

Original Research Paper

Modeling *Spirulina* Microalgae in Space Missions Using Deep Q-Learning

Iman Shafieenejad^{1*} , Ali Mahmoodi² , and Amin Mirzapour Estabragh³ 

1. Aerospace Research Institute, Ministry of Science Research and Technology, Tehran, Iran

2, 3. Faculty of Engineering, Department of Aerospace Engineering, Islamic Azad University, Science and Research Branch, Tehran, Iran

ARTICLE INFO

Article History:

Received 29 November 2025

Revised 06 July 2026

Accepted 08 July 2026

Available Online 07 October 2026

Keywords:

Spirulina
Space Biology
Nutritional Supplement
Microgravity
Artificial Intelligence
Deep Q-Learning
Space Biotechnology

ABSTRACT

Ensuring a sustainable supply of food resources and effective atmospheric revitalization remains a critical challenge for long-duration space missions. This challenge is further complicated by the technical constraints and high costs associated with repeated in-orbit experimentation. In response, this study investigates and models the biological responses of *Spirulina* microalgae, a recognized protein-rich organism, under suborbital flight conditions, with the overarching goal of replacing conventional trial-and-error approaches with an intelligent predictive framework. To this end, experimental data capturing complex environmental stressors, including microgravity and distinct light wavelengths (red, white, and dark), were utilized to train an advanced neural network. Specifically, a Deep Q-Learning (DQN) algorithm was developed, incorporating mechanisms such as experience replay to mitigate data fluctuations and enhance learning stability, and was trained over 5,000 episodes. The results demonstrate the model's outstanding performance, achieving a coefficient of determination (R^2) exceeding 0.98 for all output indicators, while the root mean square error for light-related parameters fell below 0.013, indicating an excellent agreement between predictions and actual observations. Although minor fluctuations were observed in the prediction of time-dependent parameters, the overall convergence of the model confirms that artificial intelligence can serve as a reliable, cost-effective, and efficient tool for the automated monitoring and optimization of biological responses in future space probes and orbital stations. This work thus represents a meaningful step toward ensuring astronaut biosafety in deep-space exploration.

*Corresponding Author's E-mail: shafieenejad@ari.ac.ir

How to Cite this Article:

I. Shafieenejad, A. Mahmoodi, and A. Mirzapour Estabragh, "Modeling *Spirulina* Microalgae in Space Missions Using Deep Q-Learning," *Journal of Space Science and Technology*, Vol. VV, NN, pp. 1-20, 2026, <https://doi.org/10.22034/jsst.YYYY.1607>.



COPYRIGHTS

© 2026 by the authors. Published by Aerospace Research Institute. This article is an open access article distributed under the terms and conditions of [The Creative Commons Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).



مدلسازی رفتار میکرو جلبک اسپرولینا در ماموریت‌های فضایی با رویکرد یادگیری عمیق Q

ایمان شفیعی نژاد^۱، علی محمودی^۲، و امین میرزایی استبرق^۳

۱- استادیار، پژوهشگاه هوافضا، وزارت علوم تحقیقات و فناوری، تهران، ایران

۲- استادیار، گروه هوافضا، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران، تهران، ایران

۳- کارشناس ارشد، گروه هوافضا، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران، تهران، ایران

چکیده

اطلاعات مقاله

تاریخچه مقاله:

دریافت ۸ آذر ۱۴۰۴

بازنگری ۱۵ تیر ۱۴۰۵

پذیرش ۱۷ تیر ۱۴۰۵

اولین انتشار ۱۵ مهر ۱۴۰۵

واژه‌های کلیدی:

اسپرولینا

زیست فضا

مکمل غذایی

میکروگرنش

هوش مصنوعی

یادگیری عمیق

بیوتکنولوژی فضایی

تأمین پایدار منابع غذایی و تهویه اتمسفر در مأموریت‌های فضایی طولانی‌مدت از اهمیت حیاتی برخوردار است. افزون بر این، دشواری‌های فنی و اقتصادی انجام آزمایش‌های مکرر در فضا، این چالش را دوچندان می‌کند. در پژوهش حاضر، پاسخ‌های زیستی ریزجلبک/اسپرولینا به عنوان یک منبع غنی پروتئینی در شرایط پرواز زیرمداری بررسی و مدل‌سازی شده است. هدف اصلی، جایگزینی روش‌های سنتی آزمون و خطا با یک مدل هوشمند پیش‌بینی کننده بود. بدین منظور، از داده‌های تجربی شامل متغیرهای محیطی پیچیده نظیر گرانش-کم و اثرات طول موج‌های نوری مختلف (قرمز، سفید و تاریکی) برای آموزش یک شبکه عصبی پیشرفته استفاده گردید. در این راستا، الگوریتم یادگیری عمیق Q با بهره‌گیری از سازوکارهای نوین مانند بازپخش تجربه برای غلبه بر نوسانات داده‌ها و بهبود پایداری یادگیری توسعه یافت و طی ۵۰۰۰ مرحله آموزش دید. یافته‌های پژوهش نشان‌دهنده عملکرد دقیق مدل بود؛ به گونه‌ای که ضریب تعیین (R^2) برای تمامی شاخص‌های خروجی بیش از ۰.۹۸ به دست آمد و خطای ریشه میانگین مربعات در پارامترهای نوری به کمتر از ۰.۰۱۳ رسید که حاکی از انطباق بسیار دقیق پیش‌بینی‌ها با واقعیت است. اگرچه نوسانات مختصری در پیش‌بینی پارامترهای زمانی مشاهده شد، همگرایی کلی مدل اثبات کرد که استفاده از هوش مصنوعی می‌تواند به عنوان راهکاری مطمئن، کم‌هزینه و کارآمد برای نظارت خودکار در کاوشگرها و ایستگاه‌های فضایی آینده به کار گرفته شود و گامی مؤثر در جهت تضمین امنیت زیستی فضانوردان محسوب می‌گردد.

پست الکترونیکی نویسنده مسئول: shafieenejad@ari.ac.ir

How to Cite this Article:

I. Shafieenejad, A. Mahmoodi, and A. Mirzapour Estabragh, "Modeling *Spirulina* Microalgae in Space Missions Using Deep Q-Learning," *Journal of Space Science and Technology*, Vol. VV, NN, pp. 1-20, 2026, <https://doi.org/10.22034/jsst.YYYY.1607>.



COPYRIGHTS

© 2026 by the authors. Published by Aerospace Research Institute. This article is an open access article distributed under the terms and conditions of [The Creative Commons Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).



مقدمه

اسپیرولینا^۱ به عنوان یک میکروچلیک آبی-سبز با محتوای پروتئینی بالا است. ظرفیت فتوسنتزی قوی و توانایی رشد در شرایط نسبتاً سخت، به عنوان یک گزینه جذاب برای سیستم‌های بسته پشتیبانی حیات در مأموریت‌های فضایی و نیز تولید پایدار مواد غذایی و ترکیبات زیستی فعال بررسی شده است. مطالعات ناسا از دهه ۱۹۸۰ به طور ویژه روی عملکرد اسپیرولینا برای تأمین غذا، تولید اکسیژن و بازیافت دی اکسید کربن در سیستم‌های بسته فضایی مانند ایستگاه فضایی تمرکز داشته اند. این تحقیقات هم چالش‌های فنی کشت در گرانش-کم را نشانه گذاری کرده و هم راهکارهای مهندسی برای بازیابی گازها و بهره برداری از زیست توده را پیشنهاد داده اند.

