سکوها، نفتی، توربین‌های بادی فراساحلی و سایر تجهیزات دریایی به شمار می‌روند. در سال‌های اخیر، به دلیل مشکلات خوردگی در میلگردهای فولادی، استفاده از میلگردهای کامپوزیتی مانند GFRP در سازه‌های دریایی افزایش یافته است. این میلگردها به دلیل مقاومت بالا در برابر خوردگی، وزن کم، و سهولت در نصب، جایگزین مناسبی برای فولاد هستند. باین حال، پیش‌بینی طول عمر این مواد در بلندمدت همچنان یک چالش اساسی به شمار می‌رود، به‌ویژه در محیط‌های مرطوب، قلیایی و دمای بالا که مشخصه‌ی اصلی محیط‌های دریایی محسوب می‌شوند [۲]. همچنین استفاده از مدل‌های هوش مصنوعی جهت طراحی و انتخاب مواد و تخمین طول عمر شناورهای دریایی از جمله کاربردهای بالقوه این مدل‌ها در صنایع دریایی می‌باشد.

بر اساس مطالعات موجود، نفوذ رطوبت، نمک و دمای بالا می‌توانند منجر به افت قابل توجهی در خواص مکانیکی کامپوزیت‌ها، به‌ویژه استحکام کششی و مدول الاستیسیته شوند. پدیده‌هایی نظیر تورم ماتریس، ایجاد ریزترک، جدایش الیاف از رزین و تغییرات شیمیایی همچون هیدرولیز و پلاستیکی شدن، از جمله مکانیسم‌های اصلی تخریب در این شرایط هستند. این مسائل باعث می‌شوند که پیش‌بینی دقیق طول عمر سازه‌های دریایی ساخته‌شده به یک ضرورت مهندسی تبدیل شود [۳].

روش‌های سنتی همچون مدل آرنیوس و قانون نفوذ فیک، علی‌رغم کاربرد گسترده، با محدودیت‌هایی مواجه‌اند. این مدل‌ها نه تنها توانایی کافی در درک رفتار غیرخطی و چندمتغیره محیط‌های واقعی را ندارند، بلکه در شرایطی که اثرات هم‌افزایی چندین عامل محیطی هم‌زمان وجود دارد، دقت خود را به‌طور جدی از دست می‌دهند. از سوی دیگر، انجام آزمون‌های میدانی بلندمدت به دلیل زمان‌بر بودن و هزینه‌های بالا، همیشه امکان‌پذیر نیست [۴، ۵].

در سال‌های اخیر، استفاده از روش‌های یادگیری ماشین (ML) به‌عنوان رویکردی جایگزین برای پیش‌بینی عمر کامپوزیت‌ها مورد توجه قرار گرفته است. این روش‌ها با بهره‌گیری از داده‌های آزمایشگاهی، بدون نیاز به روابط و فرضیات خاص درباره روابط بین متغیرها، قادرند الگوهای پیچیده و غیرخطی حاکم بر کاهش خواص مکانیکی کامپوزیت‌ها را شناسایی و پیش‌بینی کنند. الگوریتم‌هایی مانند شبکه‌های عصبی مصنوعی (ANN)، الگوریتم‌های ژنتیکی (GA، GEP)، سیستم‌های عصبی-فازی (ANFIS) و XGBoost در مطالعات متعددی برای

ترکیبات کلردار، اکسیژن محلول در آب و تابش شدید نور خورشید روند این واکنش‌ها را تسریع می‌بخشد [۳].

۲-۲ پیرشدگی فیزیکی

پیرشدگی فیزیکی پدیده‌ای ترمودینامیکی است که در اثر نگهداری پلیمر در دمایی پایین‌تر از دمای انتقال شیشه‌ای (T_g) رخ می‌دهد. در این حالت، ماده به تدریج به سمت وضعیت ترمودینامیکی تعادلی خود حرکت می‌کند که با کاهش حجم آزاد، آنتالپی و آنتروپی همراه است. این فرآیند باعث تغییر در خواص مکانیکی ماده از جمله کاهش انعطاف‌پذیری، افزایش مدول الاستیسیته، و در برخی موارد کاهش چقرمگی می‌شود [۳].

۲-۳ پیرشدگی مکانیکی

پیرشدگی مکانیکی ناشی از بارگذاری‌های تکراری یا طولانی‌مدت بر روی کامپوزیت است که منجر به تخریب تدریجی ساختار در مقیاس ماکروسکوپی می‌شود. پدیده‌هایی نظیر خزش، آزادسازی تنش (کاهش تنش در حالت کرنش ثابت)، تورق، تخریب بین‌لایه‌ای و ایجاد ترک‌های سطحی از جمله پیامدهای مهم این نوع پیرشدگی هستند [۳].

