

تخمین نیروی پیشران در پیشرانه گاز سرد با استفاده از شبکه عصبی چندلایه بهینه شده با الگوریتم ژنتیک

هادی محمدیان خلف انصار

دکتری، دانشگاه سراسری تبریز، دانشکده مهندسی مکانیک، تبریز، ایران

جعفر کیقبادی

استاد، دانشگاه سراسری تبریز، دانشکده مهندسی مکانیک، تبریز، ایران

مرتضی فرهید*

استادیار، پژوهشگاه فضایی ایران، پژوهشکده رانشگرهای فضایی، تبریز، ایران

چکیده

این مقاله یک مدل داده‌محور برای تخمین دقیق پیشرانش تولیدشده توسط پیشرانه گاز سرد ارائه می‌دهد. داده‌های تجربی مورد استفاده از پایگاه **Zenodo** استخراج شده و برای آموزش و ارزیابی مدل به کار رفته‌اند. مدل پیشنهادی با استفاده از یک پرسپترون چندلایه (**MLP**) و بهینه‌سازی وزن‌ها و بایاس‌های شبکه به کمک الگوریتم ژنتیک (**GA**)، رابطه بین توان الکتریکی (P_e)، دبی جریان جرمی پیشران ($\dot{m}$) و بازده پیشران (η) را به پیشرانش خروجی (F) نگاشت می‌کند. معیار بهینه‌سازی در الگوریتم ژنتیک، خطای مربعات میانگین (**MSE**) داده‌های اعتبارسنجی بود. پیاده‌سازی و آزمایش‌ها با زبان پایتون انجام شده‌اند. با استفاده از یک مجموعه‌داده متشکل از ۲۰۰۰ نمونه، مدل پیشنهادی **GA-MLP** به مقادیر $MSE=0.05$ اعتبارسنجی و $MSE=0.1$ آزمون و ضریب همبستگی $R \approx 0.872$ دست یافت. علاوه بر این، یک تحلیل حساسیت و مقایسه با یک شبکه آموزش‌دیده با روش کاهش گرادین استاندارد ارائه شده است. مقایسه‌های انجام‌شده با مدل‌های پایه‌ای یادگیری ماشین شامل جنگل تصادفی و **XGBoost** برتری چشمگیر مدل پیشنهادی را از نظر دقت تخمین و همبستگی با داده‌های واقعی نشان می‌دهد.

واژه‌های کلیدی: پیشرانه گاز سرد، پیش‌بینی نیروی پیشران، شبکه عصبی چندلایه (**MLP**)، الگوریتم ژنتیک، بهینه‌سازی، ضربه ویژه.

Estimation of thrust in a cold gas thruster using a multilayer perceptron with optimized weights by a genetic algorithm

Hadi Mohammadian KhalafAnsar

PhD, Faculty of Mechanical Engineering, University of Tabriz, Tabriz, Iran

Jafar Keighobadi

Professor, Faculty of Mechanical Engineering, University of Tabriz, Tabriz, Iran

Morteza Farhid*

Assistant professor, Iranian Space Research Center, Tabriz, Iran

Abstract

This paper presents a data-driven model for accurate estimation of thrust produced by a cold gas propulsion. The utilized experimental data are extracted from the Zenodo repository and used for training and evaluation of the model. The proposed model maps the relationship between electric power (P_e), engine mass flow ($\dot{m}$) and thrust-to-power efficiency (η) to output thrust (F) using a multilayer perceptron (MLP) and optimizes the network weights and biases using a genetic algorithm (GA). The optimization criterion in the genetic algorithm was the mean square error (MSE) of the validation data. The implementation and experiments were performed in Python. Using a dataset consisting of 2000 samples, the proposed GA-MLP model achieved validation $MSE = 0.05$ and test $MSE = 0.1$, and a correlation coefficient of $R \approx 0.872$. Furthermore, comparisons with basic machine learning models including Random Forest and XGBoost show the significant superiority of the proposed model in terms of estimation accuracy and correlation with real data. A sensitivity analysis and comparison with a network trained with standard gradient descent method are also presented.

Keywords: Cold gas thruster; Thrust prediction; Multilayer Perceptron (MLP); Genetic Algorithm; Optimization; Specific impulse (Isp).

۱- مقدمه

متنوع و در حضور تغییرات شار جرمی و فشار مخزن به چالشی تبدیل شده است [۱]. در سال‌های اخیر، شاهد تغییرات عمده‌ای در استفاده از الگوریتم‌های هوشمند، به‌ویژه یادگیری ماشین (**ML**) و هوش مصنوعی (**AI**) برای بهبود تخمین نیروی پیشران و بهینه‌سازی عملکرد کلی این سیستم‌ها هستیم. روش‌های سنتی برآورد نیروی پیشران معمولاً بر الگوسازی فیزیکی و آزمون‌های تجربی تکیه دارند که می‌تواند منابع زیادی را مصرف کند و زمان‌بر باشد. این روش‌ها اغلب قادر به الگوسازی نوسان‌ها و عدم قطعیت‌های موجود در شرایط عملیاتی نیستند [۱-۲]. با این حال، گسترش الگوریتم‌های هوشمند، برآورد نیروی پیشران را کارآمدتر، سریع‌تر و به‌صورت انطباق‌پذیر ممکن ساخته

پیشران‌های گاز سرد به‌عنوان فن‌آوری بنیادین در کاوش‌های فضایی، مانور ماهواره‌ها و مأموریت‌های درازمدت شناخته شده‌اند. این سامانه‌ها به‌خاطر سادگی ساخت، قابلیت اطمینان بالا و هزینه عملیاتی کم اهمیت زیادی دارند. سامانه‌های پیشرانه گاز سرد با تخلیه گاز فشرده از طریق نازل و ایجاد شتاب به جریان جرمی خروجی موجب تولید نیروی رانش می‌شوند. برآورد دقیق نیروی پیشران در این سیستم‌ها برای اطمینان از کنترل دقیق مسیر و موفقیت کلی مأموریت ضروری است. تخمین نیروی پیشران در زیست‌بوم‌های عملیاتی

است. یکی از روش‌های شاخص برای الگوسازی نیروی پیشران در سامانه‌های پیشران گاز سرد، استفاده از شبکه‌های عصبی مصنوعی (ANN) است. این شبکه‌ها به دلیل توانایی‌شان در تقریب‌زدن روابط پیچیده و غیرخطی بین پارامترهای ورودی مانند فشار مخزن، شار جرمی و ویژگی‌های نازل و نیروی پیشران برآمده، به‌ویژه کارا هستند [۳-۴]. از این شبکه‌ها به‌طور موفقیت‌آمیز برای پیش‌بینی نیروی پیشران در پیشران‌های اثر هال [۵-۶] و حتی پیش‌بینی مصرف انرژی حرکتی در کشتی مجهز به سامانه پیشران [۷] استفاده شده است.

یکی دیگر از راهبردهای مهم که مورد توجه قرار گرفته، ماشین‌های پشتیبان بردار (SVM) هستند که برای مدل‌سازی فضاهای بعدی و داده‌های غیرخطی مناسب هستند [۸-۹]. این الگوریتم‌ها برای سامانه‌هایی همچون پیشران‌های گاز سرد که روابط ورودی-خروجی آن‌ها می‌تواند غیرخطی باشد، بسیار مناسب هستند. مدل‌های مبتنی بر SVM به‌طور موثری برای برآورد نیروی پیشران در پیشران‌های هال و پیشران‌های یونی نیز استفاده شده‌اند، که در آن نیروی پیشران تحت تاثیر عواملی مانند ولتاژ کارکرد، آهنگ جریان و بازده یونش قرار دارد [۱۰].

الگوهای آمیخته که ترکیبی از چندین فنّ یادگیری ماشین برای بهبود دقت پیش‌بینی‌ها هستند، نیز برای برآورد نیروی پیشران مورد بررسی و مطالعه قرار گرفته‌اند. این رویکردها معمولاً شبکه‌های عصبی را با الگوریتم‌های بهینه‌سازی همچون الگوریتم‌های ژنتیک (GA) [۱۲-۱۳]، بهینه‌سازی گروه ذرات (PSO) [۱۴-۱۵] و سیستم‌های منطق فازی [۱۶] درمی‌آمیزند. این فناوری‌ها امکان تنظیم دقیق پارامترهای الگو و افزایش دقت پیش‌بینی نیروی پیشران را فراهم می‌سازند؛ درحالی‌که هزینه‌های رایانشی کاهش می‌یابند. برای نمونه، در پژوهشی از رویکردی برای بهینه‌سازی الگوریتم ژنتیک برای بهینه‌سازی آرایش پیشران توزیع‌شده استفاده شد که بر آن است تا نیروی برآر، بازده پیشران و بازده آیرودینامیکی را به‌حداکثر برساند [۱۳].

در حوزه پیشران‌های گاز سرد، تمرکز پژوهش‌ها بیشتر بر سنجش دقیق فشار مخزن، شار جرمی و شرایط نازل بوده است. تلفیق داده‌های این حسگرها با الگوریتم‌های یادگیری ماشین، امکان بهبود پیش‌بینی نیروی پیشران و عیب‌یابی به‌هنگام افت کارایی سیستم را فراهم می‌کند. استفاده از یادگیری ژرف و یادگیری تقویتی (RL) در سامانه‌های پیشران به دلیل توانایی الگوسازی رفتارهای پیچیده و وابسته به زمان، توجه شایانی را به خود جلب کرده است. یادگیری تقویتی ژرف به‌ویژه در سازگارسازی سامانه‌های پیشران به شرایط محیطی در حال تغییر، با یادگیری پیوسته از بازخوردهای عملیاتی، شواهد امیدوارکننده‌ای نشان داده است [۱۷-۱۸]. این الگوها قادر به فراگیری راهبردهای بهینه کنترل برای پیشران‌های فضایی به‌صورت برخط هستند که برای مأموریت‌های نیازمند مدیریت انطباقی نیروی پیشران، مانند پایداری مدار ماهواره‌ها و کاوش فضایی ژرف، بسیار سودمند است [۱۹-۲۰].