تحقیقات اولیه ناسا به طور آزمایشی نشان دادند که اسپیرولینا می‌تواند در بیو راکتورهای کنترل شده به صورت مؤثر اکسیژن تولید کرده و نقش مهمی در تبادل گازها ایفا کند. در این مطالعات به علت اینکه تجهیزات مکانیکی سنتی در فضا کارآمدی لازم را ندارند، روش‌های غشایی جدا سازی گاز به عنوان راه حلی مناسب برای شرایط گرانش-کم مطرح شده است [۱]. آزمایش‌های شبیه سازی شده با نظارت پیوسته طیف‌های نوری، دما و ترکیب گازی نشان دادند که با کنترل دقیق محیط، کشت بسته اسپیرولینا قابل پایدار سازی است و جدا سازی غشایی توانایی بر آورده کردن نیازهای عملیاتی مأموریت‌ها را دارد [۲].

علاوه بر جنبه‌های مهندسی، پژوهش‌ها به تغییر ترکیب شیمیایی اسپیرولینا از طریق تنظیم شرایط رشد پرداخته اند تا کیفیت تغذیه ای زیست توده بهینه شود. در آزمایش‌های کنترل شده، تغییرات در نور، دما و کمبودهای تغذیه ای باعث تغییرات معنی دار در درصد پروتئین، کربوهیدرات و لیپید شدند. به عنوان مثال، در شرایط بهینه پروتئین تا نزدیک ۷۰٪ وزن گزارش شده است، در حالی که تنش محیطی سهم کربوهیدرات را افزایش می‌دهد که نشان‌دهنده پاسخ متابولیکی جلبک است. این قابلیت تنظیم ترکیب نشان می‌دهد که اسپیرولینا را می‌توان برای تولید اهداف تغذیه ای خاص (مثلاً بالابردن شاخص پروتئینی) به گونه ای کشت کرد که برای مأموریت‌های طولانی مدت فضایی مناسب باشد.

مطالعات پیش پروازی و مأموریتی نیز به بررسی پایداری رشد و تغییرات چند ساختی اسپیرولینا پرداخته اند. نتایج اولیه نشان می‌دهد که اسپیرولینا می‌تواند برای دوره‌های چند ماهه تولید زیست توده داشته باشد. لذا نرخ رشد و دوره چرخه کشت در بعضی شرایط فضایی طولانی تر می‌شود و نیاز به تنظیمات ویژه دارد. آزمایش‌های شبیه سازی

عملکردی شرایط پیش پرواز ماه، و همچنین تحلیل‌های چند وجهی برای ارزیابی جهش‌ها و تغییرات متابولیکی، زیر ساخت علمی لازم برای کاربرد فضایی اسپیرولینا را تقویت کرده‌اند [۳].

در کنار تلاش‌های تجربی و مهندسی، نقش هوش مصنوعی و فناوری‌های نوین داده محور در بهینه سازی کشت اسپیرولینا رو به افزایش است. مطالعات متعددی مدل‌های فازی-عصبی، شبکه‌های عصبی مصنوعی و الگوریتم‌های یادگیری عمیق را به کار گرفته اند تا پیش‌بینی تولید ترکیبات فنولی، زیست توده، و شرایط مطلوب کشت را دقیق‌تر کنند. در این راستا، پژوهشی نشان داد که مدل فازی-عصبی و رگرسیون مرحله ای در پیش‌بینی ترکیبات فنولی عملکرد نسبتاً خوبی داشتند و می‌توانند شرایط محیط کشت را برای بهینه سازی تولید ترکیبات زیست فعال پیشرفت دهند [۴]. در مطالعات دیگر، شبکه‌های عصبی مصنوعی برای پیش‌بینی تولید زیست توده در کشت‌های فضای باز به کار رفتند و دقت‌های بالایی گزارش شد که می‌تواند در برنامه ریزی زمان برداشت و مدیریت منابع مفید باشد [۵].

افزون بر آن، یادگیری عمیق برای تشخیص خودکار اسپیرولینا از تصاویر میکروسکوپی به کار رفته است. در یکی از این مطالعات، شبکه کانولوشنی با افزایش مصنوعی داده‌ها توانست گونه‌های اسپیرولینا را با دقت بسیار بالا طبقه بندی کند که این ابزار می‌تواند در نظارت بالادرنگ و خودکار بر کیفیت زیست توده در سیستم‌های بسته مفید باشد [۵]. در مقیاس عملیاتی تر، ترکیب اینترنت اشیا با شبکه‌های عصبی برای بهینه سازی کشت با استفاده از پساب صنایع (مثلاً پساب روغن نخل) نشان داده که می‌توان با کنترل خودکار پارامترها و پیش‌بینی شرایط، بازده زیست توده را افزایش داد و در عین حال اثرات زیست محیطی را کاهش داد [۶]. همچنین اهمیت آزمایش‌های پروازی کوتاه مدت مثل پروازهای زیر مداری برای سنجش پاسخ‌های مولکولی و رشد اسپیرولینا تأیید شده است. تجربیات زیر مداری نشان می‌دهد که گرانش-کم و شرایط پروازی می‌توانند بیان ژن‌ها و رفتار رشد را تغییر دهند (مثلاً تفاوت‌های قابل توجه در زیست توده تحت نورهای مختلف) و نشان می‌دهد که بهینه سازی نور، شرایط تغذیه ای و پروتکل‌های نگهداری برای کاربرد فضایی ضروری است [۷].

چنانچه دقیق تر بیان شود، گیاه اسپیرولینا از جنس *Arthrospira* یک سیانوباکتری رشته‌ای فتوسنتز کننده با ساختار مارپیچی مشخص است که به دلیل دارا بودن پروتئین بالا (۵۱ تا ۷۰ درصد وزن خشک)، تمامی اسیدهای آمینه ضروری، ویتامین‌ها (مانند B12 و بتاکاروتن)، مواد معدنی (آهن، کلسیم، منیزیم) و رنگ دانه‌های آنتی اکسیدانی (فیکوسیانین) به عنوان یک فرا غذای بالقوه در

^۱ (*Arthrospira/Spirulina*)

یاد بگیرد. این شکاف پژوهشی، انگیزه اصلی پژوهش حاضر را برای استفاده از داده‌های واقعی مأموریت زیرمداری و الگوریتم یادگیری عمیق کیو^۲ جهت مدل‌سازی و بهینه‌سازی رشد/اسپیرولینا در شرایط فضایی تشکیل می‌دهد.

