



Evaluation of Machine Learning Models for Predicting the Dynamic Responses of a Small Research Submarine During Emergency Ascent

Aref Jafari^{1*}, Majid Abbaspour²

¹M.Sc. Graduate in Naval Architecture Engineering, Sharif University of Technology, Tehran, Iran aref.jafari748@sharif.edu

²Professor, Department of Mechanical Engineering, Sharif University of Technology, Tehran, Iran abbpor@sharif.edu

ARTICLE INFO

Article History:

Received: 24 May 2026

Last modification: 4 Oct 2026

Accepted: 5 Oct 2026

Available online: 10 Oct 2026

Article type:

Research Paper

Keywords:

Machine learning

Small research submarine

Dynamic response

Emergency ascent

ABSTRACT

Emergency ascent is a critical operational condition for submarines, during which complex hydrodynamic forces and nonlinear dynamic responses can significantly affect vehicle motion. Conventional computational fluid dynamics (CFD) simulations can be computationally demanding when a large number of operating conditions must be evaluated. Therefore, this study investigates the capability of machine learning models to predict the dynamic responses of a small research submarine during emergency ascent. A dataset obtained from numerical simulations under different emergency ascent conditions was used to develop three machine learning models: Random Forest, Extreme Gradient Boosting (XGBoost), and Multilayer Perceptron (MLP). The models were trained to learn the nonlinear relationships between the input parameters and the submarine's dynamic responses. Their predictive performance was evaluated using the coefficient of determination (R^2) and root mean square error (RMSE). The results showed that all three models achieved high predictive accuracy, with R^2 values greater than 0.98. Among the investigated models, MLP achieved the highest overall performance, with $R^2 = 0.991$ and RMSE = 0.033. XGBoost followed with $R^2 = 0.987$ and RMSE = 0.036, while Random Forest achieved $R^2 = 0.982$ and RMSE = 0.041. These results demonstrate the potential of machine learning models as an efficient computational approach for predicting submarine dynamic responses during emergency ascent.

ISSN: 2645-8136



DOI:

Copyright: © 2026 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/>]



ارزیابی قابلیت مدل‌های یادگیری ماشین در پیش‌بینی پاسخ‌های دینامیکی زیردریایی تحقیقاتی کوچک در شرایط صعود اضطراری

عارف جعفری^{*۱} ID، مجید عباسپور^۲ ID

۱ فارغ‌التحصیل کارشناسی ارشد مهندسی معماری کشتی، دانشگاه صنعتی شریف، تهران، ایران، aref.jafari748@sharif.edu

۲ استاد، دانشکده مهندسی مکانیک، دانشگاه صنعتی شریف، تهران، ایران، abbpor@sharif.edu

چکیده

صعود اضطراری یکی از شرایط عملیاتی بحرانی زیردریایی‌ها است که در آن نیروهای هیدرودینامیکی پیچیده و پاسخ‌های دینامیکی غیرخطی می‌توانند تأثیر قابل توجهی بر حرکت زیردریایی داشته باشند. شبیه‌سازی‌های متداول دینامیک سیالات محاسباتی (CFD)، به‌ویژه در صورت نیاز به بررسی تعداد زیادی از شرایط عملیاتی، می‌توانند از نظر محاسباتی زمان‌بر باشند. از این‌رو، پژوهش حاضر قابلیت مدل‌های یادگیری ماشین را در پیش‌بینی پاسخ‌های دینامیکی یک زیردریایی تحقیقاتی کوچک در شرایط صعود اضطراری بررسی می‌کند. برای این منظور، مجموعه داده حاصل از شبیه‌سازی‌های عددی زیردریایی در شرایط مختلف صعود اضطراری برای توسعه سه مدل یادگیری ماشین شامل جنگل تصادفی (Random Forest)، تقویت گرادیان شدید (XGBoost) و پرسپترون چندلایه (MLP) مورد استفاده قرار گرفت. مدل‌ها برای یادگیری روابط غیرخطی میان پارامترهای ورودی و پاسخ‌های دینامیکی زیردریایی آموزش داده شدند و عملکرد آن‌ها با استفاده از ضریب تعیین (R^2) و ریشه میانگین مربعات خطا (RMSE) ارزیابی شد. نتایج نشان داد که هر سه مدل از دقت پیش‌بینی بالایی برخوردار بوده و مقدار R^2 آن‌ها بیش از ۰٫۹۸ است. مدل MLP با $R^2 = ۰٫۹۹۱$ و $RMSE = ۰٫۰۳۳$ بهترین عملکرد کلی را نشان داد. پس از آن، XGBoost با $R^2 = ۰٫۹۸۷$ و $RMSE = ۰٫۰۳۶$ و جنگل تصادفی با $R^2 = ۰٫۹۸۲$ و $RMSE = ۰٫۰۴۱$ قرار گرفتند. این نتایج نشان‌دهنده ظرفیت مدل‌های یادگیری ماشین به‌عنوان رویکردی کارآمد برای پیش‌بینی پاسخ‌های دینامیکی زیردریایی در شرایط صعود اضطراری است.

اطلاعات مقاله

نارنجچه مقاله:

تاریخ دریافت مقاله: ۱۴۰۵/۰۳/۰۳

تاریخ اصلاح مقاله: ۱۴۰۵/۰۷/۱۲

تاریخ پذیرش مقاله: ۱۴۰۵/۰۷/۱۳

تاریخ انتشار مقاله: ۱۴۰۵/۰۷/۱۹

نوع مقاله

مقاله پژوهشی

کلمات کلیدی:

زیردریایی تحقیقاتی کوچک

یادگیری ماشین

پاسخ‌های دینامیکی

دینامیک سیالات محاسباتی

صعود اضطراری

DOI:

حق نشر: © ۲۰۲۶ توسط نویسندگان. این اثر برای انتشار با دسترسی آزاد، تحت شرایط و ضوابط مجوز

(CC BY) ارسال شده است.