۳- روابط تجربی در پیش‌بینی دوام کامپوزیت‌ها

۳-۱- قانون فیک^۲

همان‌طور که ذکر شد کامپوزیت‌های پلیمری مانند در محیط‌های مرطوب و دریایی، به‌ویژه به دلیل جذب رطوبت، دچار کاهش تدریجی در خواص مکانیکی می‌شوند. یکی از مدل‌های رایج برای توصیف و پیش‌بینی این پدیده، قانون نفوذ فیک است که میزان جذب رطوبت در طول زمان و تأثیر آن بر ساختار ماده را مدل می‌کند. مدل فیک، اساساً برای توصیف پدیده‌های نفوذ مولکولی طراحی شده و فرض می‌کند که رطوبت (یا هر سیال نفوذپذیر) از نواحی با غلظت بالا به نواحی با غلظت پایین حرکت می‌کند. در مورد کامپوزیت‌ها این نفوذ معمولاً از سطح خارجی به داخل ماتریس پلیمری انجام می‌شود. برای مسائل تک جهته، نفوذ رطوبت در داخل اکثر کامپوزیت‌ها از قانون فیک مرتبه دو پیروی می‌کنند [۱۰].

$$\frac{\partial c}{\partial t} = D_z \frac{\partial^2 c}{\partial z^2} \quad (۱)$$


که در آن c غلظت رطوبت نمونه (g/mm^3)، t زمان (ثانیه)، z ضخامت نمونه (mm) و D_z ضریب نفوذ در راستای ضخامت (mm^2/sec) می‌باشد. برای یک نوار غوطه‌ور در یک ظرف بی‌نهایت، پاسخ رابطه (۱) به صورت زیر خواهد شد [۱۰]:

$$\frac{M_t}{M_e} = \left(\frac{4}{l}\right) \left(\frac{Dt}{\pi}\right)^{\frac{1}{2}} \quad (۲)$$

در این رابطه M_t جرم جذب‌شده در زمان t و M_e جرم جذب‌شده در حالت تعادل و l ضخامت چسب بر حسب میلی‌متر است.

شکل ۱ نشان‌دهنده روند جذب رطوبت فیکی در کامپوزیت‌های زمینه پلیمری می‌باشد. جذب رطوبت باعث ایجاد تغییراتی همچون نرم شدن ماتریس، کاهش دمای انتقال شیشه‌ای (T_g)، تورم ماتریس، هیدرولیز و کاهش چسبندگی بین الیاف-رزین می‌شود. این اتفاقات در نهایت منجر به افت مقاومت بین‌لایه‌ای و کاهش استحکام کلی می‌گردد [۳، ۱۱].

باوجود کاربرد گسترده، مدل فیک فقط برای جذب رطوبت در شرایط ثابت مناسب است و اثرات دما، تنش مکانیکی، و محیط‌های ترکیبی را در نظر نمی‌گیرد. همچنین این مدل توانایی مدل‌سازی اثرات دما و رطوبت یا محیط‌های قلیایی را به صورت هم‌زمان ندارد.



شکل ۱- نمودار جذب رطوبت [۱۰]

برای پیش‌بینی دوام کامپوزیت‌ها در محیط‌های گرم و مرطوب مدل فیک با مدل آرنیوس ترکیب می‌شود؛ بدین صورت می‌توان تخمین زد که با چه سرعتی آب وارد ساختار می‌شود و در دماهای مختلف چه تأثیری بر خواص مکانیکی خواهد داشت [۱۱].

۳-۲ رابطه آرنیوس^۳

رابطه آرنیوس یکی از رایج‌ترین روش‌های سنتی برای پیش‌بینی دوام و عمر مفید مواد پلیمری از جمله کامپوزیت‌های زمینه پلیمری است. این مدل بر پایه رابطه بین دما و نرخ واکنش‌های شیمیایی عمل می‌کند و فرض می‌کند که نرخ تخریب یا کاهش خواص مکانیکی با افزایش دما به صورت نمایی افزایش می‌یابد. اساس مدل آرنیوس بر این ایده استوار است که بسیاری از واکنش‌های تخریبی در مواد پلیمری، نظیر هیدرولیز، اکسیداسیون و تجزیه شیمیایی، با افزایش دما سریع‌تر اتفاق می‌افتند. بنابراین، با انجام آزمایش‌هایی

$$TSF = \exp \left[\frac{E_a}{R} \left(\frac{1}{T_0} - \frac{1}{T_1} \right) \right] \quad (7)$$

در کاربردهای مهندسی، داده‌های تجربی مربوط به کاهش خواص مکانیکی (مانند استحکام کششی یا مدول الاستیسیته) در دماهای بالا ثبت شده و سپس به کمک مدل آرنیوس به دمای سرویس واقعی منتقل می‌شوند تا یک منحنی پیش‌بینی عمر بلندمدت تولید شود. از این روش برای تخمین طول عمر کامپوزیت‌ها استفاده می‌شود، به‌ویژه در مواردی که داده‌های میدانی بلندمدت در دسترس نیست [۱۲].