علاوه بر این، توجه بسیاری به کاربرد روش‌های یادگیری گروهی مانند جنگل تصادفی (RF) و ماشین‌های تقویت گرادیان (GBM) برای بهبود پایداری مدل‌های برآورد نیروی پیشران معطوف شده است. این فنون پیش‌بینی‌های چندین مدل ضعیف‌تر را تلفیق می‌کنند تا پیش‌بینی دقیق‌تر و تعمیم‌پذیرتری از نیروی پیشران ارائه دهند [۲۱-۲۲]. RF و GBM برای پیش‌بینی نیروی پیشران در پیشران‌های هال نیز به‌کار رفته‌اند و دقت پیش‌بینی را در مواردی که پراکندگی داده‌ها زیاد است، بهبود بخشیده و کارایی سامانه را در شرایط گوناگون عملیاتی تضمین کرده‌اند.

به‌کارگیری فناوری حسگرهای پیشرفته و سامانه‌های گردآوری داده‌های برخط، روند استفاده از الگوریتم‌های هوشمند در سیستم‌های پیشران گاز سرد را شتاب بخشیده است. حسگرهایی که متغیرهایی مانند فشار مخزن، شار جرمی و وضعیت نازل را اندازه‌گیری می‌کنند، در کنار مدل‌های یادگیری ماشین، امکان نظارت دقیق و بیدرنگ بر تولید نیروی پیشران را فراهم می‌آورند. این حسگرها به پیشران‌ها کمک می‌کنند تا به شرایط بهینه کارکرد

دست یابند و از کاهش کارایی سامانه جلوگیری کنند. برای اندازه‌گیری دمای اجزای گوناگون سامانه پیشران از حسگرهای دما مانند آشکارسازهای دمایی مقاومتی (RTD) و ترموکوپل استفاده می‌شود. این حسگرها قادر به اندازه‌گیری دقیق دما در حوزه‌های گوناگون پیشران هستند که برای حفظ کارکرد بهینه و جلوگیری از آسیب‌های گرمایی بسیار مهم هستند [۲۳]. فشار در سامانه‌های پیشران به خصوص در فرآیندهای گاز یونیده (پلاسما) اهمیت بالایی دارد. برای اندازه‌گیری فشار، حسگرهای فشار پیزوالکتریک و حسگرهای فشار خازنی کاربرد گسترده‌ای دارند. این حسگرها قادر به اندازه‌گیری دقیق فشار در سامانه‌های بسته و پیشران‌های فضایی هستند [۲۴]. اندازه‌گیری چگالی یون نیز در پیشران‌های یونی و اثر هال، معمولاً توسط پروب لانگمور، محفظه‌های یونی و پروب‌های پلاسما انجام می‌شود. این حسگرها قادر به اندازه‌گیری چگالی یون‌ها و ویژگی‌های پلاسما هستند و داده‌های دقیق و سودمندی درباره وضعیت پلاسما و میزان تراکم یون‌ها ارائه می‌دهند [۲۵-۲۶]. این حسگرها به‌طور مستقیم به بهبود دقت پیش‌بینی نیروی پیشران و بهینه‌سازی کارایی سامانه‌های پیشران گاز سرد کمک می‌کنند. به‌کارگیری این حسگرها در ترکیبی با مدل‌های یادگیری ماشین، امکان پایش دقیق کارایی پیشران‌ها و شبیه‌سازی شرایط بهینه بهره‌برداری را فراهم می‌آورد. سرانجام، با وجود دستاوردهای یادگیری ماشین در برآورد نیروی پیشران، هنوز چالش‌هایی همچون کمبود داده‌های آزمایشگاهی معتبر، نویز در اندازه‌گیری فشار و شار، و شرایط عملیاتی گوناگون وجود دارد. با این حال، پیشرفت پایایی روش‌های هوش مصنوعی و یادگیری ماشین، توانایی بالایی برای بهبود برآورد نیروی رانش و بهینه‌سازی سامانه‌های پیشران گاز سرد در کاربردهای فضایی دارد [۲۶-۲۸]. همزمان با پیشرفت فناوری‌های پیشران گاز سرد و پیچیده‌تر شدن مأموریت‌های فضایی، نیاز به برآوردهای دقیق‌تر و برخط از نیروی پیشران، پیوسته در حال افزایش است. به‌کارگیری الگوریتم‌های هوشمند برای رفع این چالش، گامی بلند به سوی پدیدآوری سامانه‌های پیشران بهینه‌تر، انعطاف‌پذیرتر و پایاتر برای مأموریت‌های فضایی آینده به شمار می‌رود.

این پژوهش با هدف بهبود کارایی پیشران‌های گاز سرد و پیش‌بینی دقیق‌تر نیروی پیشران، به بهره‌گیری از الگوریتم‌های هوش مصنوعی و یادگیری ماشین پرداخته است. در این مقاله الگوریتم ژنتیک برای بهینه کردن وزن‌ها و بایاس‌های شبکه MLP استفاده شده است. از سویی این مجموعه عصبی بر روی داده‌های واقعی که دارای نویز زیاد هستند، اعمال شده است و در واقع این مقاله به قصد ارائه روشی مقاوم و بهینه برای محیط‌های واقعی که در آن روش‌های کلاسیک به دلیل نویز حاصل از سنسورها، نشتی داده‌های سنسورهای مختلف با مشکلاتی اعم از ناپایداری، واگرایی و نیز گیر کردن در کمینه‌های محلی روبرو هستند، نوشته شده است. انتخاب شبکه عصبی چندلایه (MLP) همراه با بهینه‌سازی الگوریتم ژنتیک (GA) بر اساس سه عامل کلیدی است: (۱) قابلیت تقریب جهانی MLP برای روابط ورودی-خروجی غیرخطی ذاتی در پیشران‌های گاز سرد، (۲) توانایی جستجوی جهانی GA که از همگرایی به مینیمم‌های محلی جلوگیری می‌کند - که یک مسئله رایج در روش‌های مبتنی بر گرادیان در داده‌های دنیای واقعی نویزدار است، و (۳) مزیت هماهنگی که GA می‌تواند فضای وزن‌های چندبعدی را به‌طور موثرتری نسبت به روش‌های بهینه‌سازی محلی کاوش کند زمانی که نویز سنسور اطلاعات گرادیان را خراب می‌کند.

مزایای روش پیشنهادی به شرح زیر است:

- ۱- دقت بالا در پیش‌بینی نیروی پیشران: مقدار میانگین مربعات خطا (MSE) در حدود ۰/۱، حاکی از صحت بالای مدل در پیش‌بینی نیروی پیشران است و گویای توانمندی آن در شبیه‌سازی دقیق رابطه بین متغیرهای ورودی و نیروی پیشران خروجی است.
- ۲- بهبود چشمگیر صحت پیش‌بینی در قیاس با مدل‌های کلاسیک: در مقایسه با مدل‌های کلاسیک که از روش ژنتیکی بهره نبرده‌اند (MSE) در حدود ۰/۴، صحت پیش‌بینی با به‌کارگیری روش پیشنهادی، بهبودی ملموس

یافته است.

۳- همخوانی چشمگیر برآوردهای مدل با مقادیر واقعی: ضریب همبستگی ۰/۸۵ بر روی داده‌های آزمون، همخوانی چشمگیر برآوردهای مدل با مقادیر واقعی نیروی رانش را تصدیق می‌کند.

۲- مدل‌سازی

برای برآورد نیروی پیشران تولیدشده توسط یک سامانه‌ی پیشرانه‌ی گاز سرد (مانند موتورهای موشکی یا سامانه‌های همانند)، معمولاً از رابطه‌های ترمودینامیکی و مکانیکی استفاده می‌شود که به عوامل مختلفی مانند سرعت خروجی گاز، جرم گاز، دمای گاز، و ویژگی‌های سامانه‌ی پیشران وابسته است. یکی از پرکاربردترین رابطه‌ها برای محاسبه نیروی پیشران بر پایه‌ی قانون پایستگی اندازه‌ی حرکت و نیروی فشار استوار است. رابطه کلی نیروی پیشران برای سیستم پیشران گاز سرد عبارتست از [۲۶]:

$$F = \dot{m}v_e + (p_e - p_0)A_e \quad (۱)$$

که در آن F نیروی پیشران تولید شده (N) ، $\dot{m}$ نرخ جریان جرمی (kg/s) که نشان‌دهنده مقدار گاز یا سوختی است که از سیستم خارج می‌شود، v_e سرعت خروجی گاز از سیستم (m/s) ، p_e فشار در خروجی نازل (Pa) ، p_0 فشار محیط (Pa) که معمولاً برابر با فشار اتمسفری است و A_e مساحت مقطع خروجی نازل (m^2) است.

سرعت خروجی گاز معمولاً از روابط ترمودینامیکی با استفاده از انرژی گاز داغ محاسبه می‌شود. یکی از روابط پرکاربرد برای سرعت خروجی به شکل زیر است:

$$v_e = \sqrt{2 \cdot \eta \cdot C_p \cdot (T_0 - T_e)} \quad (۲)$$

که در آن η بازده سیستم، C_p ظرفیت حرارتی مخصوص گاز $(J/kg \cdot K)$ ، T_0 دمای اولیه گاز (K) و T_e دمای گاز در خروجی نازل (K) است.

در عمل، ممکن است عوامل دیگری مانند بازدهی سامانه پیشران (که می‌تواند به صورت تابعی از دما، فشار، و نوع سوخت باشد)، گازهای گوناگون (با توجه به ویژگی‌های ترمودینامیکی گاز)، اثرهای زیست‌بومی (که در شرایط مختلف محیطی می‌تواند تغییر کند) نیز برای محاسبه نیروی پیشران در نظر گرفته شوند. برای یک مدل دقیق‌تر، ممکن است نیاز به بهره‌گیری از شبیه‌سازی‌های رایانه‌ای (مانند دینامیک سیالات محاسباتی) یا داده‌های تجربی داشته باشید.