ISSN: 2645-8136



۱ - مقدمه

زیردریایی‌های تحقیقاتی کوچک به دلیل قابلیت به کارگیری در مأموریت‌های اکتشافی، پایش محیط‌های دریایی و انجام عملیات در نواحی با دسترسی محدود، از اهمیت قابل توجهی برخوردارند. یکی از شرایط عملیاتی مهم این شناورها، صعود اضطراری است که در آن زیردریایی باید در مدت زمان مناسب به سطح آب بازگردد. رفتار زیردریایی در این شرایط یک مسئله دینامیکی [1] پیچیده محسوب می‌شود؛ زیرا پاسخ آن تحت تأثیر مجموعه‌ای از تغییر در شرایط [2]. عوامل هیدرودینامیکی و عملیاتی قرار دارد اولیه و پارامترهای کنترلی می‌تواند بر سرعت صعود، شتاب در [4]، [3]. عمودی، زاویه پیچ و جابه‌جایی قائم اثرگذار باشد مطالعه مبنای این پژوهش نیز پاسخ‌های دینامیکی اصلی شامل به عنوان Heave و پاسخ Pitch سرعت عمودی، شتاب، زاویه [6]، [5]. خروجی‌های مورد بررسی در نظر گرفته شده‌اند

تحلیل دقیق رفتار زیردریایی در شرایط صعود اضطراری معمولاً با استفاده از روش‌های عددی و به ویژه دینامیک سیالات محاسباتی انجام می‌شود. روش‌های CFD امکان بررسی اثر متغیرهای مختلف و تحلیل رفتار جریان و پاسخ دینامیکی سامانه را فراهم می‌کنند، اما انجام تعداد زیادی شبیه‌سازی برای پوشش شرایط عملیاتی مختلف می‌تواند مستلزم زمان و هزینه محاسباتی قابل توجهی باشد. از این رو، استفاده از روش‌هایی که [8]، [7] بتوانند ارتباط میان پارامترهای ورودی و پاسخ‌های حاصل از شبیه‌سازی‌های عددی را فرا گرفته و با سرعت بیشتری خروجی‌های مورد نظر را پیش‌بینی کنند، مورد توجه قرار گرفته [10]، [9]. است

در سال‌های اخیر، روش‌های یادگیری ماشین به عنوان ابزاری مؤثر برای مدل‌سازی روابط پیچیده و غیرخطی در مسائل مهندسی مطرح شده‌اند. این روش‌ها با استفاده از داده‌های موجود [9]، [1] می‌توانند الگوهای میان متغیرهای ورودی و خروجی را شناسایی کرده و برای پیش‌بینی شرایط جدید مورد استفاده قرار در فایل مبنای این پژوهش، داده‌های حاصل از [10]. گیرند برای آموزش مدل‌های مختلف یادگیری ماشین CFD تحلیل‌های و Random Forest، XGBoost به کار گرفته شده و مدل‌های برای پیش‌بینی پاسخ‌های (MLP) شبکه عصبی چندلایه [12]، [11]. دینامیکی مورد بررسی قرار گرفته‌اند

با توجه به پیچیدگی و غیرخطی بودن رفتار هیدرودینامیکی زیردریایی‌ها در شرایط صعود اضطراری، استفاده از روش‌های مبتنی بر یادگیری ماشین می‌تواند به عنوان رویکردی مکمل در کنار شبیه‌سازی‌های عددی مورد توجه قرار گیرد. این روش‌ها با یادگیری روابط موجود در داده‌های حاصل از تحلیل‌های عددی، امکان پیش‌بینی سریع‌تر پاسخ‌های دینامیکی را فراهم می‌کنند و

می‌توانند نیاز به انجام مکرر شبیه‌سازی‌های پرهزینه محاسباتی را کاهش دهند.

با وجود گسترش کاربرد روش‌های یادگیری ماشین در مسائل هیدرودینامیکی و مدل‌سازی جانشین، بررسی قابلیت مدل‌های مختلف یادگیری ماشین در پیش‌بینی پاسخ‌های دینامیکی زیردریایی‌های تحقیقاتی کوچک در شرایط صعود اضطراری همچنان نیازمند مطالعه است. تفاوت در ساختار و سازوکار یادگیری مدل‌ها می‌تواند بر توانایی آن‌ها در بازنمایی روابط غیرخطی موجود میان پارامترهای ورودی و پاسخ‌های حاصل از شبیه‌سازی‌های عددی تأثیرگذار باشد.

بر این اساس، هدف اصلی پژوهش حاضر ارزیابی و مقایسه قابلیت سه مدل یادگیری ماشین شامل Random Forest، XGBoost و شبکه عصبی پرسپترون چندلایه در پیش‌بینی پاسخ‌های دینامیکی یک زیردریایی تحقیقاتی کوچک در شرایط صعود اضطراری است. داده‌های مورد استفاده از نتایج شبیه‌سازی‌های عددی استخراج شده و عملکرد مدل‌ها با استفاده از شاخص‌های ضریب تعیین و ریشه میانگین مربعات خطا مورد ارزیابی قرار گرفته است. در نهایت، عملکرد کلی مدل‌ها با یکدیگر مقایسه شده تا قابلیت آن‌ها در یادگیری روابط غیرخطی موجود در داده‌های دینامیکی بررسی شود.

۲ - معادلات اساسی حاکم

به منظور تولید داده‌های مورد نیاز برای آموزش و ارزیابی مدل‌های یادگیری ماشین، رفتار هیدرودینامیکی زیردریایی در شرایط صعود اضطراری با استفاده از شبیه‌سازی دینامیک سیالات محاسباتی بررسی شده است. در این پژوهش، جریان پیرامون زیردریایی به صورت ناپایا و تراکم‌ناپذیر در نظر گرفته شده و پاسخ‌های دینامیکی مورد بررسی شامل سرعت صعود، شتاب قائم، زاویه پیچ و دامنه نوسان قائم است. داده‌های حاصل از شبیه‌سازی‌های عددی به عنوان مجموعه داده مورد استفاده در مدل‌های یادگیری ماشین به کار گرفته شده‌اند.