باین‌حال، مدل آرنیوس محدودیت‌هایی نیز دارد. این مدل تنها اثر دما را به‌عنوان عامل مؤثر در نظر می‌گیرد و سایر عوامل محیطی مانند رطوبت، PH، اشعه UV، یا تنش‌های مکانیکی را لحاظ نمی‌کند. همچنین، فرض می‌کند که مکانیزم تخریب در تمامی دماها یکسان است؛ درحالی‌که ممکن است واکنش‌های شیمیایی متفاوتی در دماهای بالا نسبت به شرایط واقعی رخ دهد. به همین دلیل، دقت مدل آرنیوس در شرایطی که تخریب ناشی از ترکیب چند عامل محیطی باشد، کاهش می‌یابد و ممکن است تخمین‌های دقیقی نرزد [۱۳].

باوجود این محدودیت‌ها، مدل آرنیوس همچنان به‌عنوان یکی از پایه‌ای‌ترین ابزارها در تحلیل دوام مواد پلیمری شناخته می‌شود و اغلب به‌عنوان مرجع برای مقایسه با مدل‌های پیشرفته‌تر مانند مدل‌های یادگیری ماشین مورد استفاده قرار می‌گیرد. ترکیب این مدل با داده‌های میدانی یا آزمایش‌های شتاب‌یافته چندعاملی، می‌تواند دقت پیش‌بینی‌ها را در محیط‌های پیچیده‌ای همچون سازه‌های دریایی افزایش دهد.

در دماهای بالا طی مدت‌زمان کوتاه، می‌توان اطلاعاتی درباره عملکرد ماده در دمای پایین و بازه زمانی طولانی‌تر به دست آورد. فرمول پایه آرنیوس به شکل زیر ارائه می‌شود:

$$k = A \exp \left(\frac{-E_a}{RT} \right) \quad (3)$$

در این رابطه k نرخ تخریب $(1/\text{time})$ ، A ثابت ماده و ضریب لگاریتمی، E_a انرژی فعال‌سازی، R ثابت جهانی گازها و T دمای مطلق برحسب کلوین است.

برای مدل‌سازی کاهش خواص مکانیکی مانند مقاومت کششی یا مدول الاستیسیته، اغلب از روابط ریاضی ساده استفاده می‌شود. سه رابطه رایج در این زمینه عبارت‌اند از:



$$Y = a \log(t) + b \quad (4)$$

$$Y = 100 \exp \left(\frac{-t}{\tau} \right) \quad (5)$$


$$Y = (100 - Y_{\infty}) \exp \left(\frac{-t}{\tau} \right) + Y_{\infty} \quad (6)$$

در این روابط Y درصد باقی‌مانده خاصیت مکانیکی، Y_{∞} مقدار باقیمانده خاصیت مکانیکی پس از مدت‌زمان طولانی (حد پایدار)، t زمان قرارگیری در محیط و τ ثابت منحنی است.

برای تخمین دوام در دمای واقعی، معمولاً از ضریب انتقال زمانی^۴ (TSF) استفاده می‌شود که نسبت زمان معادل تخریب در دو دمای مختلف را ارائه می‌دهد. این ضریب با استفاده از رابطه ۷ تعریف می‌شود و امکان انتقال داده‌های حاصل از آزمایش‌های تسریع‌شده در دمای بالا به شرایط دمایی واقعی را فراهم می‌کند. در این رابطه T_1 دمای بالاتر و T_0 دمای پایین‌تر است.



Exposure time = Accelerated time * TSF from step 3 for each temperature



Step 3
Time Shift Factor (TSF)
Using $\frac{E_a}{R}$ obtained from step 2
$$TSF = \exp \left(\frac{E_a}{R} \left(\frac{1}{T_0} - \frac{1}{T_1} \right) \right)$$

شکل ۲- مدل‌های پیش‌بینی عملکرد بلندمدت با استفاده از تست‌های پیرشدگی تسریع‌شده با استفاده از مدل‌های آرنیوس [۱۳]