برای دقت‌بخشی بیشتر فرمول (۱)، به‌ویژه در موقعیت‌های پیچیده، نیاز به به‌کارگیری الگوهای پیشرفته‌تر همچون الگوهای ترمودینامیکی و شبیه‌سازی‌های عددی خواهیم داشت.

بر اساس مدل‌سازی ترمودینامیکی ارائه‌شده در [۲۶]، می‌توان توان ورودی پیشران را از تعادل انرژی در محفظه داغ به‌دست آورد. ابتدا توان حرارتی در دسترس پیشران طبق رابطه‌ی

$$\eta_t P_e = \dot{m} C_p T_c \quad (۳)$$

به دمای محفظه T_c تبدیل می‌شود. با جایگذاری این دما در معادله نیروی پیشران

$$F = \dot{m} C_F \sqrt{\gamma R T_c} \quad (۴)$$

فرمول کلی پیشران به‌صورت زیر بازنویسی می‌گردد:

$$F = \dot{m} C_F \sqrt{\gamma R \times \frac{\eta_t P_e}{\dot{m} C_p}} \quad (۵)$$

پس از ساده‌سازی جبری، رابطه کلی به شکل

$$F = \sqrt{\eta_t P_e \dot{m} \times \frac{C_F^2 \gamma R}{C_p}} \quad (۶)$$

درمی‌آید. با توجه به این‌که برای بسیاری از سامانه‌های پیشران گاز سرد

مقدار $C_2 \approx \frac{C_F^2 \gamma R}{C_p}$ در نظر گرفته می‌شود، معادله نهایی نیروی پیشران به شکل ساده‌شده زیر قابل بیان است:

$$F_F = \eta_t \sqrt{C_2 P_e \dot{m}} \quad (۷)$$

جدول ۱ مقادیر خام ورودی/خروجی مورد استفاده در تحلیل مقاله را نشان می‌دهد. مجموعه داده‌های مورد استفاده در این مطالعه از مخزن دسترسی آزاد موجود در Zenodo (DOI: 10.5281/zenodo.7765215) با عنوان «رتبه‌بندی و داده‌های عملکرد پیشران‌های گاز سرد/گرم» گرفته شده است. این مجموعه داده‌ها مستقیماً با مقاله داوری‌شده [۲۶] مرتبط است. این مجموعه داده‌ها، نزدیک به ۵۰۰۰ پیشران بالقوه، شامل مواد آلی و معدنی در فازهای مختلف (جامد، مایع، گازی یا چندفازی) را در شرایط محیطی ارزیابی می‌کند. این پیشران‌ها برای خروج در سیستم‌های پیشران گازی سرد/گرم تا حالت گازی خالص گرم می‌شوند. جمع‌آوری داده‌ها شامل یک بررسی سیستماتیک از خواص پیشران از پایگاه‌های داده شیمیایی معتبر (مانند NIST Chemistry WebBook یا مخازن ترمودینامیکی مشابه) است. این خواص، مانند ویسکوزیته، ظرفیت گرمایی ویژه و جرم مولی، از طریق تحلیل‌های رگرسیون و معادلات تجربی برازش‌شده با داده‌های تجربی از این منابع به دست آمدند. این معادلات در محدوده‌های دمایی خاص معتبر هستند. با این حال، برای مواردی که برون‌یابی لازم بود (خارج از محدوده اعتبار)، مدل‌های تجربی همچنان اعمال شدند و چنین مواردی را «E» (خواص توسعه‌یافته) در ستون «تفصیلات» مجموعه داده‌ها مشخص شده‌اند. هیچ داده تجربی اولیه‌ای برای این مطالعه جمع‌آوری نشد. در عوض، معیارهای عملکرد بر اساس این خواص گردآوری‌شده، پارامترهای سیستم پیشران و محدودیت‌های طراحی ماموریت، همان‌طور که در مقاله مرجع ذکر شده است، مدل‌سازی شدند.

این مجموعه داده‌ها به جای استخراج تجربی، مبتنی بر مدل هستند و بر ارزیابی عملکرد نظری برای رتبه‌بندی پیشران‌ها تمرکز دارند. چارچوب مدل‌سازی، پیکربندی استاندارد پیشران گازی سرد/گرم را در نظر می‌گیرد، از جمله:

- تنظیم پیشران: یک سیستم از نوع رزستوچ با گرمایش مقاومتی برای تبخیر و شتاب دادن پیشران از طریق نازل. این مدل تغییرات فاز را برای پیشران‌های غیرگازی در شرایط ذخیره‌سازی در نظر می‌گیرد.

- پارامترهای کلیدی: کل توان ورودی (P_T) از ۷ تا ۱۲ وات، نرخ جریان جرمی ($\dot{m}$) از ۱۸ تا ۲۸ میلی‌گرم بر ثانیه و نسبت‌های رانش به توان (F/P_T) از ۰/۹ تا ۱/۵ میلی‌نیوتن بر وات. این پارامترها بر اساس الزامات معمول پیشران‌های میکروماهواره، با فرضیات رفتار ایده‌آل گاز پس از گرمایش و انبساط ایزنتروپیک در نازل، محاسبه شده‌اند.

- محیط اکتساب: شبیه‌سازی‌ها با استفاده از یک مدل عملکرد سفارشی پیاده‌سازی‌شده در نرم‌افزار (احتمالاً MATLAB یا Python، هرچند به صراحت در مخزن داده‌ها اشاره نشده است) انجام شد. فرضیات محیطی شامل شرایط خلا (شبیه به فضا)، تلفات حرارتی ناچیز در محفظه و دمای ثابت محفظه بهینه‌شده برای هر پیشران است. معادلات مدل شامل نیروی پیشران $F = \dot{m} v_e$ هستند که v_e سرعت خروجی است و برای گاز گرم از $\sqrt{2C_p \Delta T}$ محاسبه می‌شود، C_p گرمای ویژه و ΔT افزایش دما از توان ورودی است. برای شفافیت، گزیده‌ای از فایل مجموعه داده‌ها "Propellant_Ranking_FP.xlsx" (رتبه‌بندی بر اساس نسبت نیروی پیشران به توان) را ارائه می‌دهیم که نشان‌دهنده مقادیر خام ورودی/خروجی مورد استفاده در تحلیل مقاله ما خواهد بود:

جدول ۱- مقادیر خام ورودی/خروجی مورد استفاده در تحلیل

مقاله

پیشران	P_T (W)	$\dot{m}$ (mg/s)	F/P_T (mN/W)	F_{ave} (mN)	Comments
--------	--------------	---------------------	-------------------	-------------------	----------

بایاس‌های شبکه پرسپترون چندلایه به منظور به حداقل رساندن میانگین مربعات خطای اعتبارسنجی استفاده می‌شود:

$$MSE = \frac{1}{N} \sum_{i=1}^N (F_i^{true} - F_i^{pred})^2 \quad (8)$$

که در آن N تعداد نمونه‌های داده که برابر با ۲۰۰۰ نمونه‌ی آزمونا

خروجی پیش‌بینی‌شده توسط مدل که همان نیروی پیش‌ران پیش‌بینی شده است، F_i^{true} نیروی پیش‌ران واقعی (مقدار حقیقی) برابر با F_F است. توجه به این نکته الزامی است که کار حاضر از الگوریتم ژنتیک برای بهینه‌سازی متغیرهای پیش‌بینی‌کننده (وزن‌های پرسپترون چندلایه) استفاده می‌کند. این کار بهینه‌سازی طراحی فیزیکی هندسه پیش‌ران (مثلاً مساحت نازل یا فشار محفظه) را انجام نمی‌دهد. یک بهینه‌سازی طراحی متغیرهای ساختاری جداگانه (مثلاً بهینه‌سازی هندسه نازل توسط الگوریتم ژنتیک برای به حداکثر رساندن تکانه‌ی ویژه) امکان‌پذیر است و در بخش نتیجه‌گیری به عنوان کار آینده مورد بحث قرار می‌گیرد.

ب- معماری شبکه عصبی

برای مدل‌سازی روابط پیچیده بین ورودی‌ها و نیروی پیش‌ران، یک شبکه عصبی چند لایه استفاده می‌شود. معماری شبکه براساس حافظه کامپیوتر مورد استفاده (حافظه‌ی دسترسی تصادفی ۱۲ گیگابایت و واحد پردازش مرکزی نسل ششم Core i5) شامل موارد زیر باشد:

- لایه ورودی: این لایه شامل گره‌هایی است که با تعداد ویژگی‌های ورودی هماهنگ هستند.
- لایه‌های پنهان: این لایه‌ها مسئول پردازش ویژگی‌های پیچیده و ارتباطات غیرخطی هستند. در مسأله حاضر تعداد یک لایه پنهان در نظر گرفته شده است زیرا که تعداد داده‌ها آنقدر زیاد نیست که تشخیص رابطه بین آنها برای این لایه دشوار باشد. به‌طور تجربی تعداد ۳۰ نورون برای لایه پنهان در نظر گرفته می‌شود.
- لایه خروجی: یک نورون که نیروی پیش‌ران پیش‌بینی‌شده را محاسبه می‌کند. در لایه خروجی از تابع فعال‌ساز تانژانت هذلولوی استفاده شده است.