۲-۱ - معادله پیوستگی

با فرض تراکم‌ناپذیر بودن جریان، معادله بقای جرم به صورت رابطه (۱) بیان می‌شود:

$$\nabla \cdot \mathbf{u} = 0 \quad (1)$$

در رابطه (1)، $\mathbf{u}$ بردار سرعت سیال و ∇ عملگر گرادیان است. صفر بودن واگرایی میدان سرعت بیانگر فرض تراکم‌ناپذیری جریان است.

۲-۲- معادله مومنتوم

رفتار جریان ناپایای پیرامون بدنه زیردریایی بر اساس معادله مومنتوم ناویا-استوکس، مطابق رابطه (۲)، بیان می‌شود:

$$\rho \left(\frac{\partial u}{\partial t} + u \cdot \nabla u \right) = -\nabla p + \mu \nabla^2 u + \rho g \quad (2)$$

در رابطه (۲)، ρ چگالی سیال، t زمان، u بردار سرعت، p فشار، μ ویسکوزیته دینامیکی و g بردار شتاب گرانش است. این رابطه اثر تغییرات زمانی و مکانی سرعت، نیروهای ناشی از فشار، اثرات لزجت و نیروی گرانش را بر میدان جریان در نظر می‌گیرد.

۲-۳- نیروی شناوری

نیروی شناوری وارد بر زیردریایی بر اساس حجم سیال جابه‌جا شده، مطابق رابطه (۳)، تعریف می‌شود:

$$F_B = \rho g V \quad (3)$$

در رابطه (۳)، F_B نیروی شناوری، ρ چگالی سیال، g شتاب گرانش و V حجم جابه‌جایی زیردریایی است.

در شرایط صعود اضطراری، رهاسازی وزنه‌ها باعث کاهش جرم سامانه و در نتیجه افزایش نیروی خالص مؤثر در جهت قائم می‌شود. نیروی خالص مؤثر را می‌توان مطابق رابطه (۴) بیان کرد:

$$F_{net} = F_B - W - F_D \quad (4)$$

در رابطه (۴)، F_{net} نیروی خالص وارد بر زیردریایی در راستای قائم، F_B نیروی شناوری، W وزن زیردریایی و F_D نیروی مقاومت هیدرودینامیکی است.

۲-۴- معادله حرکت قائم

حرکت قائم زیردریایی تحت تأثیر نیروهای مؤثر بر آن قرار دارد و مطابق قانون دوم نیوتن، رابطه (۵) برای آن نوشته می‌شود:

$$m \frac{dv_z}{dt} = F_{net} \quad (5)$$

در رابطه (۵)، m جرم مؤثر زیردریایی، v_z سرعت قائم، t زمان و F_{net} نیروی خالص مؤثر در راستای قائم است.

نیروی مقاومت هیدرودینامیکی نیز به صورت رابطه (۶) بیان می‌شود:

$$F_D = \frac{1}{2} \rho C_D A V_z^2 \quad (6)$$

در رابطه (۶)، F_D نیروی مقاومت، ρ چگالی سیال، C_D ضریب مقاومت، A سطح مرجع و V_z سرعت قائم زیردریایی است.

۲-۵- رابطه میان ورودی‌ها و پاسخ‌های مدل یادگیری

ماشین

پس از استخراج داده‌های موردنیاز از شبیه‌سازی‌های عددی، رابطه میان متغیرهای ورودی و پاسخ‌های دینامیکی با استفاده از مدل‌های یادگیری ماشین برقرار می‌شود. این رابطه به صورت کلی مطابق رابطه (۷) نوشته می‌شود:

$$y^{\wedge} = f(x) \quad (7)$$

در رابطه (۷)، x بردار متغیرهای ورودی، f تابع یادگرفته شده توسط مدل یادگیری ماشین و $y^{\wedge}$ بردار پاسخ‌های پیش‌بینی شده است. در این پژوهش، پاسخ‌های مورد بررسی شامل بیشینه سرعت صعود، بیشینه شتاب قائم، بیشینه زاویه پیچ و دامنه نوسان قائم هستند.

۲-۶- معیارهای ارزیابی عملکرد مدل‌ها

برای ارزیابی عملکرد مدل‌های یادگیری ماشین، از ریشه میانگین مربعات خطا و ضریب تعیین استفاده می‌شود. ریشه میانگین مربعات خطا مطابق رابطه (۸) محاسبه می‌شود:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i^{\wedge})^2} \quad (8)$$

در رابطه (۸)، $RMSE$ ریشه میانگین مربعات خطا، n تعداد نمونه‌ها، y_i مقدار واقعی پاسخ و $y_i^{\wedge}$ مقدار پیش‌بینی شده توسط مدل یادگیری ماشین برای نمونه i است.


ضریب تعیین نیز مطابق رابطه (۹) به صورت زیر محاسبه می‌شود:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y_i^{\wedge})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (9)$$

در رابطه (۹)، R^2 ضریب تعیین، y_i مقدار واقعی، $y_i^{\wedge}$ مقدار پیش‌بینی شده، $\bar{y}$ میانگین مقادیر واقعی و n تعداد نمونه‌ها است. مقدار R^2 هرچه به ۱ نزدیک‌تر باشد، بیانگر انطباق بیشتر نتایج پیش‌بینی شده با داده‌های واقعی است.

مدل هندسی زیردریایی مورد استفاده در شبیه‌سازی‌های عددی در شکل ۱ ارائه شده است. بدنه زیردریایی بر اساس پروفیل Myring طراحی شده و هندسه آن مبنای تولید داده‌های مورد استفاده در مدل‌سازی یادگیری ماشین قرار گرفته است.

یافت تا ضمن حفظ دقت در نواحی بحرانی، از افزایش غیرضروری تعداد المان‌ها جلوگیری شود. در مجاورت سطح جامد بدنه، از لایه‌های منشوری مرزی استفاده شد. ضخامت اولیه این لایه‌ها حدود ۳ میلی‌متر در نظر گرفته شد تا امکان محاسبه مناسب گرادیان‌های سرعت در ناحیه مرزی فراهم شود. همچنین، مقدار y^+ به‌عنوان یکی از معیارهای اصلی طراحی شبکه در نظر گرفته شد و مقادیر آن در نواحی بحرانی در محدوده ۳۰ تا ۳۰۰ قرار گرفت تا با کاربرد مدل آشفتگی $k-\epsilon$ سازگار باشد.