۴ - مدل‌های مبتنی بر یادگیری ماشین

با توجه به محدودیت‌های مدل‌های سنتی و تجربی در پیش‌بینی دوام کامپوزیت‌های زمینه پلیمری استفاده از مدل‌های یادگیری ماشین (ML) در سال‌های اخیر به‌طور قابل‌توجهی افزایش یافته است. در یادگیری ماشین، هدف توسعه الگوریتم‌هایی است که قادر باشند بدون نیاز به مدل‌های تحلیلی کلاسیک، از داده‌های تجربی الگوهای پنهان را شناسایی کرده و تصمیم‌گیری یا پیش‌بینی انجام دهند. این ویژگی باعث شده است که مدل‌های ML به ابزار قدرتمندی برای پیش‌بینی پدیده‌های مهندسی، به‌ویژه در زمینه رفتار درازمدت مواد کامپوزیتی، تبدیل شوند. هدف استفاده از مدل‌های یادگیری ماشین، توسعه یک تابعی است که بتواند با استفاده از داده‌های ورودی (نظیر دما، زمان، رطوبت، نوع الیاف و رزین، و غیره)، خروجی موردنظر (مانند استحکام باقیمانده یا درصد کاهش خواص مکانیکی) را با دقت بالا پیش‌بینی کند. مدل‌های ML می‌توانند به‌صورت پیش‌بینی‌کننده^۵، توصیف‌گر^۶ یا ترکیبی از هر دو باشند [۱۴، ۱۵].

فرآیند توسعه یک مدل یادگیری ماشین شامل انتخاب نوع آموزش (نظارت‌شده^۷، بدون نظارت^۸، نیمه نظارتی^۹ و تقویت‌شده^{۱۰})، تابع یادگیری، نحوه نمایش مدل و الگوریتم یادگیری است. در حوزه مهندسی، بیشترین کاربرد متعلق به روش‌های یادگیری نظارت‌شده و بدون نظارت است.

در یادگیری نظارت‌شده، مدل با استفاده از مجموعه‌ای از داده‌ها آموزش داده می‌شود تا بتواند خروجی‌های جدید را پیش‌بینی کند. این نوع آموزش برای پیش‌بینی کمی متغیرهایی مانند مقاومت مکانیکی بسیار مناسب است. در این حالت، اگر خروجی پیوسته باشد، مسئله از نوع رگرسیون^{۱۱} و اگر گسسته باشد، از نوع طبقه‌بندی^{۱۲} خواهد بود. در مقابل، یادگیری بدون نظارت به دنبال کشف ساختار در داده‌ها بدون استفاده از خروجی‌های شناخته‌شده است. در یادگیری بدون نظارت داده‌های شبیه به هم در دسته‌بندی‌های مشابه قرار می‌گیرند [۱۵، ۱۶]. همان‌گونه که در شکل ۳ قابل‌مشاهده است می‌توان الگوریتم‌های رایج یادگیری ماشین را به دو دسته یادگیری نظارت‌شده و بدون نظارت تفکیک کرد.

توسعه یک مدل یادگیری ماشین معمولاً در سه گام انجام می‌شود. نخست، داده‌ها گردآوری و آماده‌سازی می‌شوند. این مرحله شامل تعریف ورودی‌ها و خروجی‌های مدل است. سپس مرحله آموزش مدل انجام می‌شود که در آن الگوریتم، با استفاده از داده‌های آموزشی، ساختار پنهان در روابط بین پارامترها را یاد می‌گیرد. نهایتاً مدل ارزیابی می‌شود تا دقت، پایداری و توانایی تعمیم آن بررسی گردد. این فرایند به‌صورت شماتیک در شکل ۴ نشان داده شده است که روند کلی توسعه مدل ML را از ورودی داده تا ارزیابی نهایی به تصویر می‌کشد [۱۷].



شکل ۳- الگوریتم‌های رایج یادگیری ماشین مورد استفاده در کاربردهای مهندسی [۱۶]

مدل‌های دقیق ML در این حوزه است. با این حال، همان‌طور که ذکر شد، پتانسیل کاربرد این مدل‌ها در تمامی مراحل طراحی، ساخت و تحلیل دوام کامپوزیت‌ها بسیار بالا است.


۴-۱- کاربرد یادگیری ماشین در پیش‌بینی دوام کامپوزیت‌های زمینه پلیمری

همان‌گونه که ذکر شد، نیاز به مدل‌های دقیق برای پیش‌بینی عملکرد مکانیکی کامپوزیت‌ها در برابر شرایط محیطی طولانی‌مدت افزایش یافته است. به‌ویژه، پیش‌بینی کاهش خواص مکانیکی مانند مقاومت کششی، مدول الاستیسیته و مقاومت بین‌لایه‌ای که تحت تأثیر پیرشدگی محیطی قرار می‌گیرند، اهمیت زیادی در طراحی و ارزیابی ایمنی سازه‌ها دارد. در سال‌های اخیر، الگوریتم‌های یادگیری ماشین توانسته‌اند نقش مهمی در مدل‌سازی این پدیده‌ها ایفا کنند.