یکی از انگیزه‌های اصلی در انجام این پژوهش و همکاری با نهادهای پیشرو در عرصه هوافضا، بهره‌گیری از ظرفیت‌های فناورانه موجود جهت توسعه زیر ساخت‌های پرواز زیرمداری و مطالعات زیست فضای^۳ است. با توجه به اینکه آزمایش‌های زیستی در فضا فرایندی بسیار پرهزینه، زمان‌بر و پیچیده محسوب می‌شود، استفاده از داده‌های معتبر علمی جهت مدل‌سازی رایانه‌ای و شبیه‌سازی هوشمند، راهکاری راهبردی برای کاهش ریسک و صرفه‌جویی در منابع است. مدل آموزش دیده در این روش‌ها می‌تواند به عنوان یک ابزار پیش‌بینی‌کننده در طراحی مأموریت‌های آتی و بهینه‌سازی محموله‌های زیستی مورد بهره‌برداری قرار گیرد و ارزش افزوده قابل توجهی در زنجیره توسعه دانش فضایی ایجاد نماید[۱۲]. از منظر سخت‌افزاری، کاوشگرها به عنوان بازوهای رباتیک اکتشافات فضایی، نقشی حیاتی در گذار از مشاهدات صرف به تعامل با محیط ایفا می‌کنند. این سامانه‌ها که برای مأموریت‌های متنوعی از تصویر برداری سطحی تا تحلیل‌های ژئوشیمیایی (مانند مأموریت‌های مریخ‌نورد) طراحی شده‌اند، اکنون در حال تکامل به سمت میزبانی از آزمایشگاه‌های زیستی کوچک مقیاس هستند. نسل جدید کاوشگرهای زیست پایه، قابلیت حمل بیو راکتورهای مینیاتوری حاوی ریز جلیک‌هایی نظیر اسپیرولینا را دارا می‌باشند که به عنوان هسته مرکزی سامانه‌های زیست پشتیبان بسته عمل می‌کنند[۱۳]. تلفیق عملکرد این کاوشگرها با الگوریتم‌های هوش مصنوعی، امکان نظارت بلادرنگ و خودکار را فراهم می‌آورد. حسگرهای تعبیه شده در کاوشگر، داده‌های حیاتی نظیر دما، شدت تابش و غلظت گازها را به صورت پیوسته پایش کرده و اطلاعات لازم برای مدل‌های پیش‌بینی‌کننده (مانند مدل پیشنهادی در این پژوهش) را تأمین می‌کنند. مزیت راهبردی استفاده از کاوشگرها، توانایی آن‌ها در عملیات مستقل تحت شرایط سخت محیطی (مانند نوسانات شدید حرارتی و تابشی در سطح ماه یا مریخ) است؛ شرایطی که داده‌های واقعی و ارزشمندی را برای اعتبار سنجی مدل‌های رشد زیستی و تضمین خودکفایی در سکونتگاه‌های فرازمینی آینده فراهم می‌آورد.

پژوهش‌های پیشین ناسا از دهه ۱۹۸۰، قابلیت اسپیرولینا را برای استفاده در بیوراکتورهای فضایی تأیید کرده‌اند، هرچند چالش‌هایی نظیر اثر گرانش-کم بر رشد و نیاز به بهینه‌سازی شرایط نوری همچنان باقی است. مطالعات اخیر نشان داده‌اند که طیف‌های نوری مختلف (قرمز،

سیستم‌های بسته پشتیبانی حیات شناخته می‌شود. توانایی رشد در محیط‌های قلیایی و گرم، تحمل نسبی به تنش‌های محیطی و نرخ فتوسنتز اکسیژنی بالا، این ریزجلیک را به انتخابی مناسب برای تأمین همزمان غذا، تولید اکسیژن و جذب دی‌اکسیدکربن در مأموریت‌های فضایی طولانی مدت تبدیل کرده است.

پژوهش‌های متعددی به کارگیری روش‌های هوش مصنوعی و یادگیری ماشین را برای بهینه‌سازی کشت ریزجلیک‌ها و به ویژه اسپیرولینا مورد توجه قرار داده‌اند. در مرجع [۵] قاسمی و همکاران با تمرکز بر تنش‌های غیر زنده نظیر گرانش و تشعشع در سفرهای فضایی، تأثیر این عوامل محیطی را بر رشد گیاه مدل بررسی کردند و اهمیت درک پاسخ‌های زیستی به شرایط فضایی را برای مأموریت‌های بلند مدت انسانی نشان دادند. در پژوهشی دیگر [۸]، دوآن و همکاران یک روش یادگیری تقویتی وابسته به زمان را با پیش‌بینی وضعیت توسط شبکه حافظه LSTM برای بهینه‌سازی رشد گیاه/اسپیرولینا ارائه کردند. شبیه‌سازی‌های مرجع فوق نشان داد که الگوریتم پیشنهادی تحت شرایط نوری یکسان، بازدهی را ۱۷ درصد نسبت به روش سنتی و ۱۰ درصد نسبت به روش آستانه‌ای افزایش می‌دهد. در مرجع [۹] لامیا و همکاران نیز از منظر مدل‌سازی به بررسی مدل‌های رشد ریزجلیک با تأکید بر عوامل محیطی نظیر شدت و توزیع نور، دما و غلظت مواد مغذی پرداختند و نقش فتو بیو راکتورهای مختلف را در بهینه‌سازی تولیدات مبتنی بر جلیک با استفاده از مدل‌های مقیاس ژنومی تشریح کردند. در مجموع، پژوهش‌های یاد شده اگرچه پیشرفت‌های قابل توجهی در بهبود کشت اسپیرولینا با رویکردهای هوشمند داشته‌اند، اما هیچ یک از داده‌های واقعی پرواز فضایی (با شرایط گرانش-کم و ضربه‌های مکانیکی) بهره‌برداران و عمدتاً بر شبیه‌سازی‌های عددی یا داده‌های زمینی متکی بوده‌اند. همچنین پنگ و همکاران [۱۰] نیز رویکردی مبتنی بر شبکه‌های عصبی کانولوشنی عمیق CNN را برای تخمین کمی زیست‌توده ریزجلیک با استفاده از پردازش تصاویر میکروسکوپی ارائه دادند که دقت بالایی در تشخیص و کمیت سنجی رشد جلیکی نشان داد. در ادامه، ووزنیاک و همکاران [۱۱] در سال ۲۰۲۵ پیرو مطالعه مروری جامع خود، استراتژی‌های مختلف کنترل کشت جلیک شامل سیستم‌های با شرایط ثابت، روش‌های مبتنی بر قوانین، کنترل پیش‌بینی مدل و بازخورد تطبیقی را مقایسه کردند. آنان یادگیری تقویتی^۱ را به عنوان راهکاری دقیق برای بهینه‌سازی پویا و بلادرنگ متغیرهایی نظیر نور، دما، pH و اکسیژن محلول معرفی نمودند و تأکید کردند که یادگیری عمیق بر خلاف روش‌های سنتی مبتنی بر قوانین ایستا، می‌تواند با تعامل با محیط، خط‌مشی‌های کنترلی را به صورت خودکار

³ Astrobiology

¹ Reinforcement Learning

² Deep Q-Learning

بلمن، بازپخش تجربه و سیاست حریصانه با ضریب کاوش) قادر است به طور خودکار و بدون نیاز به دانش پیشین از دینامیک سیستم، بهترین توالی از اقدامات نوری را برای بیشینه‌سازی رشد در محیط فضایی کشف کند و یک مدیریت خودکار انتخاب طیف نوری را ارائه دهد. پژوهش حاضر برای نخستین بار اثر متقابل نور (قرمز، سفید، تاریکی) و گرانش-کم را در قالب یک تابع ارزش کیو3 مدل می‌کند و نشان می‌دهد که ضریب تعیین بالای ۰.۹۹ در کنار خطای کمتر از ۰.۱۳ برای پارامترهای نوری، بیانگر برتری آشکار این رویکرد نسبت به مدل‌های خطی یا شبکه‌های عصبی نظارت شده در شبیه‌سازی رفتار غیرخطی و تنش پذیر اسپرولینا است. به این ترتیب، پژوهش حاضر پلی میان زیست فناوری فضایی و یادگیری تقویتی عمیق ایجاد کرده و گامی فراتر از پیش‌بینی به سوی کنترل هوشمند و مدیریت خودکار سامانه‌های زیستی در ماموریت‌های فضایی آینده محسوب خواهد شد.