پ- الگوریتم ژنتیک برای بهینه‌سازی وزن‌ها

وزن‌ها و بایاس‌های شبکه پرسپترون چندلایه (MLP) با یک الگوریتم ژنتیک (GA) پیوسته —که مستقیماً فضای وزن‌ها را هدف می‌گیرد— بهینه‌سازی شدند. هر کروموزوم به‌صورت یک بردار مسطح شامل تمامی وزن‌ها و بایاس‌ها کدگذاری می‌شود و تابع تناسب برابر با مقدار MSE بر روی مجموعه اعتبارسنجی تعریف گردید (MSE کمتر نشان‌دهنده تناسب بهتر است). عرض مسئله بسیار بزرگ و غیرمحدب بود (در نمونه حاضر حدود ۱۰۴۷۱ متغیر)، از این‌رو طراحی اپراتورهای تکثیر و پارامترهای GA با توجه به ملاحظات حفظ تنوع ژنتیکی و جلوگیری از همگرایی زودرس صورت گرفت. در پیاده‌سازی عملیاتی، از یک ترکیب عملگرها استفاده شد که هم جنبه‌های کاوشی و هم بهره‌برداری محلی را پشتیبانی کند: برای انتخاب والدین، روش تورنمنت با اندازه ۳ به‌عنوان روش اصلی به‌کار رفت تا ضمن اولویت‌دهی به راه‌حل‌های متناسب‌تر، شانس بقای نمونه‌های ضعیف‌تر نیز حفظ شود و از افت ناگهانی تنوع جلوگیری شود. در طراحی اولیه نیز مزایا و مقایسه روش‌های دیگر مانند چرخ رولت مورد بررسی قرار گرفت، چرا که قرقره‌ای شانس انتخاب متناسب با تناسب را می‌دهد و می‌تواند از حذف کامل افراد ضعیف جلوگیری کند؛ این خصوصیت در فضاهای بسیار بزرگ می‌تواند مفید باشد. برای عملگر تقاطع، هر دو استراتژی تک‌نقطه‌ای و یک‌نواخت مورد آزمایش قرار گرفتند؛ در نهایت به‌دلیل نمایش کروموزوم به‌صورت بردار مسطح

-	۱۲/۰	۱/۲	۲۰	۱	Water
E	۱۵/۴	۱/۴	۲۲	۱	Xenon
-	۹/۹	۱/۱	۲۵	۹	BoricAcid

جدول ۱ یک نمونه نماینده است؛ مجموعه کامل داده‌ها شامل هزاران ورودی است. ستون «ظرات» در صورت لزوم، ویژگی‌های برون‌یابی‌شده را نشان می‌دهد.

تمام نتایج عددی در مجموعه داده‌ها و مطالعه ما شامل واحدهای صریح هستند: توان کل: (P_T) وات (W)، نرخ جریان جرمی: $(\dot{m})$ میلی گرم در ثانیه (mg/s)، نسبت نیروی پیش‌ران به توان: (F/P_T) میلی نیوتن بر وات (mN/W)، نیروی رانش متوسط: F_{ave} میلی نیوتن (mN)، ضربه ویژه: (I_{sp}) ثانیه (S)، ضربه حجمی: (I_{vol}) نیوتن-ثانیه بر لیتر (Ns/L)، ضربه ویژه مؤثر: (I_{sp}^*) ثانیه (S)، با احتساب جرم مرطوب.

خطاهای مدل از فرضیات (مانند گاز ایده‌آل، بدون تلفات) و برون‌یابی ویژگی‌ها ناشی می‌شوند، اما به عنوان خطاهای آماری در مجموعه داده‌ها کمی‌سازی نمی‌شوند. در عوض، معیارهای عملکرد، خروجی‌های قطعی از مدل هستند. برای تجزیه و تحلیل یادگیری ماشین در مطالعه ما، ویژگی‌های ورودی $(P_T, \dot{m}, F/P_T)$ و اهداف (F_{ave}) با استفاده از استانداردسازی امتیاز Z (تفریق میانگین و تقسیم بر انحراف معیار) نرمال‌سازی شدند تا از تغییرناپذیری مقیاس در طول آموزش اطمینان حاصل شود. این نرمال‌سازی برای پیش‌بینی‌های نهایی معکوس می‌شود تا مقادیر را در واحدهای فیزیکی گزارش دهد. هیچ میله خطایی در داده‌های خام ارائه نشده است، زیرا توسط مدل تولید شده‌اند. با این حال، تجزیه و تحلیل حساسیت (همان‌طور که در متن مقاله ارائه شده است) تغییرات ناشی از تغییرات پارامتر را کمی‌سازی می‌کند. به عنوان یک مثال ملموس، آب را به عنوان یک پیش‌ران در یک سیستم گاز گرم در نظر بگیرید: پارامترهای ورودی $P_T = 10 W$ ، $\dot{m} = 20 mg/s$ ، $F/P_T = 1.2 mN/W$ ، خروجی مدل‌سازی‌شده $F_{ave} \approx 12 mN$ زمینه در دمای محفظه حدود ۴۰۰ کلون (بهینه‌شده برای تبخیر)، با فرض نسبت انبساط نازل ۱:۱۰۰ و ذخیره‌سازی محیطی در ۱ اتمسفر / ۲۹۸ کلون است. این مثال، تکانه ویژه مؤثر بالا به دلیل چگالی آب را نشان می‌دهد، با وجود اینکه I_{sp} معمولی در مقایسه با گازهای نجیب مانند زنون کمتر است.

۲-۱ مدل شبکه عصبی با به‌روزرسانی وزن‌ها با استفاده از الگوریتم ژنتیک

بهینه‌سازی ذره‌ای (PSO) به عنوان یک الگوریتم ابتکاری جایگزین در نظر گرفته شد؛ با این حال، GA به دلیل تعادل برتر اکتشاف و بهره‌برداری در فضاهای پارامتری مخلوط گسسته و پیوسته و همچنین سابقه اثبات‌شده در بهینه‌سازی پیش‌ران‌ها، ترجیح داده شد. علاوه بر این، روش‌های نزول گرادیان، اگرچه از نظر محاسباتی کارآمد هستند، اما در برابر تخریب گرادیان حاصل از نویز آسیب‌پذیرند، که منجر به همگرایی ناکارآمد در حضور نویز اندازه‌گیری سنسورهای می‌شود که داده‌های آزمایش پیش‌ران‌ها را سرد را تشکیل می‌دهند. برای پیاده‌سازی یک مدل شبکه عصبی که وزن‌های آن توسط الگوریتم ژنتیک به‌روزرسانی می‌شود، مراحل زیر قابل اجرا است:

الف- ورودی‌ها و خروجی‌ها

مدل نظارت‌شده، سه ورودی اندازه‌گیری‌شده توان الکتریکی (P_e)، نرخ جریان سوخت ($\dot{m}$)، کارایی رانش (η_P) را به یک خروجی اسکالر واحد یعنی نیروی پیش‌ران F_F نگاشت می‌کند. الگوریتم ژنتیک برای بهینه‌سازی وزن‌ها و

۳- نتایج

در این بخش، نتایج حاصل از پیاده‌سازی و ارزیابی مدل شبکه عصبی ترکیب‌شده با الگوریتم ژنتیک برای تخمین نیروی پیشران ارائه می‌شود. این نتایج، عملکرد مدل را روی داده‌های آزمون و در مقایسه با مقادیر واقعی نیروی رانش ارزیابی می‌کند.

مدل شبکه عصبی با استفاده از الگوریتم ژنتیک توانسته است دقت بالایی در تخمین نیروی پیشران بدست آورد. میزان خطای پیش‌بینی در داده‌های آزمون به طور متوسط کمتر از ۵ درصد بوده است. این نتیجه نشان‌دهنده توانایی بالای الگوریتم ژنتیک در بهینه‌سازی وزن‌های شبکه عصبی و دقت بالای مدل در پیش‌بینی نیروی پیشران است.

۳-۱- عملکرد شبکه عصبی با الگوریتم ژنتیک

پس از پیاده‌سازی و آموزش، مدل ایجادشده در تخمین نیروی پیشران با مقادیر واقعی سنجیده شد. برای ارزیابی عینی عملکرد، از معیارهای میانگین مربع خطا (MSE) و ضریب همبستگی R^2 استفاده گردید. در این تحقیق، یک شبکه عصبی با یک لایه ورودی شامل ۳ نورون متناظر با پارامترهای ورودی، یک لایه پنهان با ۶۰ نورون، و یک لایه خروجی با یک نورون متناظر با نیروی پیشران بود. شکل ۲، نمودار مقایسه مقادیر پیش‌بینی‌شده توسط مدل را با مقادیر واقعی نشان می‌دهد. ارزیابی روی داده‌های آزمون، مقدار MSE را حدود ۰/۴۲ و میانگین خطای پیش‌بینی را کمتر از ۵ درصد محاسبه کرد. این نتایج حاکی از دقت بالای مدل در شناسایی و مدل‌سازی رابطه بین پارامترهای ورودی و نیروی پیشران خروجی است. برای درک بهتر کارایی این روش، نتایج با مدل‌های سنتی که از الگوریتم ژنتیک استفاده نمی‌کنند مقایسه شد. مقدار MSE در آن مدل‌ها حدود ۰/۰۵ به‌دست آمد که نشان می‌دهد استفاده از الگوریتم ژنتیک برای بهینه‌سازی وزن‌های شبکه‌ی عصبی، منجر به بهبود قابل‌توجهی در دقت پیش‌بینی مدل شده است. انتخاب GA به جای PSO بر اساس آزمایش‌های اولیه (نمایش داده نشده) بود که در آن GA رفتار همگرا شدن ثابت‌تری را برای مسئله‌ی بهینه‌سازی وزن با حدود ۱۴۷۱ پارامتر نشان داد. PSO در چندین اجرا به دلیل تجمع ذرات در بهینه‌های محلی، همگرایی زود هنگام را نشان داد. در مقایسه با نزول گرادیان استاندارد، GA محدودیت ذاتی روش‌های مبتنی بر گرادیان را دور می‌زند: وابستگی آن‌ها به قابل مشتق بودن و پیوستگی تابع زیان. در حضور نویز سنسور (σ حدود ۵-۱۰٪ از محدوده‌ی اندازه‌گیری)، برآوردهای گرادیان غیرقابل اعتماد می‌شوند، در حالی که جستجوی تصادفی مبتنی بر جمعیت GA همچنان مقاوم باقی می‌ماند.

MSE ۰/۱ حاصل شده در داده‌های آزمایشی معادل خطای مطلق حدود ± 0.3 میلی‌نیوتون برای بازه‌های پیشران معمولی (۱-۱۰ میلی‌نیوتون) است، که در حاشیه‌های قابل قبول برای مانورهای کنترل وضعیت است که دقت پیشران $\pm 5\%$ در کل کافی به نظر می‌رسد. برای حفظ موقعیت دقیق، کالیبراسیون اضافی ممکن است مورد نیاز باشد. در مقایسه با مدل‌های مبتنی بر فیزیک که نیازمند شبیه‌سازی‌های CFD است، روش پیشنهادی پیش‌بینی‌های زمان واقعی با دقت قابل مقایسه و در عین حال کاهش زمان محاسباتی به میزان قابل توجهی را ارائه می‌دهد.