پژوهش‌های متعددی نشان داده‌اند که الگوریتم‌هایی مانند شبکه‌های عصبی مصنوعی (ANN)، الگوریتم XGBoost، برنامه‌نویسی ژنتیکی (GEP) و سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) قادرند کاهش خواص مکانیکی کامپوزیت‌های FRP را با دقت بالا پیش‌بینی کنند، مشروط بر آن‌که پایگاه داده‌ای باکیفیت کافی در دسترس باشد [۷، ۱۹-۲۲].


ورودی‌های رایج در این مدل‌ها شامل متغیرهایی نظیر دما، زمان قرارگیری در محیط، مقدار PH، نسبت حجمی الیاف، قطر الیاف یا ضخامت نمونه و نوع الیاف یا رزین هستند. خروجی نیز معمولاً به‌صورت درصد باقیمانده یک خاصیت مکانیکی تعریف می‌شود. نتایج حاصل از مدل‌های مختلف نشان می‌دهند که زمان و دما از مهم‌ترین عوامل تأثیرگذار بر کاهش خواص مکانیکی کامپوزیت‌ها هستند. همچنین در برخی مدل‌ها مشاهده شده که عوامل ساختاری مانند نسبت حجمی الیاف و ضخامت نمونه نیز نقش چشمگیری دارند. این یافته‌ها معمولاً با استفاده از تحلیل حساسیت و رتبه‌بندی اهمیت ویژگی‌ها استخراج شده‌اند و بیانگر آن هستند که مدل‌های یادگیری ماشین می‌توانند روابط پیچیده و غیرخطی میان متغیرهای ورودی و تغییرات عملکرد مصالح را به‌خوبی شناسایی کنند [۲، ۲۲].

از منظر مدل‌سازی، برخی از الگوریتم‌ها مانند GEP قادر به تولید روابط تحلیلی بین متغیرهای ورودی و خروجی هستند که امکان استفاده از آن‌ها در نرم‌افزارهای طراحی یا تحلیل عددی را فراهم می‌سازد. همچنین استفاده از مدل‌های مختلف بر روی یک مجموعه داده، اغلب منجر به نتایج نسبتاً همگن از لحاظ دقت پیش‌بینی شده است، اما در برخی موارد اختلافاتی در حساسیت مدل نسبت به پارامترها مشاهده می‌شود که نشان می‌دهد تفسیر



شکل ۴- فرآیند توسعه یک مدل یادگیری ماشین [۱۷]

در شکل ۵ یک چارچوب جامع برای استفاده از یادگیری ماشین در کل چرخه ساخت کامپوزیت‌های زمینه پلیمری معرفی شده است. در این رویکرد، یادگیری ماشین نه تنها در پیش‌بینی دوام، بلکه از مرحله انتخاب مواد اولیه (الیاف، ماتریس، پرکننده‌ها)، تا مرحله تولید و درنهایت شناسایی خواص مکانیکی نهایی به‌کار گرفته می‌شود. مطابق این شکل، ابتدا داده‌های مربوط به انتخاب مواد اولیه به‌عنوان ورودی به الگوریتم داده می‌شوند تا ترکیب بهینه برای دستیابی به خواص موردنظر تعیین گردد. سپس در مرحله ساخت، پارامترهایی نظیر فشار، دما و نرخ تزریق به‌عنوان ورودی به مدل داده‌شده و شرایط ساخت بهینه‌سازی می‌شود. در مرحله بعد، برای شناسایی خواص مکانیکی، می‌توان از مدل‌های یادگیری ماشین به‌جای تست‌های فیزیکی استفاده کرد تا در هزینه و زمان صرفه‌جویی شود. درنهایت، می‌توان از مدل‌سازی عددی نظیر روش اجزای محدود (FEM) برای شبیه‌سازی پاسخ مکانیکی کامپوزیت استفاده کرد و خروجی آن را با نتایج مدل یادگیری ماشین مقایسه نمود [۱۸]. نکته قابل‌توجه در کاربرد یادگیری ماشین در دوام کامپوزیت‌ها این است که این مدل‌ها به داده‌های تجربی زیاد و باکیفیت نیاز دارند. داده‌های مربوط به رفتار بلندمدت کامپوزیت‌های FRP، به‌ویژه در محیط‌های واقعی دریایی، هنوز محدود هستند و این موضوع یکی از موانع اصلی برای توسعه



شکل ۵- نقش یادگیری ماشین در کامپوزیت های زمینه پلیمری [۱۸]

مدل ANFIS نیز دقت بسیار قابل قبولی از خود نشان داد و نتایج آن تنها اندکی ضعیف تر از ANN می باشد. لازم به ذکر است هرچند دقت نتایج پیش بینی شده توسط مدل GEP مقداری کمتر از مدل های ANN و ANFIS می باشد، اما به دلیل ارائه یک رابطه ریاضی ساده و صریح میان متغیرهای ورودی (قطر میلگرد، درصد حجمی الیاف، pH محیط، دما و مدت زمان قرارگیری در شرایط قلیایی) و خروجی (TSR)، از ارزش خاصی برخوردار است. این مزیت استفاده از مدل GEP را در شرایطی که نیاز به پیش بینی سریع و بدون نیاز به پردازش های پیچیده کامپیوتری وجود دارد، بسیار ارزشمند می سازد. هر سه مدل، دقت قابل قبولی

نتایج یادگیری ماشین باید با در نظر گرفتن مبانی فیزیکی و مکانیزم های تخریب انجام شود [۲].