شکل ۱- مدل هندسی زیردریایی تحقیقاتی کوچک مورد استفاده در شبیه‌سازی‌های عددی

۸-۲- مطالعه استقلال شبکه

به‌منظور اطمینان از دقت و پایداری حل عددی، مطالعه استقلال شبکه (Mesh Independence Study) با استفاده از چهار سطح مختلف شبکه انجام شد. تعداد سلول‌ها و تغییرات شاخص مورد استفاده برای ارزیابی استقلال شبکه در جدول ۱ ارائه شده است.

جدول ۱- تقسیم سطح مش‌بندی و بررسی تغییرات مش‌بندی

وضعیت شبکه	تغییر نسبت به شبکه قبلی (%)	تعداد سلول‌ها	شبکه
پایه اولیه	—	۴۸۳٬۶۶۲	G1
بهبود مشهود	۳۲٫۸	۶۴۲٬۳۱۵	G2
تغییرات کم	۱۰٫۲۷	۷۰۸٬۲۵۸	G3
تغییرات ناچیز	۰٫۶۴	۷۱۲٬۸۰۰	G4

نتایج مطالعه استقلال شبکه نشان داد که با افزایش تراکم شبکه از G1 به G2، تغییرات قابل توجهی در شاخص مورد ارزیابی مشاهده می‌شود. با افزایش تراکم شبکه از G2 به G3، میزان تغییرات کاهش یافته و در مقایسه بین شبکه‌های G3 و G4، تغییرات به مقدار ناچیزی رسیده است. بر این اساس، شبکه G3 به‌عنوان شبکه نهایی برای انجام شبیه‌سازی‌های عددی انتخاب شد؛ زیرا افزایش بیشتر تراکم شبکه از G3 به G4، با وجود افزایش تعداد سلول‌ها، تغییر قابل توجهی در نتایج ایجاد نکرد و استفاده از G3 تعادل مناسبی میان دقت عددی و هزینه محاسباتی فراهم می‌کند.

۳- تولید داده و مدل‌سازی یادگیری ماشین

به‌منظور بررسی قابلیت مدل‌های یادگیری ماشین در پیش‌بینی پاسخ‌های دینامیکی زیردریایی در شرایط صعود اضطراری، از داده‌های حاصل از شبیه‌سازی‌های عددی به‌عنوان مبنای توسعه مدل‌ها استفاده شد. داده‌های مورد استفاده شامل مجموعه‌ای از متغیرهای مؤثر بر رفتار دینامیکی زیردریایی و پاسخ‌های متناظر آن در شرایط مختلف صعود اضطراری بودند. در این پژوهش،

۷-۲- مشخصات هندسی، دامنه محاسباتی و شبکه‌بندی

مدل هندسی زیردریایی مورد استفاده در شبیه‌سازی‌های عددی بر اساس پروفیل Myring طراحی شده است. طول کل بدنه زیردریایی ۳ متر، بیشینه قطر بدنه ۲ متر، حجم جابه‌جایی ۶٫۹۷ مترمکعب و جرم کلی بدنه ۶۹۷۳ کیلوگرم در نظر گرفته شد. جریان پیرامون زیردریایی به‌صورت ناپایا و تراکم‌ناپذیر مدل‌سازی شده و برای مدل‌سازی آشفتگی از مدل $k-\epsilon$ استفاده شده است. در راستای محور طولی، محور X در امتداد جریان و از ناحیه پاشنه مدل تعریف شد. دامنه محاسباتی به‌گونه‌ای انتخاب شد که فاصله کافی میان بدنه زیردریایی و مرزهای دامنه وجود داشته باشد و اثر مرزهای مصنوعی بر میدان جریان به حداقل برسد. در امتداد جریان، مرز خروجی از پاشنه مدل در فاصله L_{10} قرار گرفته و به‌صورت Pressure Outlet تعریف شده است که در آن L طول بدنه زیردریایی است. در راستای محور y ، مرزهای بالایی و پایینی دامنه به‌ترتیب در فواصل $L_{2/5}$ و $L_{1/5}$ از مرکز هندسی مدل قرار داده شدند. انتخاب این فواصل با هدف کاهش اثرات مرزهای بالایی و پایینی و جلوگیری از بازتاب فشار به ناحیه مورد بررسی انجام شده است.

با توجه به تقارن هندسی و فیزیکی مسئله نسبت به صفحه مرکزی، تنها نیمه فوقانی دامنه محاسباتی مدل‌سازی شد و صفحه $y=0$ به‌عنوان مرز تقارن (Symmetry) در نظر گرفته شد. استفاده از این شرط تقارن موجب کاهش تعداد المان‌های محاسباتی و در نتیجه کاهش زمان حل، بدون ایجاد تغییر در ساختار فیزیکی مسئله، شده است.

برای تولید شبکه محاسباتی از روش Block-structured mesh با شبکه غالباً هگزاهدری (Hexa-dominant) استفاده شد. توزیع شبکه در ناحیه اطراف بدنه زیردریایی متراکم‌تر در نظر گرفته شد و در نواحی دورتر از بدنه، اندازه سلول‌ها به‌صورت تدریجی افزایش


هدف از به کارگیری مدل های یادگیری ماشین، یادگیری ارتباط غیرخطی میان شرایط ورودی مسئله و پاسخ های دینامیکی حاصل از تحلیل های عددی است.

بر اساس داده های موجود در مطالعه مینا، متغیرهای ورودی شامل پارامترهای مرتبط با شرایط عملیاتی و مشخصات مؤثر بر رفتار هیدرودینامیکی زیردریایی هستند. خروجی های مورد بررسی نیز شامل بیشینه سرعت صعود، بیشینه شتاب قائم، بیشینه زاویه پیچ و دامنه پاسخ قائم زیردریایی در طول فرآیند صعود اضطراری است.