بر این اساس، نوآوری اصلی پژوهش حاضر در سه محور قابل خلاصه‌سازی است. نخست، به کارگیری الگوریتم یادگیری عمیق کیو برای مدل‌سازی رشد/اسپرولینا در شرایط فضایی است؛ رویکردی که برخلاف پژوهش‌های پیشین که عمدتاً از شبکه‌های عصبی نظارت‌شده یا مدل‌های فازی-عصبی یا یادگیری تقویتی صرفاً برای پیش‌بینی ایستا استفاده کرده‌اند، قادر است با تعامل با محیط و دریافت بازخورد پاداش، بهترین کنش‌های کنترلی (انتخاب طیف نوری مناسب) را به صورت تطبیقی بیاموزد. دوم، استفاده از داده‌های واقعی حاصل از یک ماموریت پرواز زیرمداری (شامل شرایط گرانش-کم، ضربه‌های مکانیکی بازگشت و نوسانات شدید محیطی) به جای داده‌های آزمایشگاهی زمینی است. ویژگی‌ای که مدل ارائه شده را از پژوهش‌های مشابه که در شرایط زمینی یا شبیه‌سازهای ایستا انجام شده‌اند متمایز می‌کند. سوم، ارائه معماری مشخص و کاملاً مستند از شبکه (تعداد لایه‌ها، نورون‌ها، توابع فعال‌سازی)، فراپارامترهای یادگیری تقویتی (ضریب تخفیف، نرخ یادگیری، سیاست ε-greedy) و مکانیزم بازپخش تجربه است که همگی به صورت شفاف در بخش روش شناسی تشریح شده‌اند. این ویژگی‌ها در کنار یکدیگر، مزیت پژوهش حاضر را نسبت به پژوهش‌های هم‌رده در دو سطح دقت پیش‌بینی و قابلیت تصمیم‌گیری پویا (انتخاب خودکار شرایط نوری بهینه) جهت مدیریت خودکار رشد گیاه تثبیت می‌کند و گامی فراتر از پیش‌بینی صرف به سوی کنترل هوشمند سامانه‌های زیستی در ماموریت‌های فضایی آینده محسوب می‌شود.

سفید، سیاه) می‌توانند پاسخ‌های رشدی متفاوتی را در شرایط گرانش-کم ایجاد کنند. با این حال، فقدان یک مدل پیش‌بینی‌کننده و تصمیم ساز هوشمند که بتواند به جای روش‌های آزمون و خطای پرهزینه، شرایط بهینه کشت را در محیط پویای فضا تعیین کند، انگیزه اصلی پژوهش حاضر است. در این راستا، از داده‌های تجربی ماموریت زیرمداری برای آموزش یک الگوریتم یادگیری عمیق کیو استفاده شده است تا گامی به سوی کشت با مدیریت خودکار و بهینه/اسپرولینا در ماموریت‌های فضایی آینده برداشته شود[۱۴].

تفاوت رویکرد پژوهش حاضر با پژوهش‌های پیشین را می‌توان به این گونه مطرح کرد که پژوهش‌های پیشین عمدتاً از شبکه‌های عصبی پیشخور ساده^۱، مدل‌های فازی-عصبی، ترکیب اینترنت اشیا با شبکه‌های عصبی یا یادگیری تقویتی برای پیش‌بینی ایستا (فقط نگاشت ورودی به خروجی) تولید زیست‌توده یا ترکیبات فنولی اسپرولینا در شرایط زمینی استفاده کرده‌اند، نوآوری اصلی پژوهش حاضر در دو جنبه کلیدی خلاصه می‌شود. نخست، به کارگیری یادگیری تقویتی عمیق کیو به جای یادگیری نظارت شده است. این تغییر رویکرد، مدل را از یک پیش‌بینی‌کننده منفعل به یک عامل هوشمند تصمیم‌گیرنده تبدیل می‌کند که قادر است با تعامل با محیط پویای فضا و دریافت پاداش، سیاست بهینه کنترلی (مانند انتخاب طیف نوری مناسب در هر لحظه) را بیاموزد. این موضوع قابلیت است که در مدل‌های پیشین وجود نداشته است. دوم، برخلاف پژوهش‌هایی که بر پایه داده‌های آزمایشگاهی زمینی یا حوضچه‌های باز انجام شده‌اند، پژوهش حاضر از داده‌های واقعی یک ماموریت فضایی زیر مداری^۲ استفاده کرده است که شامل شرایط منحصر به فردی نظیر گرانش-کم، ضربه‌های مکانیکی بازگشت به جو و نوسانات طیف نوری ناشی از محیط عملکردی فضا می‌باشد. این ویژگی، مدل را به نخستین معماری یادگیری تقویتی عمیق برای شبیه‌سازی رشد اسپرولینا در شرایط واقعی ماموریت فضایی تبدیل می‌کند.

پیشرفت اصلی این پژوهش نسبت به وضعیت دانش موجود، فراتر رفتن از پیش‌بینی صرف و ورود به حیطه بهینه‌سازی کنش‌های کنترلی در زمان واقعی است. مدل‌هایی مانند شبکه عصبی مصنوعی، یا مدل فازی-عصبی اگرچه دقت قابل قبولی در پیش‌بینی تولید زیست‌توده یا ترکیبات فنولی داشته‌اند، اما هیچ مکانیزمی برای تصمیم‌گیری پشت سرهم و تطبیق با شرایط پیش‌بینی‌نشده ارائه نمی‌دهند [۵]. در مقابل، روش پیشنهادی این پژوهش با بهره‌گیری از چارچوب یادگیری تقویتی (شامل معادله

تحلیل اثرات زیستی پروازهای زیر مداری بر فیزیولوژی اسپیرولینا

یکی از پژوهش‌های شاخص در زمینه بررسی امکان سنجی استفاده از میکرو جلبک‌ها در مأموریت‌های فضایی، مطالعه لانوس و همکاران در سال ۲۰۲۲ است. در این تحقیق، برای نخستین بار اثر پرواز زیر مداری بر رشد و پاسخ‌های مولکولی میکرو جلبک *اسپیرولینا* بررسی شد. هدف اصلی پژوهش، ارزیابی توانایی *اسپیرولینا* برای بقا، رشد و سازگاری در شرایط پرواز فضایی کوتاه مدت بود. شرایطی که به دلیل فراهم کردن گرانش-کم، تابش و تغییرات شدید محیطی، شباهت نسبی به مأموریت‌های آینده در مدار پایین زمین و حتی سفرهای فزاینده دارد [۱۵].


در این آزمایش، نمونه‌های اسپیرولینا در یک محفظه ویژه موسوم به نانولب قرار گرفتند. این نانولب به حسگرهای دقیق برای ثبت دما، رطوبت نسبی و شتاب مجهز بود تا داده‌های پروازی به طور هم زمان ثبت و تحلیل شوند. نمونه‌ها با شرایط نوری متفاوت شامل نور قرمز (۱۱۰۰ لوکس)، نور سفید (۸۷۵ لوکس) و تاریکی کامل کشت داده شدند. پرواز در تاریخ ۲ مه ۲۰۱۹ با استفاده از فضاپیما نیو شپرد متعلق به شرکت بلو اوریجین^۱ انجام شد و پرتابه به ارتفاع بیش از ۱۰۵ کیلومتر رسید. در طول پرواز، شرایط گرانش-کم به مدت تقریبی ۴/۳ دقیقه برقرار بود و داده‌های حسگرها نشان دادند که بیشینه شتاب ثبت شده برابر با ۲.۱۶ g و در زمان باز شدن چتر نجات حتی تا حدود ۷ افزایش یافته است.

نتایج حاصل از این پژوهش از چند منظر حائز اهمیت بود نمونه‌های پروازی کاهش معناداری در بیان ژن‌های مرتبط با انتقال منیزیم و نیترات نشان دادند. این تغییرات بیانگر آن بود که پرواز و شرایط گرانش-کم می‌توانند به طور مستقیم بر فرآیندهای زیستی و مسیریهای متابولیکی *اسپیرولینا* اثر بگذارند.