اقبال و همکاران [۸] در پژوهشی میزان مقاومت کششی باقی مانده (TSR) ^{۱۵} میلگردهای GFRP در محیط های قلیایی با استفاده از سه مدل ANN، ANFIS و GEP بررسی کردند. ارزیابی عملکرد این مدل ها بر مبنای معیارهای آماری مختلفی همچون ضریب همبستگی ^{۱۶} (R)، خطای میانگین مطلق ^{۱۷} (MAE) و خطای میانگین مربعی ^{۱۸} (RMSE) انجام شد (شکل ۶). نتایج این پژوهش نشان می دهد که مدل ANN با ضریب همبستگی (R ≈ 0.95) در مقایسه با سایر مدل ها از دقت بالاتری برخوردار بود.

در مجموع، مدل‌های یادگیری ماشین قابلیت بالایی در پیش‌بینی دوام کامپوزیت‌های پلیمری در شرایط محیطی مرطوب، گرم و قلیایی دارند. هرچند، عملکرد این مدل‌ها به شدت وابسته به کیفیت داده‌های آموزشی، تعریف دقیق متغیرهای ورودی و فرآیند اعتبارسنجی مدل است.


در پیش‌بینی حفظ مقاومت کششی میلگردهای GFRP نشان دادند و در تمامی آن‌ها ضریب همبستگی بالاتر از ۰/۸ بود که نشان‌دهنده قابلیت اعتماد بالای این مدل‌ها در پیش‌بینی رفتار بلندمدت کامپوزیت‌ها تحت پیرشدگی است [۸].

جدول ۲ - نقاط قوت و ضعف برخی از مدل‌های هوش مصنوعی در پیش‌بینی دوام کامپوزیت‌ها


نام مدل	نقاط قوت	نقاط ضعف	کاربرد
شبکه عصبی مصنوعی (ANN)	قابلیت بالا در مدل‌سازی روابط غیرخطی پیچیده؛ سازگاری با داده‌های حجیم؛ عملکرد مناسب در پیش‌بینی کمّی	نیاز به تنظیم پارامترهای متعدد (تعداد لایه‌ها، نرون‌ها)؛ خطر بیش‌برازش؛ تفسیرناپذیری	بسیار مناسب برای پیش‌بینی مقاومت کششی، مدول، یا میزان کاهش در شرایط پیچیده
الگوریتم درختی تقویتی (XGBoost)	دقت پیش‌بینی بالا؛ مقاومت در برابر بیش‌برازش ^{۱۳} ؛ تحلیل حساسیت قوی (تعیین اهمیت هر پارامتر)؛ سرعت آموزش بالا	نیاز به تنظیم دقیق پارامترها؛ عملکرد وابسته به کیفیت داده	ایده‌آل برای مسائل با تعداد متغیر بالا و تحلیل تأثیر متقابل آن‌ها
برنامه‌نویسی ژنتیکی (GEP)	خروجی به صورت فرمول تحلیلی قابل تفسیر؛ سازگار با داده‌های نویزی؛ مناسب برای ایجاد مدل‌های شبیه‌سازی‌شده	پیچیدگی در پیاده‌سازی؛ ممکن است به زمان محاسباتی بالا نیاز داشته باشد	مناسب برای استخراج روابط نیمه‌تجربی در پیش‌بینی رفتار مواد
سیستم عصبی-فازی تطبیقی (ANFIS)	ترکیب قابلیت یادگیری ANN با منطق فازی؛ تفسیرپذیری ^{۱۴} بالا؛ مناسب برای سیستم‌هایی با عدم قطعیت	عملکرد ضعیف‌تر در داده‌های بسیار بزرگ	مناسب برای مدل‌سازی محیط‌های با عدم قطعیت زیاد مانند شرایط محیطی طبیعی



(الف)



(ب)



(ج)

شکل ۶- مقایسه پاسخ سه مدل: (الف) ANN (ب) GEP (ج) ANFIS [۸]

۵- نتیجه گیری

در این مقاله مدل‌های مختلف پیش‌بینی دوام کامپوزیت‌های زمینه پلیمری مورد استفاده در صنایع دریایی بررسی شد. در ابتدا، روش‌های سنتی نظیر مدل آرنیوس و قانون فیک به‌عنوان ابزارهای رایج برای مدل‌سازی اثرات دما و رطوبت بر خواص مکانیکی مواد معرفی شدند. اگرچه این مدل‌ها به‌واسطه سادگی و امکان کالیبراسیون با داده‌های آزمایشگاهی مورداستفاده قرار می‌گیرند، اما در شبیه‌سازی رفتار مواد در برابر اثرات هم‌افزای محیطی، دارای محدودیت‌های جدی هستند.