در مرحله آماده سازی داده ها، مجموعه داده استخراج شده از شبیه سازی های عددی برای استفاده در مدل های یادگیری ماشین سازمان دهی شد. به طور کلی، هر نمونه از مجموعه داده شامل مجموعه ای از متغیرهای ورودی و پاسخ های دینامیکی متناظر با آن است. هدف مدل سازی، برآورد پاسخ های دینامیکی برای شرایط جدید بر اساس الگوهای آموخته شده از داده های موجود است.

به منظور نمایش نمونه ای از پاسخ های دینامیکی مورد استفاده در تشکیل مجموعه داده، تغییرات سرعت عمودی زیردریایی در طول فرآیند صعود اضطراری مورد بررسی قرار گرفت. این پاسخ، یکی از شاخص های اصلی توصیف کننده رفتار حرکتی زیردریایی در راستای قائم بوده و تغییرات آن تحت تأثیر شرایط عملیاتی و نیروهای هیدرودینامیکی قرار دارد. نمونه ای از تغییرات سرعت عمودی حاصل از تحلیل عددی در شکل ۲ ارائه شده است.

داده های استخراج شده از پاسخ های دینامیکی مشابه، پس از پردازش و سازمان دهی، به عنوان مبنای آموزش و ارزیابی مدل های یادگیری ماشین مورد استفاده قرار گرفتند. بنابراین، شکل ۲ علاوه بر نمایش رفتار دینامیکی زیردریایی در فرآیند صعود اضطراری، منشأ فیزیکی بخشی از داده های مورد استفاده در مدل سازی یادگیری ماشین را نیز نشان می دهد.



شکل ۲- تغییرات سرعت عمودی زیردریایی در طول فرآیند صعود اضطراری (متر بر ثانیه)

در این پژوهش، سه روش یادگیری ماشین شامل جنگل تصادفی (Random Forest)، XGBoost و شبکه عصبی پرسپترون چندلایه (MLP) برای پیش بینی پاسخ های دینامیکی زیردریایی مورد استفاده قرار گرفتند. هدف از انتخاب این سه روش، مقایسه عملکرد مدل هایی با سازوکارهای متفاوت در یادگیری روابط غیرخطی میان متغیرهای ورودی و پاسخ های دینامیکی حاصل از شبیه سازی های عددی بود. داده های مورد استفاده برای آموزش و ارزیابی هر سه مدل، همان مجموعه داده حاصل از شبیه سازی های عددی این پژوهش است و در این مرحله داده جدیدی به مجموعه داده اضافه نشده است.

جنگل تصادفی (Random Forest) یک روش یادگیری مبتنی بر مجموعه ای از درخت های تصمیم است که در آن چندین درخت به صورت مستقل ایجاد شده و خروجی نهایی از ترکیب پیش بینی درخت ها به دست می آید. هر درخت بخشی از روابط میان متغیرهای ورودی و خروجی را یاد می گیرد و ترکیب چندین درخت موجب کاهش وابستگی پیش بینی نهایی به یک درخت منفرد می شود. این روش قابلیت مناسبی در مدل سازی روابط غیرخطی و تعامل میان متغیرهای ورودی دارد و به دلیل ماهیت درختی، به مقیاس متغیرهای ورودی حساسیت کمتری دارد. با این حال، افزایش تعداد و پیچیدگی درخت ها می تواند هزینه محاسباتی مدل را افزایش دهد و در صورت انتخاب ساختار نامناسب، احتمال بیش برآزش نیز وجود دارد.

XGBoost نیز یک روش مبتنی بر درخت های تصمیم است، اما سازوکار یادگیری آن با جنگل تصادفی متفاوت است. در XGBoost، درخت ها به صورت ترتیبی و در قالب یک فرایند تقویتی ایجاد می شوند؛ به گونه ای که هر مرحله تلاش می کند خطاهای باقی مانده از مراحل قبلی را کاهش دهد. در نتیجه، مجموعه ای از درخت های نسبتاً ساده به صورت تدریجی ترکیب شده و یک مدل پیش بینی کننده قوی ایجاد می کنند. قابلیت مناسب در یادگیری روابط غیرخطی و تعامل میان متغیرها از ویژگی های این روش است. در مقابل، عملکرد XGBoost به انتخاب مناسب پیچیدگی مدل و پارامترهای فرایند آموزش وابسته است و افزایش بیش از حد پیچیدگی مدل می تواند احتمال بیش برآزش را افزایش دهد.

شبکه عصبی پرسپترون چندلایه (MLP) برخلاف دو روش قبلی، یک مدل مبتنی بر شبکه عصبی است که از لایه ورودی، یک یا چند لایه پنهان و لایه خروجی تشکیل می شود. در این ساختار، اطلاعات ورودی از طریق لایه های متوالی پردازش شده و با استفاده از توابع فعال سازی، روابط غیرخطی میان متغیرهای ورودی و خروجی یاد گرفته می شوند. این ویژگی باعث می شود MLP توانایی مناسبی برای تقریب روابط پیچیده و غیرخطی داشته باشد. در مقابل، آموزش این مدل به ساختار شبکه، تنظیم

مدل یادگیری ماشین	R^2	RMSE
شبکه عصبی پرسپترون چندلایه	۰/۹۹۱	۰/۰۳۳

بررسی نتایج جدول ۲ نشان می‌دهد که هر سه مدل مورد بررسی از دقت بالایی در پیش‌بینی پاسخ‌های دینامیکی برخوردار هستند. مقدار ضریب تعیین برای تمامی مدل‌ها بیشتر از ۰/۹۸ و مقدار ریشه میانگین مربعات خطا نیز در محدوده نسبتاً پایینی قرار دارد که نشان‌دهنده توانایی مناسب مدل‌ها در یادگیری روابط موجود در مجموعه داده است.