جنگل تصادفی و $XGBoost$ به عنوان مدل‌های پایه انتخاب شدند زیرا عملکرد اثبات‌شده‌ای در وظایف رگرسیون و محبوبیت در کاربردهای هوافضا دارند. پارامترهای فوق برای تمام مدل‌ها با استفاده از جستجوی شبکه تنظیم شد: RF (max_depth: ۲-۵, n_estimators: ۵۰۰-۱۰۰۰), $XGBoost$ (max_depth: ۱۰-۳, learning_rate: ۰/۳-۰/۰۱, n_estimators: ۵۰۰-۱۰۰۰). یک رده‌بندی تصادفی یکسان در تمام آزمایش‌ها استفاده شد تا تقسیم‌بندی قابل تکرار داده‌ها را تضمین کند. مقایسه نشان می‌دهد که روش‌های مبتنی بر درخت مجموعه‌ای، اگرچه برای داده‌های

و احتمال پراکندگی ساختارهای مفید در طول کروموزوم، تقاطع یکنواخت برای گزارش نهایی ترجیح داده شد زیرا به‌صورت ژن‌به‌ژن عمل کرده و از خرد شدن احتمالی الگوهای پراکنده جلوگیری می‌کند. جهش به‌صورت اغتشاش گاوسی پیوسته اعمال شد: ژن‌های تصادفی با احتمال $p_m = 0.01$ تحت تغییرات تصادفی نرمال قرار گرفتند که دامنه انحراف با رابطه $\sigma = 0.02 \times \text{range}_{\text{gene}}$ تعریف شده بود؛ این نوع جهش با توجه به پیوسته‌بودن وزن‌ها و بایاس‌ها امکان جستجوی محلی و پالایش دقیق در اطراف راه‌حل‌های امیدوارکننده را فراهم می‌آورد.

پارامترهای کلیدی الگوریتم به‌صورت تجربی و بر اساس بهترین شیوه‌های موجود در ادبیات تعیین شدند: اندازه جمعیت ۵۰، نرخ تقاطع $p_c = 0.8$ ، نرخ جهش $p_m = 0.01$ و حداکثر تعداد نسل‌ها برابر با ۲۰۰. همچنین معیار توقف زود هنگام به‌کار رفت به‌طوری که الگوریتم اگر در طول ۲۰ نسل متوالی بهبود نسبی در MSE اعتبارسنجی کمتر از 1×10^{-4} نشان می‌داد، متوقف می‌شد. پس از پایان جستجو، کروموزوم برتر رمزگشایی و وزن‌ها و بایاس‌های متناظر به‌عنوان مقداردهی اولیه شبکه جهت انجام تنظیم دقیق نهایی روی داده‌ها مورد استفاده قرار گرفتند. این رویه ترکیبی (بهینه‌سازی جهانی توسط GA و پالایش موضعی توسط آموزش محلی) به‌منظور دستیابی به دقت بالا و جلوگیری از گیرکردن در کمینه‌های محلی اتخاذ شد. برای مرجع و جزئیات بیشتر در مورد اجزای استاندارد GA و گزینه‌های جایگزین به منابع [۲۸، ۲۷] مراجعه شود.

ت- پیاده‌سازی مدل

پیاده‌سازی این مدل با استفاده از زبان برنامه‌نویسی $Python$ برای بخش شبکه عصبی و یک چارچوب تخصصی برای الگوریتم‌های ژنتیک انجام شد. پس از انتخاب وزن‌های بهینه، مدل از الگوریتم ژنتیک برای به‌روزرسانی وزن‌های شبکه عصبی بهره برد تا دقت آموزش شبکه افزایش یابد و فرایند بهینه‌سازی تکمیل شود. در نهایت، شبکه عصبی به‌عنوان ابزاری مؤثر برای پیش‌بینی نیروی پیشران در سامانه‌های پیشران گاز سرد مورد استفاده قرار گرفت. وزن‌های بهینه‌شده توسط الگوریتم ژنتیک با دقت بالاتری روابط پیچیده بین پارامترهای ورودی و نیروی پیشران را مدل‌سازی کنند.

ث- آموزش و ارزیابی مدل

پس از انتخاب وزن‌های بهینه توسط الگوریتم ژنتیک، این وزن‌ها برای آموزش شبکه عصبی به‌کار گرفته می‌شوند تا دقت شبکه در تبدیل پارامترهای ورودی به نیروی پیشران خروجی افزایش یابد. داده‌های آموزشی مورد استفاده، شامل مقادیر مختلف پارامترهای ورودی و مقادیر واقعی نیروی پیشران جمع‌آوری‌شده از سامانه‌های پیشران گاز سرد است. این داده‌ها مطابق با روش k -fold به سه بخش زیر تقسیم شده‌اند:

۱- داده‌های آموزشی: ۸۵ درصد از داده‌ها برای آموزش مدل شبکه عصبی استفاده می‌شوند.


۲- داده‌های اعتبارسنجی: ۱۰ درصد از داده‌ها برای تنظیم پارامترهای مدل و جلوگیری از بیش‌برازش به‌کار می‌روند.

۳- داده‌های تست: ۵ درصد از داده‌ها برای ارزیابی نهایی دقت مدل استفاده می‌شوند.

شبیه‌کد الگوریتم به‌روزرسانی وزن‌ها در شبکه عصبی با استفاده از الگوریتم ژنتیک، که شامل خلاصه‌ای از توضیحات فوق است، در جدول ۲ ارائه شده است.

همچنین فلوجارت این الگوریتم در شکل ۱، مراحل کار را از استخراج تا بهینه‌سازی مسئله، به ترتیب نشان می‌دهد.

ضعیف‌تری دارند.




شکل ۲- نمودار مقادیر واقعی و خروجی شبکه یادشده برای نیروی رانشگر (نمودار بالا برای داده‌های صحت‌سنجی و پایینی برای داده‌های تست)

جدول ۲- شبه‌کد الگوریتم به‌روزرسانی وزن‌ها در شبکه عصبی با استفاده از الگوریتم ژنتیک


پارامترها: اندازه جمعیت (PP)، حداکثر نسل‌ها (GG)، نرخ جهش (μ)، نرخ ترکیب (χ)

- ۱- ایجاد اولیه یک جمعیت تصادفی از وزن‌ها و بایاس‌ها.
- ۲- محاسبه مقدار تناسب برای هر عضو در جمعیت.
- ۳- تکرار برای هر نسل $g = 1$ تا $g = GG$
- ۴- انتخاب والدین از جمعیت بر اساس مقدار تناسب آن‌ها.
- ۵- اعمال ترکیب با احتمال χ برای تولید فرزندان.
- ۶- اعمال جهش با احتمال μ برای ایجاد تنوع در فرزندان.
- ۷- محاسبه تناسب برای فرزندان.
- ۸- به‌روزرسانی جمعیت با جایگزینی بدترین اعضای جمعیت با بهترین فرزندان.
- ۸-۱- استخراج وزن‌ها و بایاس‌ها از بردار راه‌حل.
- ۸-۲- ورود داده‌ها به شبکه عصبی با استفاده از وزن‌ها و بایاس‌ها.
- ۸-۳- محاسبه خروجی شبکه و مقایسه آن با مقادیر هدف.
- ۸-۴- محاسبه خطا با استفاده از میانگین مربعات خطا
$$Fitness = 1 - \frac{1}{N} \sum_{i=1}^N \left(\frac{y_{i,true} - y_{i,pred}}{y_{i,true}} \right)^2$$
- ۸-۵- بازگشت مقدار خطا به عنوان مقدار تناسب (کمتر بودن خطا بهتر است).
- ۹- تکرار تا زمانی که تعداد نسل‌ها به حداکثر مقدار برسد یا شرط توقف محقق شود.
- ۱۰- بازگشت بهترین راه‌حل پیدا شده (وزن‌ها و بایاس‌های بهینه).




شکل ۱- فلوچارت شبکه یادشده برای نیروی رانشگر

ساختاریافته جدولی موثر هستند، اما در مقایسه با روش‌های شبکه عصبی در هنگام درک روابط ترمودینامیکی زیربنایی در سیستم‌های پیشران‌ش عملکرد




شکل ۴- نمودار خطای مقادیر پیش‌بینی شبکه یادشده با مقادیر واقعی نیروی پیش‌ران



شکل ۵- نمودار ضریب همبستگی مدل شبکه با به‌روزرسانی الگوریتم ژنتیک و گرادین نزولی

الگوریتم ژنتیک در این پژوهش نقش کلیدی در بهینه‌سازی وزن‌های شبکه عصبی داشت. وزن‌های بهینه‌ای که با این الگوریتم تعیین شدند، موجب افزایش دقت پیش‌بینی مدل و کاهش خطای آموزش و آزمون شدند. این بهینه‌سازی موجب شد که شبکه عصبی بتواند پیچیدگی‌های غیرخطی موجود در رابطه بین پارامترهای ورودی و نیروی پیش‌ران را به‌خوبی مدل کند و از گیر کردن در حداقل‌های محلی جلوگیری کند.