در ادامه، مدل‌های مختلف یادگیری ماشین به‌عنوان جایگزین‌های هوشمند و دقیق برای تحلیل و بررسی کاهش خواص مکانیکی کامپوزیت‌ها موردبررسی قرار گرفتند. این مدل‌ها قابلیت یادگیری از داده‌های تجربی و کشف روابط پیچیده و غیرخطی بین

متغیرهای ورودی (نظیر دما، زمان، PH، رطوبت) و خروجی‌های موردنظر را دارند. مقایسه نتایج حاصل از سه مدل ANN، ANFIS و GEP برای پیش‌بینی طول عمر میله‌های کامپوزیتی تحت پیرشدگی محیطی نشان می‌دهد که نتایج به‌دست‌آمده از مدل‌های ANN و ANFIS از دقت بالاتری برخوردارند، چنانچه ضریب همبستگی نتایج در این مدل‌ها ۰/۹۵ می‌باشد که نسبت به مدل GEP با ضریب همبستگی ۰/۸۵ حدود ۱۲ درصد بهبود را نشان می‌دهد. این در حالی است که تنها مزیت مدل GEP نسبت به سایر مدل‌ها ارائه یک رابطه تحلیلی میان پارامترهای ورودی و خروجی می‌باشد.

باوجود عملکرد مثبت این مدل‌ها، چالش‌هایی نظیر نیاز به پایگاه داده گسترده و دقیق، انتخاب بهینه پارامترهای مدل و تفسیر فیزیکی نتایج همچنان باقی است. همچنین، تطبیق نتایج مدل‌های داده‌محور با مشاهدات میدانی واقعی و افزایش قابلیت اطمینان

6- H. Naderpour and S. A. Alavi, (2017), *A proposed model to estimate shear contribution of FRP in strengthened RC beams in terms of Adaptive Neuro-Fuzzy Inference System*, Composite Structures, vol. 170, pp. 215–227, <https://doi.org/10.1016/j.compstruct.2017.03.028>.

7- K. Zhang, K. Zhang, and R. Bao, (2023), *Machine learning models to predict the residual tensile strength of glass fiber reinforced polymer bars in strong alkaline environments: A comparative study*, Journal of Building Engineering, vol. 73, p. 106817, <https://doi.org/10.1016/j.jobbe.2023.106817>.

8- M. Iqbal, D. Zhang, F.E. Jalal, and M. Faisal Javed, (2021), *Computational AI prediction models for residual tensile strength of GFRP bars aged in the alkaline concrete environment*, Ocean Engineering, vol. 232, p. 109134, <https://doi.org/10.1016/j.oceaneng.2021.109134>.

9- T. Gates, "1 - The physical and chemical ageing of polymeric composites," in *Ageing of Composites*, R. Martin Ed.: Woodhead Publishing, 2008, pp. 3–33, <https://doi.org/10.1533/9781845694937.1.3>.

10- J. Comyn, "Diffusion of Water in Adhesives," in *Design of Adhesive Joints Under Humid Conditions*, L. F. M. da Silva and C. Sato Eds. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013, pp. 1–19, 10.1007/978-3-642-37614-6_1.

11- J. Summerscales, "1 - Materials selection for marine composites," in *Marine Composites*, R. Pemberton, J. Summerscales, and J. Graham-Jones Eds.: Woodhead Publishing, 2019, pp. 3–30, <https://doi.org/10.1016/B978-0-08-102264-1.00001-7>.

12- G. Hota, W. Barker, and A. Manalo, (2020), *Degradation mechanism of glass fiber/vinylester-based composite materials under accelerated and natural aging*, Construction and Building Materials, vol. 256, p. 119462, <https://doi.org/10.1016/j.conbuildmat.2020.119462>.

13- C. Machello, M. Bazli, A. Rajabipour, H. M. Rad, M. Arashpour, and A. Hadigheh, (۲۰۲۳), *Using machine learning to predict the long-term performance of fibre-reinforced polymer structures: A state-of-the-art review*, Construction and Building Materials, vol. 408, p. 133692, <https://doi.org/10.1016/j.conbuildmat.2023.133692>.

14- V. Cherkassky and F. M. Mulier, *Learning from data: concepts, theory, and methods*. John Wiley & Sons, 2007.