در میان مدل‌های مورد بررسی، شبکه عصبی پرسپترون چندلایه با مقدار $R^2 = 0.991$ و $RMSE = 0.033$ بهترین عملکرد کلی را نشان می‌دهد. پس از آن، مدل XGBoost با مقدار

$R^2 = 0.987$ و $RMSE = 0.036$ قرار دارد. مدل جنگل تصادفی نیز با وجود عملکرد نسبتاً ضعیف‌تر در مقایسه با دو مدل دیگر، همچنان دقت بالایی داشته و مقادیر $R^2 = 0.982$ و $RMSE = 0.041$ را ارائه می‌دهد.

مقایسه هم‌زمان دو شاخص ارزیابی نشان می‌دهد که ترتیب عملکرد مدل‌ها در هر دو معیار یکسان است. با حرکت از مدل جنگل تصادفی به سمت XGBoost و سپس شبکه عصبی پرسپترون چندلایه، مقدار ضریب تعیین افزایش یافته و مقدار خطای پیش‌بینی کاهش پیدا می‌کند. این روند نشان می‌دهد که مدل MLP در مجموعه داده مورد بررسی توانایی بیشتری در بازنمایی روابط غیرخطی میان متغیرهای ورودی و پاسخ‌های دینامیکی داشته است.

با این حال، اختلاف عملکرد مدل‌ها بسیار زیاد نیست و هر سه روش مقادیر قابل قبولی را ارائه کرده‌اند. بنابراین، نتایج نشان می‌دهد که ساختار داده‌های حاصل از شبیه‌سازی‌های عددی قابلیت مدل‌سازی مناسبی با استفاده از روش‌های مختلف یادگیری ماشین دارد. در عین حال، انتخاب مدل مناسب می‌تواند با توجه به میزان دقت مورد نیاز و پیچیدگی مدل انجام شود.

برای نمایش دیداری نتایج جدول ۲، مقایسه مقادیر ضریب تعیین و ریشه میانگین مربعات خطا می‌تواند در قالب نمودارهای جداگانه ارائه شود. شکل ۳ مقایسه مقادیر ضریب تعیین سه مدل شکل ۴ مقایسه مقادیر ریشه میانگین مربعات خطای آن‌ها را نشان می‌دهد. این نمودارها امکان مشاهده سریع‌تر تفاوت عملکرد مدل‌ها را فراهم می‌کنند.

فرایند آموزش و مقیاس متغیرهای ورودی وابستگی بیشتری دارد و پیچیدگی بیش از حد شبکه می‌تواند موجب بیش‌برازش شود. تفاوت اصلی سه روش مورد استفاده در سازوکار یادگیری آن‌هاست Random Forest، با ترکیب چندین درخت تصمیم، XGBoost با تقویت ترتیبی درخت‌های تصمیم و MLP با استفاده از لایه‌های متوالی شبکه عصبی، روابط میان شرایط ورودی و پاسخ‌های دینامیکی را یاد می‌گیرند. بنابراین، استفاده هم‌زمان از این سه روش امکان مقایسه یک رویکرد مبتنی بر ترکیب درخت‌ها، یک رویکرد تقویتی مبتنی بر درخت‌ها و یک رویکرد مبتنی بر شبکه عصبی را برای مسئله مورد مطالعه فراهم می‌کند.

پس از آماده‌سازی مجموعه داده، داده‌ها به بخش‌های مورد نیاز برای آموزش و ارزیابی تقسیم شدند. هر سه مدل با استفاده از داده‌های آموزشی توسعه داده شدند و عملکرد آن‌ها بر روی داده‌های ارزیابی بررسی شد. برای مقایسه عملکرد مدل‌ها از معیارهای ضریب تعیین (R^2) و ریشه میانگین مربعات خطا (RMSE) استفاده شد. بنابراین، مقایسه مدل‌ها بر اساس یک مجموعه داده و یک مسئله پیش‌بینی یکسان انجام گرفت و تفاوت مشاهده شده در عملکرد، به سازوکار یادگیری و قابلیت هر مدل در بازنمایی روابط موجود در داده‌ها مربوط می‌شود.

۴ - ارزیابی و مقایسه عملکرد مدل‌ها

پس از توسعه و آموزش مدل‌های یادگیری ماشین، عملکرد آن‌ها در پیش‌بینی پاسخ‌های دینامیکی زیردریایی مورد ارزیابی قرار گرفت. در این پژوهش، سه روش یادگیری ماشین شامل جنگل تصادفی، XGBoost و شبکه عصبی پرسپترون چندلایه مورد بررسی قرار گرفتند. هدف از این مقایسه، ارزیابی توانایی مدل‌های مختلف در یادگیری روابط میان پارامترهای ورودی و پاسخ‌های دینامیکی حاصل از شبیه‌سازی‌های عددی بود.

برای ارزیابی عملکرد مدل‌ها، از دو شاخص ضریب تعیین و ریشه میانگین مربعات خطا استفاده شد. مقدار بیشتر ضریب تعیین بیانگر توانایی بیشتر مدل در توضیح تغییرات داده‌ها بوده و مقدار کمتر ریشه میانگین مربعات خطا نشان‌دهنده دقت بالاتر پیش‌بینی است.

نتایج حاصل از ارزیابی مدل‌ها در جدول ۲ ارائه شده است.

جدول ۲- مقایسه عملکرد مدل‌های یادگیری ماشین در پیش‌بینی پاسخ‌های دینامیکی

مدل یادگیری ماشین	R^2	RMSE
جنگل تصادفی	۰/۹۸۲	۰/۰۴۱
XGBoost	۰/۹۸۷	۰/۰۳۶

تصادفی نیز با وجود قرار گرفتن در رتبه سوم، مقادیر قابل قبولی از شاخص‌های ارزیابی را ارائه کرده است.

این نتایج نشان می‌دهد که رابطه میان متغیرهای ورودی و پاسخ‌های دینامیکی زیردریایی دارای ماهیتی غیرخطی است و مدل‌های مورد بررسی توانایی مناسبی در یادگیری این روابط دارند. برتری نسبی مدل MLP می‌تواند بیانگر توانایی بیشتر ساختار شبکه عصبی در بازنمایی الگوهای پیچیده موجود در داده‌های حاصل از شبیه‌سازی عددی باشد. در مقابل، عملکرد نزدیک XGBoost به مدل MLP نشان می‌دهد که روش‌های مبتنی بر درخت تقویتی نیز می‌توانند با دقت مناسبی برای این نوع مسائل مورد استفاده قرار گیرند.