داده‌های کمی نشان داد که زیست توده حاصل از نمونه‌های پروازی نسبت به نمونه‌های کنترل تفاوت چشمگیری داشت. برای مثال، در شرایط نور قرمز، مقدار زیست توده در نمونه‌های کنترل ۱.۵۴۶ گرم بر لیتر بود در حالی که همین مقدار در نمونه‌های پروازی تنها ۰.۵۸۴ گرم بر لیتر گزارش شد. این اختلاف قابل توجه نشان دهنده حساسیت اسپیرولینا به ترکیب شرایط پروازی و نور قرمز بود. در مقابل، در نور سفید و تاریکی، نمونه‌های پروازی به ترتیب ۲۵٪ و ۲۱٪ افزایش زیست توده نسبت به کنترل داشتند که بیانگر سازگاری بهتر اسپیرولینا در این شرایط است.

تصاویر میکروسکوپی نشان دادند که ساختار سلولی در نمونه‌های پروازی تحت نور سفید و تاریکی انسجام بیشتری نسبت به شرایط نور قرمز داشت. این یافته‌ها نشان دادند که نور قرمز اگرچه از دیدگاه فتوسنتزی سودمند است، اما در شرایط پروازی ممکن است استرس زیستی بیشتری ایجاد کند. در نمونه‌های پروازی تحت نور قرمز، مقدار pH کاهش یافته و سطح آمونیاک افزایش یافته بود که این خود نشانه‌ای از فشار محیطی و استرس متابولیکی است. به طور کلی، این مطالعه اهمیت دو گانه ای داشت. از یک سو نشان داد که *اسپیرولینا* قادر به بقا و رشد در شرایط پرواز زیر مداری است و همچنان می‌تواند به عنوان یک منبع غذایی پایدار در نظر گرفته شود. از سوی دیگر، آشکار شد که نوع نور و شدت آن نقش تعیین‌کننده ای در موفقیت یا ناکامی رشد این میکرو جلبک در فضا دارد.


همان‌طور که در شکل (۱) مشاهده می‌شود، نمونه‌های زیستی در فاز بازگشت جوی تحت تأثیر نیروهای دینامیکی شدیدی قرار گرفته‌اند. نمودارهای (ه) و (و) به ترتیب لحظات بحرانی گشوده شدن چترهای نجات و فرود نهایی را به تصویر می‌کشند.



(ه)




(و)




(ز)


نشان می دهد که ناشی از تغییرات ارتفاع و عملکرد سامانه‌های داخلی فضاییماست.




(الف)




(ب)



(ج)



(د)



(ح)

شکل ۱ - نمایه‌های تغییرات شتاب گرانشی ثبت شده در محموله زیستی طی فازهای بحرانی بازگشت فضاییما؛ (ه) لحظه گشوده شدن چتر نجات، (و) لحظه فرود و برخورد با زمین، (ز) و (ح) داده‌های تطبیقی حسگرهای تعبیه شده درون قاب نگه دارنده محموله [۱۵].

Fig. 1. Profiles of gravitational acceleration variations recorded in the biological payload during the critical phases of spacecraft return: (h) the moment of parachute deployment, (v) the moment of landing and impact with the ground, and (z) and (h) the adaptive data from the sensors embedded inside the payload holding frame .

نوسانات ناگهانی و دامنه‌های بلند ثبت شده در این نمودارها بیانگر اعمال نیروهای گرانشی لحظه ای (ضربه) و تکانه‌های شدید بر محیط کشت مایع است. این نیروها می توانند موجب تلاطم هیدرودینامیکی درون محفظه شده و تنش‌های برشی قابل توجهی را به دیواره سلولی اسپرولینا وارد نمایند. همچنین، نمودارهای (ز) و (ح) که توسط حسگرهای مستقل داخلی ثبت شده‌اند، صحت و پیوستگی این تنش‌های مکانیکی را در طول مأموریت تأیید می کنند. در مدل سازی ارائه شده در این پژوهش، این پروفایل‌های شتاب به عنوان متغیرهای ورودی مؤثر بر نرخ بقا و یکپارچگی سلولی در نظر گرفته شده اند، چراکه تخریب ساختاری مشاهده شده در نمونه‌های نوری (به ویژه نور قرمز) همبستگی مستقیمی با این شوک‌های مکانیکی دارد.

داده‌های تجربی استخراج شده از حسگرهای پروازی که در شکل (۲) منعکس شده‌اند، زیر بنای محاسباتی اصلی پایگاه داده جهت آموزش مدل هوشمند در این پژوهش را تشکیل می دهند. این مجموعه داده‌ها به دلیل ثبت پیوسته و هم زمان متغیرهای فیزیکی و پاسخ‌های بیولوژیک، از ارزش منحصر به فردی برای الگوریتم‌های یادگیری ماشین برخوردارند. نمودارهای (الف) تا (ج) که نوسانات حرارتی و شدت نور را در بازه‌های زمانی مختلف (پیش پرواز، پرواز زیر مداری و پس پرواز) ترسیم می کنند، نشان دهنده ناپایداری ذاتی محیط مأموریت هستند. به طور خاص، پروفایل دمایی در طول فاز پروازی رفتاری غیر یکنواخت از خود

خروجی‌های زیستی، امکان شبیه‌سازی شرایطی را که آزمایش تجربی آن‌ها انجام نشده است، فراهم می‌آورد.

شبکه معرفی الگوریتم یادگیری عمیق Q

مبانی نظری

شبکه‌های عصبی مصنوعی به دلیل توانایی در تقریب توابع غیرخطی پیچیده، ابزاری کارآمد برای مدل‌سازی سیستم‌های زیستی نظیر رشد ریزجلیک‌ها تحت تأثیر متغیرهای محیطی متعدد هستند. یادگیری تقویتی شاخه‌ای از یادگیری ماشین است که در آن یک عامل هوشمند از طریق تعامل با محیط و دریافت بازخورد (پاداش یا جریمه) رفتار خود را اصلاح می‌کند [۱۶]. الگوریتم یادگیری کیو یکی از روش‌های بنیادین در این حوزه است که ارزش هر زوج وضعیت-کنش را در یک جدول ذخیره می‌کند و با استفاده از معادله بلمن به‌روزرسانی می‌شود. اما در مسائل با فضای وضعیت پیوسته و بزرگ (مانند کنترل زیست‌سامانه فضایی)، ذخیره جدول عملاً غیرممکن است. راه حل، استفاده از یادگیری عمیق (کیو) است که در آن یک شبکه عصبی عمیق به عنوان تقریب‌زن تابع Q عمل می‌کند و به جای جدول، پارامترهای شبکه (وزن‌ها) را ذخیره می‌نماید [۱۵].


در این پژوهش، یک عامل هوشمند مبتنی بر الگوریتم یادگیری عمیق کیو برای پیش‌بینی و بهینه‌سازی رشد اسپیرولینا در شرایط پرواز زیرمداری طراحی و پیاده‌سازی گردید. جزئیات معماری و فرآیندها به شرح زیر است:

فضای وضعیت^۱

بردار وضعیت s از سه مؤلفه تشکیل شده است: (الف) شاخص زمان، (ب) نوع طیف نوری (کدگذاری شده به صورت ۰ برای تاریکی، ۱ برای نور سفید، ۲ برای نور قرمز)، (ج) مقدار رشد گیاه لحظه‌ای (اندازه‌گیری شده توسط حسگرهای محموله). همچنین مقادیر دما و شتاب (شکل‌های ۴ و ۵) به عنوان داده‌های محیطی ضمنی در آموزش اثرگذار بوده‌اند.