۱۵- K. P. Murphy, *Machine learning: a probabilistic perspective*. MIT press, 2012.

16- W. Z. Taffese and E. Sistonen, (2017), *Machine learning for durability and service-life assessment of reinforced concrete structures: Recent advances and future directions*, Automation in Construction, vol. 77, pp. 1–14, <https://doi.org/10.1016/j.autcon.2017.01.016>.

17- H.-T. Thai, (2022), *Machine learning for structural engineering: A state-of-the-art review*,

آن‌ها برای استفاده در طراحی سازه‌های دریایی، به‌عنوان گام‌های بعدی در توسعه این رویکردها مطرح هستند.

کلید واژگان

- 1- Aging
- 2- Fick's Law
- 3- Arrhenius Relation
- 4- Time Shift Factor
- 5- Predictive
- 6- Descriptive
- 7- Supervised
- 8- Unsupervised
- 9- Semi-supervised
- 10- Reinforcement
- 11- Regression
- 12- Classification
- 13- Overfitting
- 14- Interpretability
- 15- Tensile Strength Retention
- 16- Correlation coefficient
- 17- Mean Absolute Error
- 18- Root Mean Square Error

۶ - مراجع

- 1- Z. Wang, X.-L. Zhao, G. Xian, G. Wu, R. K. Singh Raman, S. Al-Saadi, and A. Haque, (2017), *Long-term durability of basalt- and glass-fibre reinforced polymer (BFRP/GFRP) bars in seawater and sea sand concrete environment*, Construction and Building Materials, vol. 139, pp. 467–489, <https://doi.org/10.1016/j.conbuildmat.2017.02.038>.
- 2- M. Iqbal, K. Elbaz, D. Zhang, L. Hu, and F. E. Jalal, (2023), *Prediction of residual tensile strength of glass fiber reinforced polymer bars in harsh alkaline concrete environment using fuzzy metaheuristic models*, Journal of Ocean Engineering and Science, vol. 8, no. 5, pp. 546–558, <https://doi.org/10.1016/j.joes.2022.03.011>.
- 3- V. M. Karbhari, "1 - Introduction: the use of composites in civil structural applications," in *Durability of Composites for Civil Structural Applications*, V. M. Karbhari Ed.: Woodhead Publishing, 2007, pp. 1–10, <https://doi.org/10.1533/9781845693565.1>.
- 4- Z. Lu, G. Xian, and H. Li, (2015), *Effects of exposure to elevated temperatures and subsequent immersion in water or alkaline solution on the mechanical properties of pultruded BFRP plates*, Composites Part B: Engineering, vol. 77, pp. 421–430, <https://doi.org/10.1016/j.compositesb.2015.03.066>.
- 5- O. Starkova, K. Aniskevich, and J. Sevchenko, (2۰۲۱) *Long-term moisture absorption and durability of FRP pultruded rebars*, Materials Today: Proceedings, vol. 34, pp. 36–40, <https://doi.org/10.1016/j.matpr.2019.12.154>.

- Structures, vol. 38, pp. 448–491, <https://doi.org/10.1016/j.istruc.2022.02.003>.
- 18- P. Pattnaik, A. Sharma, M. Choudhary, V. Singh, P. Agarwal, and V. Kukshal, (2021), *Role of machine learning in the field of Fiber reinforced polymer composites: A preliminary discussion*, Materials Today: Proceedings, vol. 44, pp. 4703–4708, <https://doi.org/10.1016/j.matpr.2020.11.026>.
- 19- M. Iqbal, Q. Zhao, D. Zhang, F. E. Jalal, and A. Jamal, (2021), *Evaluation of tensile strength degradation of GFRP rebars in harsh alkaline conditions using non-linear genetic-based models*, Materials and Structures, vol. 54, no. 5, p. 190, 10.1617/s11527-021-01783-x.
- 20- Y. Kim and H. Oh, "Comparison between Multiple Regression Analysis, Polynomial Regression Analysis, and an Artificial Neural Network for Tensile Strength Prediction of BFRP and GFRP," *Materials*, vol. 14, no. 17, doi: 10.3390/ma14174861.
- 21- M. Iqbal, D. Zhang, and F. E. Jalal, (2022), *Durability evaluation of GFRP rebars in harsh alkaline environment using optimized tree-based random forest model*, Journal of Ocean Engineering and Science, vol. 7, no. 6, pp. 596–606, <https://doi.org/10.1016/j.joes.2021.10.012>.
- 22- X. Liu, T. Liu, and P. Feng, (2022), *Long-term performance prediction framework based on XGBoost decision tree for pultruded FRP composites exposed to water, humidity and alkaline solution*, Composite Structures, vol. 284, p. 115184, <https://doi.org/10.1016/j.compstruct.2022.115184>.