با توجه به اختلاف نسبتاً محدود میان شاخص‌های عملکرد، انتخاب نهایی مدل نباید تنها بر اساس بیشترین مقدار R^2 انجام شود. عواملی مانند پیچیدگی مدل، سهولت آموزش و کاربرد مورد نظر نیز می‌توانند در انتخاب روش مناسب مؤثر باشند. بر این اساس، در شرایطی که هدف دستیابی به بیشترین دقت پیش‌بینی باشد، مدل MLP گزینه مناسب‌تری در میان مدل‌های بررسی‌شده است. از سوی دیگر، مدل XGBoost نیز با توجه به عملکرد نزدیک به MLP، می‌تواند به‌عنوان یک گزینه رقابتی برای مدل‌سازی پاسخ‌های دینامیکی مورد استفاده قرار گیرد.

در مجموع، مقایسه انجام‌شده نشان می‌دهد که استفاده از مدل‌های یادگیری ماشین می‌تواند فرآیند پیش‌بینی پاسخ‌های دینامیکی زیردریایی را بر اساس داده‌های حاصل از تحلیل‌های عددی تسهیل کند. نتایج همچنین نشان می‌دهد که انتخاب مدل مناسب باید با توجه به عملکرد پیش‌بینی و ویژگی‌های کاربردی مدل انجام شود و لزوماً یک روش واحد برای تمامی شرایط و کاربردها بهترین گزینه نخواهد بود.


۶ - نتیجه‌گیری

در این پژوهش، قابلیت سه مدل یادگیری ماشین شامل جنگل تصادفی، XGBoost و شبکه عصبی پرسپترون چندلایه در پیش‌بینی پاسخ‌های دینامیکی زیردریایی تحقیقاتی کوچک در شرایط صعود اضطراری مورد بررسی قرار گرفت. داده‌های مورد استفاده برای توسعه مدل‌ها از نتایج شبیه‌سازی‌های عددی استخراج شدند و عملکرد مدل‌ها با استفاده از شاخص‌های ضریب تعیین و ریشه میانگین مربعات خطا ارزیابی شد.

نتایج نشان داد که هر سه مدل مورد بررسی توانایی مناسبی در یادگیری و پیش‌بینی روابط میان متغیرهای ورودی و پاسخ‌های دینامیکی دارند. مقادیر ضریب تعیین برای هر سه مدل بیشتر از ۰.۹۸ بود که بیانگر دقت بالای روش‌های مورد استفاده در بازنمایی داده‌های حاصل از شبیه‌سازی‌های عددی است. همچنین، مقایسه مقادیر ریشه میانگین مربعات خطا نشان داد که اختلاف



شکل ۳- مقایسه ضریب تعیین مدل‌های یادگیری ماشین



شکل ۴- مقایسه ریشه میانگین مربعات خطای مدل‌های یادگیری ماشین

در مجموع، نتایج این بخش نشان می‌دهد که هر سه مدل یادگیری ماشین توانایی بالایی در پیش‌بینی پاسخ‌های دینامیکی مورد بررسی دارند، اما شبکه عصبی پرسپترون چندلایه بر اساس هر دو معیار ارزیابی، بهترین عملکرد کلی را ارائه کرده است. مدل XGBoost نیز با اختلاف اندکی در رتبه بعدی قرار دارد و جنگل تصادفی، با وجود داشتن بیشترین مقدار خطا در میان مدل‌های بررسی‌شده، همچنان از دقت قابل قبولی برخوردار است. این نتایج مبنایی برای تحلیل دقیق‌تر قابلیت پیش‌بینی مدل‌ها و بررسی انتخاب مدل مناسب در بخش بعدی فراهم می‌کند.

۵ - تحلیل قابلیت پیش‌بینی و انتخاب مدل مناسب

نتایج ارائه‌شده در بخش قبل نشان داد که هر سه مدل یادگیری ماشین مورد بررسی، توانایی مناسبی در پیش‌بینی پاسخ‌های دینامیکی حاصل از شبیه‌سازی‌های عددی دارند. با این حال، مقایسه شاخص‌های عملکرد نشان می‌دهد که انتخاب مدل مناسب می‌تواند بر دقت نهایی پیش‌بینی تأثیرگذار باشد.

بر اساس نتایج جدول ۲، شبکه عصبی پرسپترون چندلایه با دستیابی به بیشترین مقدار ضریب تعیین و کمترین مقدار ریشه میانگین مربعات خطا، بهترین عملکرد کلی را در میان مدل‌های مورد بررسی ارائه کرده است. پس از آن، مدل XGBoost قرار دارد که اختلاف عملکرد آن با مدل MLP محدود بوده و همچنان دقت بالایی در پیش‌بینی پاسخ‌ها نشان می‌دهد. مدل جنگل

۱۰ - مراجع

1- Hou, Y., Duan, F., Zhu, W., Li, H., Shen, S., Shen, X., Wang, J., Huang, Y., Wei, W., Liu, X. and Liu, L., (2024), *Time-sequenced hydrodynamics prediction system for underwater vehicles based on AI edge computing*, Ocean Engineering, Vol. 294, 116797. <https://doi.org/10.1016/j.oceaneng.2024.116797>

2- Hong, L., Wang, X. and Zhang, D.-S., (2024), *CFD-based hydrodynamic performance investigation of autonomous underwater vehicles: A survey*, Ocean Engineering, Vol. 305, 117911. <https://doi.org/10.1016/j.oceaneng.2024.117911>

3- Chen, T., Fu, C., Zang, Z., Zhang, Q. and Li, J., (2026), *Numerical investigations on the kinematic response of a submarine during emergency ascent subject to internal solitary waves*, Ocean Engineering, Vol. 343, 123351. <https://doi.org/10.1016/j.oceaneng.2025.123351>