فضای کنش^۲

مجموعه کنش‌های a شامل انتخاب نوع طیف نوری برای مرحله زمانی بعدی (سه کنش گسسته: قرمز، سفید، تاریکی) و نیز تنظیم شدت نور در محدوده قابل اعتماد (مقادیر پیوسته) می‌باشد. در پیاده‌سازی عملی، کنش‌ها به صورت گسسته-پیوسته ترکیبی در نظر گرفته شدند.



(ه)

شکل ۲- پایش پارامترهای محیطی و شاخص‌های رشد زیستی در طول مأموریت؛ (الف) تا (ج) تغییرات زمانی پروفایل‌های دمایی و شدت تابش نور در مراحل پیش پرواز، حین پرواز و پس پرواز، (د) و (ه) منحنی‌های نرخ رشد زیست توده اسپیرولینا به ترتیب تحت تیمارهای نوری قرمز و سفید [۱۵].

Fig. 2. Monitoring of environmental parameters and biological growth indicators throughout the mission: (a) to (c) the temporal variations of temperature profiles and light intensity during the pre-flight, in-flight, and post-flight phases; (d) and (e) the biomass growth rate curves of *Spirulina* under red and white light treatments, respectively.

در معماری شبکه عصبی پیشنهادی، این سری‌های زمانی به عنوان مؤلفه‌های بردار وضعیت در نظر گرفته شده‌اند؛ بدین معنا که مدل به جای دریافت یک عدد میانگین برای دما، با توالی پویایی از تغییرات حرارتی مواجه می‌شود و می‌آموزد که چگونه شوک‌های حرارتی کوتاه مدت می‌توانند مسیرهای متابولیک جلبک را تحت الشعاع قرار دهند. از سوی دیگر، منحنی‌های نرخ رشد زیست توده که در نمودارهای (د) و (ه) نمایش داده شده‌اند، نقش حقیقت مینا را در فرایند یادگیری ایفا می‌کنند و تفاوت‌های چشمگیر رفتار بیولوژیک تحت تیمارهای نوری مختلف را آشکار می‌سازند. تحلیل نمودار (د) مربوط به نور قرمز، حاکی از وقوع نوعی رکود یا بازدارندگی رشد است که می‌تواند ناشی از برهم کنش منفی میان طیف نوری تک رنگ و تنش‌های محیطی باشد؛ این داده‌ها به مدل می‌آموزند که در شرایط نوری خاص، حتی با وجود دمای مناسب، رشد می‌تواند متوقف گردد. در نقطه مقابل، روند صعودی و پایدار رشد در نمودار (ه) تحت نور سفید، الگوی سازگاری و تاب آوری را به شبکه معرفی می‌کند. این تضاد رفتاری آشکار میان دو نمودار، مهم‌ترین ویژگی غیرخطی است که الگوریتم یادگیری عمیق کیو باید قادر به شناسایی و تفکیک آن باشد. در واقع، هدف نهایی مدل آن است که با دریافت ورودی‌های محیطی (دما و زمان)، بتواند دقیقاً پیش‌بینی کند که سیستم زیستی در مسیر رشد (مانند نمودار ه) یا در مسیر زوال (مانند نمودار د) قرار خواهد گرفت. بدین ترتیب، این نگاشت دقیق میان ورودی‌های فیزیکی و

تابع پاداش^۱

پاداش لحظه‌ای r_t به صورت منفی میانگین مربعات خطای (MSE) بین رشد گیاه پیش‌بینی شده توسط شبکه و مقدار واقعی ثبت شده از حسگرها تعریف می‌گردد (B رشد گیاه را نشان می‌دهد).

$$r_t = -(\hat{B}_t - B_{real,t})^2 \quad (1)$$

بدین ترتیب، هرچه خطای پیش‌بینی کمتر باشد، پاداش (که عددی منفی است) به صفر نزدیک‌تر شده و مطلوبیت بیشتری دارد.

معماری شبکه عصبی تقریب‌زن Q

شبکه عصبی مورد استفاده از نوع پیشخور^۲ با ساختار زیر است:

- لایه ورودی: ۵ نورون (دریافت وضعیت شامل زمان نرمال‌شده، زیست‌توده نرمال‌شده، نوع نور، دما و شتاب).
- لایه پنهان اول: ۱۲۸ نورون با تابع فعال‌سازی ReLU.
- لایه پنهان دوم: ۶۴ نورون با تابع فعال‌سازی ReLU.
- لایه خروجی: ۳ نورون و مقدار Q برای هر سه کنش نوری (بدون تابع فعال‌سازی (خروجی خطی)). شبکه به روش گرادینت کاهشی تصادفی^۳ با بهینه‌ساز Adam و نرخ یادگیری $\alpha = 0.001$ آموزش داده شده است. همچنین تابع هزینه، میانگین مربعات خطای تفاوت زمانی^۴ می‌باشد.

پارامترهای یادگیری تقویتی

- ضریب تخفیف $\gamma = 0.99^5$ اهمیت پاداش‌های آینده در مقابل آنی.
- نرخ یادگیری^۶ $\alpha = 0.001$
- سیاست انتخاب کنش^۷ سیاست ϵ -greedy با مقدار اولیه $\epsilon = 1.0$ که در طول آموزش به صورت خطی تا $\epsilon_{min} = 0.01$ کاهش می‌یابد. بدین ترتیب، در ابتدا کاوش (اکتشاف) حداکثر است و به تدریج بهره‌برداری غالب می‌شود.
- شبکه هدف^۸: برای پایداری آموزش، یک کپی از شبکه اصلی هر ۱۰۰ گام به روز می‌شود.
- بازپخش تجربه^۹: حافظه با ظرفیت ۱۰۰۰۰ تجربه (وضعیت، کنش، پاداش، وضعیت بعدی) است. در هر گام، یک مینی‌بچ ۳۲ تایی به صورت تصادفی برای آموزش شبکه انتخاب می‌شود.

- تعداد اپیزودها^{۱۰}: ۵۰۰۰ اپیزود، که هر اپیزود معادل یک بازه زمانی مشخص از مأموریت (توالی ۵۰ گام زمانی) است.

داده‌های آموزشی

- داده‌های تجربی حاصل از مأموریت زیرمداری نیو شپرد^{۱۱} شامل ثبت پیوسته دما، شتاب، شدت نور و رشد اسپرولینا تحت سه تنش نوری (قرمز، سفید، تاریکی) در فازهای پیش‌پرواز، پرواز و پس از پرواز، پس از پیش‌پردازش (نرمال‌سازی و حذف نویز) به عنوان مجموعه اصلی آموزش (۸۰٪) و آزمون (۲۰٪) مورد استفاده قرار گرفت.
- انتخاب معماری یادگیری عمیق کیو با لایه‌های پنهان ۱۲۸ و ۶۴ و توابع فعال‌سازی ReLU به دلیل توانایی بالای این توابع در جلوگیری از محو شدن گرادینت و سرعت همگرایی مناسب در مسائل با داده‌های پیوسته و نویزی است. سیاست ϵ -greedy تعادل بهینه میان کاوش (آزمایش کنش‌های جدید) و بهره‌برداری (استفاده از کنش‌های خوب شناخته شده) را فراهم می‌کند که در محیط پویای فضایی با عدم قطعیت بالا ضروری است. همچنین مکانیزم بازپخش تجربه با حافظه ۱۰۰۰۰ تایی، همبستگی زمانی داده‌های متوالی را کاهش داده و تنوع نمونه‌ها را حفظ می‌نماید که به ویژه در مواجهه با نوسانات ناگهانی شتاب حیاتی است. در نهایت، استفاده از شبکه هدف با به‌روزرسانی تأخیری، از واگرایی و نوسانات شدید در مقدار Q جلوگیری می‌کند و پایداری یادگیری را در طول ۵۰۰۰ اپیزود تضمین می‌نماید. نتایج شبیه‌سازی و ارزیابی عملکرد مدل در این بخش، عملکرد مدل یادگیری عمیق کیو توسعه یافته برای پیش‌بینی رشد میکروچلیک اسپرولینا در محیط شبیه‌سازی شده پرواز زیرمداری، مورد تجزیه و تحلیل قرار می‌گیرد. انتخاب الگوریتم یادگیری عمیق کیو به جای مدل‌های جایگزین مانند شبکه‌های عصبی مصنوعی^{۱۲} یا شبکه‌های حافظه^{۱۳} بر اساس ماهیت مسئله و اهداف پژوهش صورت گرفته است. در این مطالعه، هدف صرفاً پیش‌بینی غیرفعال رشد میکروچلیک نبوده، بلکه طراحی یک عامل هوشمند بود که بتواند در یک محیط پویا و ناشناخته (شرایط پرواز فضایی) تصمیم‌گیری متوالی انجام داده و با دریافت بازخورد (پاداش)، سیاست بهینه را برای کنترل شرایط نوری و بهینه‌سازی رشد