نمودار میله‌ای شکل ۶، مقایسه‌ی میانگین خطای مطلق (MAE) چهار روش یادگیری ماشین را نشان می‌دهد که تفاوت‌های چشمگیری در دقت پیش‌بینی آن‌ها آشکار می‌سازد. الگوریتم ژنتیک بهینه‌شده با کمترین میزان MAE (0.013 ± 0.0196)، بالاترین عملکرد را دارد که حاکی از دقت پیش‌بینی بالا و تغییرپذیری اندک آن است. در مقابل، الگوریتم گرادین استاندارد (GA) با بیشترین خطا (0.0534 ± 0.011)، دارای محدودیت‌های قابل‌توجهی در قابلیت پیش‌بینی است، به‌طوری‌که خطای آن بیش از ۲٫۷ برابر الگوریتم پیشنهادی بهینه‌شده است. روش‌های جنگل تصادفی (0.035 ± 0.0247) و XGBoost (0.0361 ± 0.050) عملکردی میانه دارند؛ با این حال، جنگل تصادفی نه تنها دقت بهتری از خود نشان می‌دهد، بلکه تغییرپذیری کمتری نیز نسبت به XGBoost دارد. میله‌های خطا که انحراف معیار را نشان می‌دهند، حاکی از پایداری عملکرد در اجراهای مکرر هستند. این پایداری در تمامی روش‌ها به‌جز XGBoost، که دارای بیشترین میزان تغییرپذیری است، مشاهده می‌شود. در مجموع، این تحلیل به‌وضوح تأیید می‌کند که الگوریتم ژنتیک بهینه‌شده، بهبودی آماری و قابل‌ملاحظه در دقت پیش‌بینی در مقایسه با روش‌های متداول ایجاد می‌کند. شکاف عملکردی چشمگیر بین این الگوریتم و روش‌های استاندارد، مؤید اثربخشی استراتژی بهینه‌سازی اعمال‌شده برای این وظیفه است.



شکل ۳- نمودار پراکندگی برای داده‌های صحت‌سنجی و آزمون

ماتریس نمودار پراکندگی شکل ۳، ارزیابی جامعی از عملکرد چهار مدل رگرسیون (GA بهینه، GD استاندارد، جنگل تصادفی و XGBoost) را بر اساس مجموعه داده‌های اعتبارسنجی (آبی) و آزمون (نارنجی) ارائه می‌دهد. خط مورب مرجع، نشان‌دهنده‌ی وضعیت پیش‌بینی ایده‌آل ($y = x$) است؛ بنابراین، نقاطی که به این خط نزدیک‌تر باشند، از دقت بالاتر مدل حکایت دارند. مدل GA بهینه با فشرده‌ترین خوشه‌ی داده‌ها در اطراف خط مرجع، بالاترین ضریب همبستگی ($R^2 = 0.872$) را در مجموعه‌ی آزمون به خود اختصاص داده است. هم‌چنین، انحراف ناچیز بین نتایج اعتبارسنجی و آزمون، حاکی از قابلیت تعمیم قوی و موفقیت این مدل در بازتولید فیزیک حاکم بر پیش‌ران فضاییما است. اگرچه مدل جنگل تصادفی با ($R^2 = 0.72$) عملکرد خوبی دارد، اما مدل GA بهینه از نظر ثبات و قابلیت تعمیم، برتری خود را نشان می‌دهد. در مقابل، XGBoost با پراکندگی بیشتر داده‌ها ($R^2 = 0.6$) نشانه‌هایی از برازش پایین را نشان می‌دهد.

همچنین در شکل ۴ مقادیر خطای بین مدل پیش‌بینی و مقادیر واقعی آمده است. ضریب همبستگی R^2 برای مدل آموزش دیده با الگوریتم ژنتیک در داده‌های آزمون حدود ۰٫۸۷۲ به‌دست آمده که در شکل ۵ قابل مشاهده است. این مقدار نشان‌دهنده تطابق بالای بین پیش‌بینی‌های مدل و مقادیر واقعی نیروی پیش‌ران است. به‌طور خاص، R^2 بالای ۰٫۸ نشان‌دهنده توانایی مدل در تعمیم‌دهی خوب به داده‌های جدید است. از طرفی این معیار نشان می‌دهد که کدام مدل توانسته واریانس بیشتری را توضیح دهد و در نتیجه بهتر عمل کرده است. مقایسه با نتایج مدل‌های دیگر که از روش‌های بدون بهینه‌سازی مانند گرادین نزولی استفاده می‌کنند، R^2 مدل پیشنهادی به‌طور قابل‌توجهی بالاتر است. فرمول محاسبه R^2 به صورت زیر است:

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (9)$$



که در آن SS_{res} مجموع مربعات خطا، یعنی مجموع مربعات تفاوت بین مقادیر واقعی و مقادیر پیش‌بینی‌شده است. SS_{tot} مجموع مربعات کل، یعنی مجموع مربعات تفاوت بین مقادیر واقعی و میانگین مقادیر واقعی است. برای مقایسه جامع‌تر با مدل مبتنی بر الگوریتم ژنتیک، در مدل پایه، وزن‌ها به‌طور دستی تنظیم شده و بهینه‌سازی با استفاده از الگوریتم‌های استاندارد (مانند الگوریتم پخش‌خطا) انجام شد. نتایج نشان داد که MSE مدل بدون الگوریتم ژنتیک حدود ۰٫۴۴ و R^2 آن در ۰٫۵۶ بود که این نشان‌دهنده کاهش نسبی دقت پیش‌بینی در مقایسه با مدل بهینه‌شده با الگوریتم ژنتیک است.

می‌توان با معادله پاستنگ انرژی برای یک گاز ایده‌آل توضیح داد $P = \dot{m} C_p \Delta T + Q_{loss}$ ، که در آن توان ناکافی، افزایش دمای گاز و در نتیجه سرعت خروجی را محدود می‌کند. در سطوح توان بالاتر (بیشتر از ۱۲ وات)، افزایش اتلاف‌های هدایت گرمایی به دیواره‌های محفظه بازده کلی را کاهش می‌دهد. این نقطه عملیاتی بهینه، به‌طور دقیق با منحنی نظری توان-رانش می‌دهد از معادله پیش‌رانش برای سیستم‌های گاز سرد $F = \sqrt{\frac{\dot{m} C_p \sqrt{\gamma R T_c}}{C_F}}$ مشتق شده است، همسویی دارد. در این معادله، ضریب پیش‌رانش C_F که تابعی از نسبت فشار محفظه به محیط و هندسه نازل است، در یک محدوده دمایی بهینه به حداکثر بازده خود می‌رسد. این رفتار با مدل‌های شبیه‌سازی عددی مانند CFD برای پیش‌رانش‌های گرم‌شده (مانند گزارش‌های NASA در پیش‌ران‌های رزیستوت) همخوانی دارد، که اوج بازده را در توان‌های متوسط پیش‌بینی می‌کنند.

رابطه‌ی مقعر در نمودار نسبت پیش‌ران به توان، یک آستانه بحرانی برای بازده در سیستم‌های پیش‌رانش گرمایشی را نشان می‌دهد. حداقل مشاهده‌شده در بازه ۱۲ تا ۱۳ mN/W، با بازده تبدیل انرژی حرارتی به جنبشی مطابقت دارد. پایین‌تر از این نسبت، پیش‌ران در رژیم کار می‌کند که در آن انرژی حرارتی منتقل شده به گاز ناکافی است و در نتیجه سرعت خروجی و پیش‌ران پایین می‌ماند. بالاتر از این نسبت، پیش‌ران وارد رژیم می‌شود که در آن، اتلاف‌های حرارتی و باز ترکیب در نازل غالب می‌گردند و بازده کلی را کاهش می‌دهند. این پدیده توسط قوانین ترمودینامیک و رابطه‌های ایزنتروپیک برای جریان در نازل توصیف می‌شود. این رابطه مقعر، صحت فیزیکی مدل را تأیید می‌کند، زیرا آستانه بحرانی را بر اساس قوانین ترمودینامیک (مانند فرایندهای ایزنتروپیک در نازل‌های همگرا-اگرا) به درستی ثبت کرده و با داده‌های تجربی پیش‌ران‌ها مانند سیستم‌های ARCJET همخوانی دارد.


رابطه افزایشی یکنواخت رانش با نرخ شار جرمی، مستقیماً از معادله بنیادی رانش $F = \dot{m} v_e$ پیروی می‌کند، که در آن « v_e » سرعت خروجی است و برای یک گاز ایده‌آل به دمای محفظه « T_c » وابسته است. انحنا مشاهده‌شده در نمودار، رابطه غیرخطی بین نرخ شار جرمی و توان مورد نیاز برای حفظ دمای بهینه محفظه را نشان می‌دهد. نرخ شار جرمی بالاتر، برای حفظ دمای عملیاتی بهینه گاز، به توان گرمایشی بالاتری نیاز دارد. کاهش بازده در نرخ‌های شار جرمی بالاتر (که با افزایش شیب نمودار مشخص می‌شود) با مشاهدات تجربی پدیده «سرد شدن جریانی» در سیستم‌های گرمایشی همخوانی دارد. در این پدیده، افزایش شار سوخت، کارایی انتقال حرارت به هر مولکول گاز را کاهش داده و در نتیجه میانگین سرعت خروجی « v_e » را پایین می‌آورد. این رفتار به‌طور تجربی در آزمایش‌های انجام‌شده بر روی پیش‌ران‌های گاز سرد/داغ با گرمایش مقاومتی تأیید شده است. برای مثال، مطالعات ESA روی میکرو پیش‌ران‌ها نشان می‌دهد که نرخ شار جرمی بیش از ۲۵ mg/s اغلب به کاهش Isp (پیش‌ران ویژه) منجر می‌شود، که با انحنا نمودار مطابقت دارد.

مدل شبکه عصبی بهینه‌شده با الگوریتم ژنتیک در مدت زمان نسبتاً کوتاهی آموزش داده شد. زمان محاسبه برای هر نسل از الگوریتم ژنتیک و بهینه‌سازی وزن‌ها در حدود ۱۲۰ دقیقه بود، که با توجه به پیچیدگی و تعداد پارامترهای سیستم، زمان مناسبی برای چنین مسائلی به‌نظر می‌رسد. این امر نشان‌دهنده کارایی بالای الگوریتم ژنتیک در بهینه‌سازی مدل است.