4- Xiang, G., Ou, Y., Chen, J., Wang, W. and Wu, H., (2024), *A study on the influence of unsteady forces on the roll characteristics of a submarine during free ascent from great depth*, Journal of Marine Science and Engineering, Vol. 12, 757. <https://doi.org/10.3390/jmse12050757>

5- Palaniappan, M., Jyothi, V.B.N., Chowdhury, T., et al., (2024), *A method for evaluating safety reliability of descend/ascent drop-weight system and mission abort decision for deep-ocean scientific human submersibles*, Scientific Reports, Vol. 14, 19266. <https://doi.org/10.1038/s41598-024-70158-3>

6- Lee, J., Kim, S., Shin, J., Yoon, J., Ahn, J. and Kim, M., (2025), *Experiment and modeling of submarine emergency rising motion using free-running model*, International Journal of Naval Architecture and Ocean Engineering, Vol. 17, 100641. <https://doi.org/10.1016/j.ijnaoe.2024.100641>

7- Valentinis, F. and Woolsey, C., (2019), *Nonlinear control of a subscale submarine in emergency ascent*, Ocean Engineering, Vol. 171, p. 646-662. <https://doi.org/10.1016/j.oceaneng.2018.11.029>

8- Walker, J.M., Coraddu, A. and Oneto, L., (2024), *A review on shape optimization of hulls and airfoils leveraging Computational Fluid Dynamics data-driven surrogate models*, Ocean Engineering, Vol. 312, Part 3, 119263. <https://doi.org/10.1016/j.oceaneng.2024.119263>

عملکرد مدل‌ها محدود بوده، اما مدل‌های مختلف از نظر دقت پیش‌بینی دارای تفاوت قابل مشاهده‌ای هستند.

در میان مدل‌های بررسی‌شده، شبکه عصبی پرسپترون چندلایه با مقدار $R^2 = 0.991$ و مقدار $RMSE=0.033$ بهترین عملکرد کلی را ارائه کرد. پس از آن، مدل XGBoost با مقدار $R^2 = 0.987$ و مقدار $RMSE=0.036$ قرار گرفت. مدل جنگل تصادفی نیز با مقدار $R^2 = 0.982$ و مقدار $RMSE=0.041$ وجود قرار گرفتن در رتبه سوم، همچنان عملکرد قابل قبولی از خود نشان داد.

بر اساس نتایج، استفاده از مدل‌های یادگیری ماشین می‌تواند به عنوان روشی مؤثر برای پیش‌بینی پاسخ‌های دینامیکی حاصل از تحلیل‌های عددی مورد استفاده قرار گیرد و نیاز به انجام مکرر شبیه‌سازی‌های محاسباتی را کاهش دهد. همچنین، نتایج نشان داد که انتخاب مدل مناسب می‌تواند بر دقت پیش‌بینی تأثیرگذار باشد و در مجموعه داده مورد بررسی، مدل MLP بهترین عملکرد کلی را ارائه کرده است.

در مجموع، یافته‌های این پژوهش نشان می‌دهد که ترکیب داده‌های حاصل از شبیه‌سازی CFD با روش‌های یادگیری ماشین می‌تواند چارچوب مناسبی برای پیش‌بینی سریع‌تر رفتار دینامیکی زیردریایی در شرایط صعود اضطراری فراهم کند. توسعه این رویکرد با استفاده از مجموعه داده‌های گسترده‌تر و بررسی شرایط عملیاتی متنوع‌تر می‌تواند زمینه استفاده از مدل‌های یادگیری ماشین را در تحلیل و ارزیابی سامانه‌های زیرسطحی گسترش دهد.

۷ - مشارکت نویسندگان

عارف جعفری: ایده‌پردازی و طراحی پژوهش، انجام شبیه‌سازی‌ها و تحلیل‌های عددی، تهیه و پردازش داده‌ها، توسعه و ارزیابی مدل‌های یادگیری ماشین، تحلیل و تفسیر نتایج، نگارش پیش‌نویس اولیه مقاله و اعمال اصلاحات.

مجید عباسپور: راهنمایی و نظارت علمی بر پژوهش، مشارکت در تدوین چارچوب پژوهش، بررسی و تفسیر علمی نتایج، بازبینی و اصلاح محتوای علمی مقاله و تأیید نسخه نهایی. تمامی نویسندگان نسخه نهایی مقاله را مطالعه و تأیید کرده‌اند.

۸ - بیانیه دسترسی به داده‌ها

داده‌های پشتیبان نتایج این پژوهش از طریق نویسندگان مسئول و با درخواست معقول در دسترس خواهند بود.

۹ - بیانیه ناشر

هرگونه دیدگاه و اطلاعات بیان‌شده در این نشریه متعلق به نویسندگان است و لزوماً دیدگاه‌های ناشر را منعکس نمی‌کند.

- 9- Maric, T., Fadeli, M.E., Rigazzi, A., et al., (2025), *Combining machine learning with computational fluid dynamics using OpenFOAM and SmartSim*, Meccanica, Vol. 60, p. 1831-1850. <https://doi.org/10.1007/s11012-024-01797-z>
- 10- Dong, Y., Du, L. and Li, G., (2025), *Hybrid Ship Design Optimization Framework Integrating a Dual-Mode CFD-Surrogate Mechanism*, Applied Sciences, Vol. 15, No. 19, 10318. <https://doi.org/10.3390/app151910318>
- 11- Rojas Cala, E.F., Béjar, R., Mateu, C., Borri, E. and Cabeza, L.F., (2025), *Artificial Intelligence Applied to Computational Fluid Dynamics and Its Application in Thermal Energy Storage: A Bibliometric Analysis*, Applied Sciences, Vol. 15, No. 13, 7199. <https://doi.org/10.3390/app15137199>
- 12- Chen, T., Li, R., Hu, X., Zhang, B., Liu, Y., Wang, L. and Gao, N., (2025), *Machine learning as CFD surrogate models for rapid prediction of building-related physical fields: A review of methods and state-of-the-art*, Building and Environment, Vol. 285, Part B, 113667. <https://doi.org/10.1016/j.buildenv.2025.113667>