8 Target Network
9 Experience Replay
10 Episodes
11 Blue Origin
12 ANN
13 LSTM

1 Reward Function
2 Feedforward
3 SGD
4 TD error
5 Discount factor
6 Learning rate
7 Policy

تابع پاداش، عامل را به سمت یادگیری سیاستی سوق می‌دهد که خطای تفاوت زمانی را کمینه کرده و در نتیجه پیش‌بینی‌های دقیق‌تری از رشد اسپیرولینا تحت شرایط نوری مختلف در محیط فضایی ارائه دهد. تمامی این تعاریف با داده‌های تجربی واقعی کالیبره شده‌اند و اساس آموزش مدل را تشکیل داده‌اند.

تحلیل فرآیند آموزش و همگرایی مدل

یکی از شاخص‌های کلیدی در کارایی شبکه‌های عصبی، نحوه کاهش خطا در طول زمان آموزش است. در این پژوهش، روند تغییرات میانگین مربعات خطا برای سه خروجی اصلی مدل شامل شاخص زمان، پارامتر نوری قرمز و سفید در بازه‌های پانصد اپیزودی ثبت و پایش شد. داده‌های استخراج شده از حلقه آموزشی در جدول (۱) ارائه شده است.


تحلیل داده‌های جدول فوق نشان می‌دهد که مدل روند کاهشی مطلوبی را طی کرده است. به عنوان مثال، خطای مربوط به پارامتر نوری قرمز از مقدار تقریبی ۰.۰۰۱ در اپیزود ۵۰۰، به حدود ۰.۰۰۰۸ در اپیزود ۵۰۰۰ کاهش یافته است. همچنین کمترین میزان خطا برای خروجی سفید در اپیزود ۳۵۰۰ (با مقدار تقریبی ۰.۰۰۰۲) ثبت شده است که نشان دهنده همگرایی سریع تر این پارامتر نسبت به سایرین است. اگرچه نوساناتی در مقادیر خطا مشاهده می‌شود، اما این رفتار به دلیل ماهیت تصادفی نمونه برداری از حافظه باز پخش تجربه در الگوریتم‌های یادگیری تقویتی، امری طبیعی محسوب می‌شود.

کلیه مراحل پیش‌پردازش، نرمال‌سازی و حذف نویزهای آشکار (مانند لحظات شوک مکانیکی بازگشت) بر روی این داده‌های واقعی انجام شد و هیچ داده مصنوعی یا شبیه‌سازی‌ای در مرحله آموزش مدل به کار نرفته است. محیط شبیه‌سازی شده که در ابتدای بخش نتایج به آن اشاره شده، یک بستر نرم‌افزاری برای باز تولید ترتیب زمانی داده‌های آزمون و ارزیابی حلقه بسته عملکرد عامل هوشمند است و نقشی در تولید داده‌های آموزشی نداشته است. مجموعه داده‌های خام شامل ۱۶۶۵ نمونه از سه عملکرد نوری (قرمز، سفید، تاریکی) بوده که پس از پالایش اولیه، با حفظ نسبت هر عملکرد نوری، به صورت تصادفی به دو بخش آموزش (۱۳۳۲ نمونه) و آزمون (۳۳۳ نمونه) تفکیک شدند. دامنه تغییرات هر متغیر در مجموعه آموزش به گونه‌ای است که مقادیر کمینه و بیشینه تقریباً تمام گستره داده‌های اصلی را پوشش می‌دهد که نشان دهنده پراکندگی مناسب و قابلیت تعمیم‌پذیری مدل می‌باشد. همچنین برای اطمینان از عدم سوگیری در تفکیک داده‌ها، از روش اعتبارسنجی متقاطع ۵ لایه استفاده شده است که انحراف معیار کمتر از ۰.۰۰۰۵ در ضریب تعیین بین لایه‌های مختلف، پایداری فرایند آموزش را تأیید می‌کند.

بیاومزد. شبکه‌های عصبی ساده هر چند در تقریب توابع غیرخطی توانمند هستند، فاقد مکانیزم تصمیم‌گیری و تعامل با محیط می‌باشند و صرفاً یک نداشت ایستا از ورودی به خروجی ارائه می‌دهند. از سوی دیگر، معماری اگرچه برای داده‌های توالی زمانی (مانند سری‌های زمانی رشد) مناسب است، اما فاقد چارچوب یادگیری تقویتی (بازخورد پاداش) و قابلیت کاوش در فضای کنش برای یافتن سیاست بهینه می‌باشد. در مقابل، ساختار یادگیری عمیق کیو با ترکیب قدرت تقریب‌زنی شبکه‌های عصبی عمیق و چارچوب تصمیم‌گیری مبتنی بر پاداش، قادر است به طور همزمان هم روابط غیرخطی حاکم بر رشد زیستی را مدل کند و هم استراتژی‌های کنترلی (نظیر انتخاب طیف نوری مناسب) را به صورت تطبیقی و در تعامل با محیط شبیه سازی شده فضایی فرا بگیرد. همچنین، استفاده از مکانیزم بازپخش تجربه، در الگوریتم یادگیری عمیق مشکل همبستگی داده‌های متوالی را حل کرده و پایداری یادگیری را در برابر نوسانات داده‌های پروازی افزایش می‌دهد. بنابراین، بهره بردن از الگوریتم یادگیری عمیق کیو یک انتخاب روش‌شناختی متناسب با هدف جایگزینی روش آزمون و خطا با یک مدل تصمیم ساز هوشمند بوده و از قابلیت‌های صرفاً پیش‌بینی‌کننده مدل‌های (ANN) یا (LSTM) فراتر می‌رود [۱۷، ۱۸].

در چارچوب یادگیری عمیق کیو توسعه یافته در این پژوهش، فضای وضعیت (S) به صورت یک بردار ترکیبی از سه دسته مؤلفه اصلی تعریف شده است: (۱) شاخص زمان (t) که بیانگر لحظه نمونه‌برداری در طول مأموریت (پیش از پرواز تا پس از پرواز) می‌باشد؛ (۲) نوع طیف نوری (λ) که در سه حالت گسسته: قرمز، سفید و تاریکی تعریف گردیده است. این موضوع نشان دهنده وضعیت نوردهی فعلی به کشت میکروجلبک می‌باشد. (۳) داده‌های لحظه‌ای زیستی که توسط حسگرهای تعبیه شده در محموله در طول پرواز زیر مداری ثبت شده‌اند. فضای کنش (a) مجموعه اقداماتی است که عامل هوشمند می‌تواند در هر وضعیت انجام دهد؛ این کنش‌ها شامل، انتخاب نوع طیف نوری برای مرحله بعدی رشد (قرمز، سفید یا تاریکی) و همچنین تنظیم شدت نور در محدوده قابل اعمال بر اساس داده‌های تجربی پرواز می‌باشند. عامل با انتخاب هر کنش، محیط را به وضعیت جدید (S') منتقل کرده و پاسخ رشد میکروجلبک را مشاهده می‌کند.