شکل ۶- نتایج آماری شبکه به‌روزرسانی با الگوریتم ژنتیک و روش‌های استاندارد

نمودار شکل ۷، تغییرات تنوع جمعیت را در طول نسل‌های متوالی الگوریتم ژنتیک (GA) نشان می‌دهد. محور افقی نمایانگر شماره نسل و محور عمودی، میزان تنوع جمعیت را که با انحراف معیار سنجیده شده، نمایش می‌دهد. همانطور که در نمودار مشهود است، با پیشروی نسل‌ها، تنوع جمعیت روندی نزولی و پیوسته در پیش می‌گیرد. این کاهش حاکی از همگرایی تدریجی الگوریتم به سمت یک راه‌حل بهینه است؛ به‌طوری که افراد جمعیت، به مرور شباهت بیشتری به یکدیگر پیدا می‌کنند. کاهش مداوم انحراف معیار نیز مؤید کاهش تنوع ژنتیکی در جمعیت است. در واقع، با گذشت نسل‌ها، ویژگی‌های اعضای جمعیت یکسان‌تر شده و به پاسخ بهینه نزدیک‌تر می‌شوند. این فرآیند هرچند برای همگرایی ضروری است، اما می‌تواند به تمرکز بر روی برخی از ویژگی‌های خاص و کاهش توانایی الگوریتم در کاوش فضا منجر شود. از این‌رو، معمولاً لازم است در کنار بهینه‌سازی، مکانیزم‌هایی برای حفظ بخشی از تنوع جمعیت در نظر گرفته شود تا از همگرایی زودهنگام جلوگیری شده و به راه‌حلی مقاوم و کارآمد دست یافت.



شکل ۷- نمودار انحراف معیار شبکه الگوریتم ژنتیک

رابطه‌ی محدب مشاهده‌شده در نمودار توان کل (که حداکثر پیش‌ران را در بازه ۱۰ تا ۱۱ وات نشان می‌دهد)، به‌طور مستقیم با رابطه بنیادی توان-پیش‌ران در پیش‌ران‌های گاز سرد مطابقت دارد. توجه فیزیکی این پدیده در تعادل بین انرژی گرمایی محبوس شده و بازده تبدیل انرژی جنبشی در نازل نهفته است. در سطوح توان پایین‌تر (کمتر از ۸ وات)، انرژی کافی برای گرم کردن گاز و ایجاد فشار محفظه لازم برای شتاب کارآمد در دسترس نیست. این موضوع را

نتایج جدول ۳ نشان می‌دهد که در تنظیمات فعلی و با بهینه‌سازی کامل‌تر هاپرپارامترها، روش بهینه GA به طور میانگین بهترین R^2 و پایین‌ترین خطاها را دارد. انحراف معیار مقادیر نشان‌دهنده پایداری نسبی مدل‌ها در تقسیم‌بندی ۵-fold است.

جدول ۴- نتایج اعتبارسنجی متقاطع (Leave-one-out)

Model	R^2 score (Overall)	MSE (MEAN ± STD)	MAE (MEAN ± STD)
Optimal GA	۰.۸۶۱۰	۰.۱۵۵۴±۰.۱۲۱۰	۰.۲۰۳۶±۰.۳۳۶۰
Standard GD	۰.۳۱۷۳	۰.۹۸۸۷±۰.۶۵۴۸	۰.۷۷۵۹±۰.۶۹۰۹
RF	۰.۶۰۵۶	۰.۴۴۰۹±۰.۲۱۳۳	۰.۲۹۵۹±۰.۵۹۴۵
XGB	۰.۳۳۵۱	۰.۷۴۳۴±۰.۷۹۲۲	۰.۵۹۰۸±۰.۶۲۷۹


در جدول ۴ مشاهده می‌شود که برآوردهای LOO در مقایسه با ۵-fold معمولاً نرخ R^2 پایین‌تر و خطاهای بالاتری گزارش کرده‌اند. علت اصلی این اختلاف دوگانه است: (۱) LOO به‌خاطر آزمون تکنمونه‌ای حساس به نقاط پرت و ناپایداری مدل است و (۲) برای قابل اجرا بودن LOO در این مطالعه، جستجوی هاپرپارامترها محدود شد (کمتر شدن تعداد نسل‌ها/نمونه‌ها/جمعیت)، که خود موجب کاهش عملکرد مدل‌های یادگیری شد. بنابراین کاهش عملکرد در جدول ۴ نباید لزوماً به‌عنوان «کاهش عملکرد ذاتی مدل» تفسیر شود بلکه تا حدی ناشی از مصالحه‌های محاسباتی است.

نیازهای محاسباتی مدل GA-MLP پیشنهادی متعادل است: آموزش بر روی پردازنده Intel Core i۵ استاندارد با ۸ گیگابایت رم در حدود ۳۰ دقیقه به طول می‌انجامد. پس از آموزش، زمان استنباط مدل کمتر از ۱ میلی‌ثانیه برای هر پیش‌بینی است، که آن را برای برنامه‌های زمان‌واقعی مناسب می‌کند. برای پیاده‌سازی در داخل فضاپیماها با منابع محاسباتی محدود (مثلاً ARM Cortex پردازنده‌ها)، مدل آموزش‌دیده می‌تواند به عنوان یک موتور استنباط سبک‌وزن با محاسبات نقطه‌ای ثابت صادر شود، که پهنای باند حافظه را به کمتر از ۱۰۰ کیلوبایت کاهش می‌دهد. اندازه مجموعه داده ۲۰۰۰ نمونه، چالش‌های محاسباتی ایجاد نکرد؛ با این حال، مقیاس‌بندی به مجموعه‌های داده بزرگتر (بیش از 10^5 نمونه) ممکن است به شتاب‌دهنده‌های GPU یا چارچوب‌های محاسبات توزیع‌شده نیاز داشته باشد.

۴- نتیجه‌گیری

در این پژوهش، یک مدل شبکه عصبی چندلایه به همراه الگوریتم ژنتیک برای پیش‌بینی نیروی رانش سیستم‌های رانش گاز سرد توسعه و ارزیابی شد. نتایج حاصل از تحلیل‌های انجام‌شده نشان‌دهنده کارایی بالای مدل پیشنهادی در پیش‌بینی دقیق و کاهش خطای پیش‌بینی نسبت به سایر روش‌های موجود است. استفاده از الگوریتم ژنتیک به‌منظور بهینه‌سازی وزن‌های شبکه عصبی موجب بهبود قابل‌توجه دقت مدل در فرآیند پیش‌بینی و تطابق بهتر آن با داده‌های آزمایشی گردید.

با توجه به جدول ۴ و مقایسه ویژگی‌های آماری و همچنین شکل ۴ برای مربع خطای میانگین به وضوح نشان داده شد که مدل پیشنهادی از نظر عملکرد در مقایسه با روش‌های بهینه‌سازی سنتی و متداول به‌ویژه در زمینه پیش‌بینی نیروی پیش‌ران، مزیت‌های چشمگیری دارد. نتایج نشان‌دهنده تأثیر مثبت فرآیند بهینه‌سازی الگوریتم ژنتیک در تقویت توان پیش‌بینی مدل و کاهش خطاهای ناشی از متغیرهای غیرخطی و پیچیده است. به‌ویژه، الگوریتم ژنتیک توانسته است با تنظیم بهینه وزن‌ها و پارامترهای شبکه، عملکرد مدل را به‌طور معناداری ارتقا دهد. قابلیت تعمیم مدل از طریق اعتبارسنجی متقاطع دقیق ارزیابی شد، که عملکردی یکنواخت در میان بخش‌های داده نشان داد



شکل ۸- نمودار حساسیت نسبت به ورودی توان کل، نسبت پیش‌ران- به-توان و شار جرمی

تحلیل حساسیت بینش‌های مهمی را برای طراحی و عملکرد پیش‌رانه‌ها آشکار می‌کند: (۱) نرخ جریان جرم بالاترین حساسیت را نشان می‌دهد (ضریب نرمال‌شده: ۰.۴۲)، که نشان می‌دهد کنترل دقیق جریان جرم برای دقت پیش‌ران ضروری است—توصیه به کنترل‌کننده‌هایی با عدم قطعیت $\leq 1\%$; (۲) کارایی شتاب به توان حساسیت متوسطی (۰.۳۱) نشان می‌دهد، که پیشنهاد می‌کند مدیریت حرارتی و بهینه‌سازی کارایی نازل می‌تواند به دستاوردهای قابل توجهی در عملکرد منجر شود؛ (۳) توان الکتریکی حساسیت کمتری اما غیرناچیز (۰.۲۷) دارد، که نشان می‌دهد ثبات منبع توان کمتر از کنترل جریان جرم حیاتی است. این یافته‌ها می‌توانند اولویت‌های انتخاب سنسور و طراحی سیستم کنترل را برای سیستم‌های پیش‌ران گاز سرد راهنمایی کنند.

جهت ارزیابی عملکرد مدل‌ها از دو روش اعتبارسنجی متقاطع استفاده شده است: اعتبارسنجی k -fold با $k = 5$ و اعتبارسنجی (Leave-One- (Out (LOO). فرموله‌سازی ریاضی LOO و k -fold به‌صورت زیر است. برای تابع هزینه عمومی $L(\cdot)$ مثلاً MSE، برآورد خطای LOO به‌صورت:

$$LOO = \frac{1}{n} \sum_{i=1}^n L(y_i, \hat{f}_{-i}(x_i)) \quad (10)$$

که در آن $\hat{f}_{-i}$ مدل آموزش‌دیده روی مجموعه آموزشی کامل به‌جز نمونه i ام است. معادله کلی k -fold به‌صورت:

$$k\text{-fold} = \frac{1}{k} \sum_{j=1}^k \frac{1}{|V_j|} \sum_{i \in V_j} L(y_i, \hat{f}_{-V_j}(x_i)) \quad (11)$$

که V_j مجموعه شاخص‌های معیار برای فولد j است و $\hat{f}_{-V_j}$ مدل آموزش‌دیده بدون نمونه‌های V_j .

جدول ۳- نتایج اعتبارسنجی متقاطع (5-fold)

Model	R^2 score (MEAN ± STD)	MSE (MEAN ± STD)	MAE (MEAN ± STD)
Optimal GA	۰.۸۷۶۲±۰.۰۲۱۶	۰.۰۶۸۰±۰.۰۱۲۶	۰.۱۹۵۶±۰.۰۱۶۹
Standard GD	۰.۳۳۷۳±	۰.۷۵۸۷±	۰.۵۳۳۵±۰.۰۶۴۶
RF	۰.۳۱۷۳	۰.۶۵۴۸	۰.۲۴۷۳±
	۰.۶۴۳۰±۰.۳۵۰۵	۰.۴۵۲۰±	۰.۲۴۷۳±
		۰.۵۹۶۸	۰.۰۴۶۷
XGB	۰.۴۲۶۶±۰.۳۳۵۷	۰.۶۵۷۹±۰.۵۲۱۶	۰.۳۶۱۴±
			۰.۰۸۹۲

- Proceedings of the 2024 3rd International Symposium on Intelligent Unmanned Systems and Artificial Intelligence; 2024. p. 216-220.
- [6] Zhang W, Xu M, Yang H, Wang X, Zheng S, Li X. Data-driven deep learning approach for thrust prediction of solid rocket motors. *Measurement*. 2024;225:114051.
 - [7] Kim JY, Lee JH, Oh JH, Oh JS. A comparative study on energy consumption forecast methods for electric propulsion ship. *Journal of Marine Science and Engineering*. 2021;10(1):32.
 - [8] Tang R, Fang G, Liu G, Wang H. Propulsion life prediction based on support vector machine. In: *IOP Conference Series: Earth and Environmental Science*. Vol. 687, No. 1. IOP Publishing; 2021. p. 012082.
 - [9] Burges CJC. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*. 1998;2:121-167.
 - [10] Kwon K. A novel numerical analysis of hall effect thruster and its application in simultaneous design of thruster and optimal low-thrust trajectory [Doctoral dissertation]. Georgia Institute of Technology; 2010.
 - [11] Karthik A, Chiniwar DS, Das M, Prabhu P, Mulimani PA, Samanth K, Naik N. Electric propulsion for fixed-wing aircrafts—A review on classifications, designs, and challenges. *Engineered Science*. 2021;16(2):129-145.
 - [12] Zaccone R, Campora U, Martelli M. Optimisation of a diesel-electric ship propulsion and power generation system using a genetic algorithm. *Journal of Marine Science and Engineering*. 2021;9(6):587.
 - [13] Comunian P, Serpieri J, Cafiero G. A genetic-algorithm based approach for optimized distributed propulsion. In: *AIAA AVIATION FORUM AND ASCEND 2024*; 2024. p. 3603.
 - [14] Song H, Li B, Zhao Y, Jiang K. Aero-engine thrust estimator design based on clustering and particle swarm optimization extreme learning machine. *Journal of Propulsion Technology*. 2017;38(6):1379.
 - [15] Zhou L, Sun Q, Ding S, Han S, Wang A. A machine-learning-based method for ship propulsion power prediction in ice. *Journal of Marine Science and Engineering*. 2023;11(7):1381.
 - [16] Jung W, Chang D. Deep reinforcement learning-based energy management for liquid hydrogen-fueled hybrid electric ship propulsion system. *Journal of Marine Science and Engineering*. 2023;11(10):2007.
 - [17] KhalafAnsar HM, Keighobadi J. A backstepping dynamic surface control strategy for nonlinear systems in non-strict feedback form. *Journal of Mechanical Engineering (University of Tabriz)*. 2024;56(1):61-67.
 - [18] Xie R, Dempster AG. An on-line deep learning framework for low-thrust trajectory optimization. *Aerospace Science and Technology*. 2021;118:107002.
 - [19] Federici L, Scorsoglio A, Zavoli A, Furfaro R. Meta-reinforcement learning for adaptive spacecraft guidance during finite-thrust rendezvous missions. *Acta Astronautica*. 2022;201:129-141.
 - [20] Wang H, Wang W, Yan J, Fu C, Liu W. Measurement and prediction of micronewton class thrust of electric propulsion based on the torsional pendulum and machine learning technique. *IEEE Transactions on Instrumentation and Measurement*. 2022;72:1-14.
 - [21] Salek PJ. Prediction of delivered and ideal specific impulse using random forest models and parsimonious neural networks [Master's thesis]. Purdue University; 2022.
 - [22] Marianacci A, Mazouffre S. Supervised machine learning-based Hall thruster scaling. *Journal of Electric Propulsion*. 2024;3(1):14.
 - [23] Patterson RL, Hammoud A, Elbuluk M, Culley D. Development of a temperature sensor for jet engine and space mission applications. In: *HiTEC 2008 High Temperature*

(انحراف معیار $R^2=0.9216$ برای اعتبارسنجی متقاطع ۵ تایی). برای استنباط شرایط عملیاتی به‌طور قابل توجه متفاوت (مثلاً، سوخت‌های مختلف، دماهای افراطی)، مدل نیاز به بازآموزی یا رویکردهای یادگیری انتقال دارد. مدل فعلی در محدوده داده‌های آموزشی قابل اعتمادترین است: $\dot{m} \in \text{mg/s}$, $P_e \in W$, $\eta \in [0.1, 0.3]$. برای برنامه‌های حیاتی از نظر ایمنی، توصیه می‌شود که میزان عدم قطعیت را از طریق روش‌های مجموعه‌ای یا شبکه‌های عصبی بیزین برای پیش‌بینی‌های خارج از توزیع آموزشی پیاده‌سازی شود.

در مجموع، مدل توسعه‌یافته در این تحقیق با بهره‌گیری از داده‌های آزمایشگاهی معتبر و استفاده بهینه از شبکه‌های عصبی و الگوریتم ژنتیک، قادر به تولید پیش‌بینی‌هایی دقیق، قابل اعتماد در نیروی رانش سیستم‌های رانش گاز سرد است. این ویژگی‌ها موجب می‌شود که مدل پیشنهادی به‌عنوان ابزاری مؤثر در تحلیل و بهینه‌سازی عملکرد پیش‌رانه‌های فضایی و سایر سیستم‌های مشابه در نظر گرفته شود. با توجه به نتایج به‌دست‌آمده، این تحقیق بر قابلیت‌های بالای الگوریتم‌های تکاملی و شبکه‌های عصبی در زمینه مدل‌سازی و پیش‌بینی سیستم‌های پیچیده تأکید دارد و می‌تواند به عنوان مبنای توسعه روش‌های نوین در طراحی و تحلیل سیستم‌های رانش الکتریکی مورد استفاده قرار گیرد.

جهت‌های تحقیق آینده شامل موارد زیر است: (۱) مدل‌سازی با چندین قابلیت اطمینان با ادغام پارامترهای هندسی نازل حاصل از CFD (قطر دهانه، نسبت گسترش، زاویه انحراف) به‌عنوان ورودی‌های اضافی، با استفاده از شبکه‌های عصبی آگاه از فیزیک (PINNs) برای گنجاندن معادلات حاکم به‌عنوان محدودیت‌های نرم؛ (۲) ادغام فشار محفظه از طریق تخمین حالت پویا، که در آن داده‌های سری زمانی فشار می‌توانند با استفاده از لایه‌های LSTM قبل از MLP پردازش شوند؛ (۳) استراتژی‌های کاهش نویز شامل خودکدگذاران حذف نویز ورودی و استفاده از فیلتر کالمن برای پیش‌پردازش سنسور به‌منظور کاهش انتشار نویز اندازه‌گیری؛ (۴) یادگیری انتقال برای تطبیق مدل آموزش‌دیده قبلی با سوخت‌های مختلف با حداقل داده‌های آموزشی اضافی، کاهش هزینه‌های آزمایشی برای مشخصه‌سازی سیستم جدید.

۵- سپاسگزاری

لازم است از پژوهشگاه فضایی ایران که حمایت مالی پژوهش را برعهده داشته است، قدردانی کنیم.

۶- تعارض منافع

هیچ‌گونه تعارض منافع بین نویسندگان این مقاله وجود ندارد.

۷- مراجع

- [1] Esho AOO, Iluyomade TD, Olatunde TM, Igbinenikaro OP. Electrical propulsion systems for satellites: A review of current technologies and future prospects. *International Journal of Frontiers in Engineering and Technology Research*. 2024;6(2):35-44.
- [2] Sabatini M, Palmerini GB. Mixed-integer GA optimization for the tracking control of a formation of small satellites equipped with multi-constrained electric thrusters. *Acta Astronautica*. 2023;202:1-8.
- [3] Gao D, Wang X, Wang T, Wang Y, Xu X. Optimal thrust allocation strategy of electric propulsion ship based on improved non-dominated sorting genetic algorithm II. *IEEE Access*. 2019;7:135247-135255.
- [4] Mughal AH, Chadalavada P, Munir A, Dutta A, Qureshi MA. Design of deep neural networks for transfer time prediction of spacecraft electric orbit-raising. *Intelligent Systems with Applications*. 2022;15:200092.
- [5] Zine El Abidine H, Tang HB, Wang Z. Data-driven modeling of miniature Hall thrusters: A machine learning approach. In:

- Electronics Conference/International Microelectronics and Packaging Society (IMAPS); 2008 May. No. E-16795.
- [24] Czyż Z, Karpiński P, Skiba K. Experimental study of propellers for the electric propulsion system. In: 2021 IEEE 8th International Workshop on Metrology for AeroSpace (MetroAeroSpace). IEEE; 2021. p. 682-686.
- [25] Mohammadian KhalafAnsar H, Keighobadi J, Shahhosseini M. Capsule-based federated reinforcement learning adaptive sliding mode for anomaly detection and control of floating wind turbines. PLOS ONE. 2025;20(12):e0336410.
- [26] Mohammadian KhalafAnsar H, Keighobadi J, Farhid M. Estimation of thrust force of cold gas propulsion using a multi-layer perceptron optimized by genetic algorithm. Engineering Research Express. 2025;7(4):045580.
- [27] KhalafAnsar HM, Keighobadi J. Adaptive inverse deep reinforcement Lyapunov learning control for a floating wind turbine. Scientia Iranica. 2023 [Epub ahead of print].
- [28] KhalafAnsar HM, Rohten J, Keighobadi J. A hybrid type-2 fuzzy double DQN with adaptive reward shaping for stable reinforcement learning. AI. 2025;6(12):319.