تابع پاداش ($r(S, a, S')$) به گونه‌ای طراحی شده است که مدل را به سمت کاهش خطای پیش‌بینی سوق دهد. به عبارت دقیق‌تر، هرچه مقدار پیش‌بینی‌شده توسط شبکه عصبی به مقدار واقعی اندازه‌گیری شده نزدیک‌تر باشد، پاداش بزرگتری دریافت می‌کند. در پیاده سازی عملی، پاداش به صورت منفی میانگین مربعات خطا تعریف شده است. از طرف دیگر، برای تعادل میان پاداش‌های آنی و آینده، از ضریب تخفیف $\gamma = 0.99$ استفاده شده است (مطابق معادله (۱)). این طراحی



شکل ۳- منحنی همگرایی میانگین مربعات خطا در طول اپیزودهای آموزشی؛ کاهش نوسانات نشان دهنده پایداری یادگیری است.

Fig. 3. The convergence curve of the mean squared error during the training episodes; the reduction in oscillations indicates learning stability.

همان‌طور که در اشکال (۴) مشهود است، استفاده از بهینه ساز آدام منجر به کاهش سریع خطا از مقادیر اولیه ۰.۷ به کمتر از ۰.۱ در همان ۱۰۰۰ تکرار نخست شده است. این همگرایی سریع به ویژه برای پارامترهای نوری قرمز و سفید کاملاً یکنواخت بوده است، در حالی که پارامتر زمانی نوسانات جزئی تری را نشان می دهد که با توجه به گستردگی دامنه اعداد آن قابل توجیه است. در مجموع، نتایج این بخش تأیید می کند که مدل با گذراندن ۵۰۰۰ اپیزود به همگرایی قابل قبولی رسیده است، هر چند نوسانات مشاهده شده در پارامتر زمانی پیشنهاد می دهد که در پژوهش‌های آتی می توان با افزایش ظرفیت حافظه باز پخش (مثلاً به پانزده هزار) یا کاهش نرخ یادگیری در مراحل پایانی، پایداری مدل را بیش از پیش افزایش داد.

ارزیابی کمی و اعتبارسنجی آماری

پس از پایان فاز آموزش، عملکرد نهایی مدل با استفاده از مجموعه داده‌های آزمون (شامل ۳۳۳ نمونه متمایز) مورد ارزیابی دقیق قرار گرفت. در این مرحله، معیارهای آماری استاندارد شامل میانگین مربعات خطا، ریشه میانگین مربعات خطا، میانگین خطای مطلق و ضریب تعیین برای هر سه خروجی مدل محاسبه گردید. خلاصه این نتایج در جدول (۲) ارائه شده است. شکل (۴) روند کاهشی ریشه میانگین مربعات خطا^۱ را در طول هزار تکرار نخست فرایند آموزش برای هر سه پارامتر خروجی مدل شامل زمان (نمودار الف)، شدت نور قرمز (نمودار ب) و شدت نور سفید (نمودار ج) نشان می‌دهد. در این نمودارها، خط آبی پررنگ همراه با نشانگر دایره، بیانگر مقدار لحظه ای میانگین مربعات خطا محاسبه شده بر روی مجموعه آموزش در هر تکرار است. خط آبی کم‌رنگ (با خطچین) نمایانگر نسخه هموار شده^۲ همان خطا می باشد که برای

جدول ۱- روند تغییرات میانگین مربعات خطا برای خروجی‌های مختلف در طول ۵۰۰۰ اپیزود آموزشی.

Table 1. The trend of mean squared error variations for different outputs over 5000 training episodes.



شماره اپیزود	میانگین مربعات خطای پارامتر زمان	میانگین مربعات خطای پارامتر نور قرمز	میانگین مربعات خطای پارامتر نور سفید
500	0.000741191	0.00105729	0.000530009
1000	0.000986698	0.001281731	0.000281196
1500	0.000697976	0.001418723	0.000592532
3000	0.000969208	0.001535474	0.000527175
2500	0.001154385	0.00122187	0.000409259
3000	0.000771764	0.001392964	0.000440019
3500	0.000419187	0.001489774	0.000224394
4000	0.000600199	0.001647403	0.000254901
4500	0.000348441	0.001661451	0.000318103
5000	0.000555067	0.000855557	0.000709092


برای درک بهتر دینامیک یادگیری، روند تغییرات خطا به صورت بصری در شکل (۳) ترسیم شده است. خطوط رنگی در این شکل بیانگر کاهش تدریجی تابع هزینه و حرکت مدل به سمت نقطه بهینه سراسری هستند.

تحلیل شکل (۳) نشان می دهد که خروجی مربوط به نور قرمز بیشترین نوسان را تجربه کرده، اما در نهایت به خطای کمتر از ۰.۰۰۱ همگرا شده است. همچنین پارامتر زمانی با وجود دامنه وسیع داده‌های ورودی (۲۰ تا ۷۶۲)، همگرایی قابل قبولی داشته است. این رفتار با تنظیمات انجام شده برای فرا پارامترها (نرخ یادگیری ۰.۰۰۱ و ضریب تخفیف ۰.۹۹) سازگار است و نشان می‌دهد که شبکه عصبی با افزایش تعداد اپیزودها به ثبات می رسد. علاوه بر خطای میانگین مربعات، جهت ارزیابی مراحل اولیه آموزش و تنظیم وزن‌های اولیه شبکه، روند ریشه میانگین مربعات خطا نیز پایش شد. شکل (۴) این روند را برای خروجی‌های سه گانه در فاز آموزش اولیه نظارت شده نشان می‌دهند.


جزئی بیشتری دیده میشود، اما روند کلی نزولی و پایدار شدن خطا در سطوح پایین، نشان دهنده یادگیری موفق الگوهای زمانی حاکم بر رشد/سپیروالینا توسط شبکه عصبی است. این رفتار تأیید می کند که معماری انتخاب شده برای شبکه عصبی تقریب Q ، همراه با فرا پارامترهای مناسب اشاره شده توانسته است پیچیدگی‌های داده‌های پروازی را به خوبی فرا گیرد و مبنایی پایدار برای ادامه آموزش در اپیزودهای بعدی فراهم آورد.

کاهش نوسانات لحظه ای و نمایش بهتر روند کلی کاهش خطا ترسیم شده است. همچنین خط مشکی با نقطه چین و نشانگر دایره نشان دهنده ریشه میانگین مربعات خطا محاسبه شده بر روی مجموعه اعتبارسنجی است؛ همانطور که مشاهده می شود، در تمامی موارد، مقدار خطا از حدود ۰.۷ در ابتدای آموزش به سرعت کاهش یافته و پس از حدود ۲۰۰ تکرار به مقادیر کمتر از ۰.۱ می رسد. این کاهش سریع و یکنواخت، به ویژه برای پارامترهای نوری (قرمز و سفید)، حاکی از عملکرد مؤثر بهینه ساز در تنظیم وزن‌های شبکه و همگرایی زودهنگام مدل است. هرچند در پارامتر زمانی نوسانات







(ب-۱)



(ب-۲)



(ج-۱)



شکل ۴- روند نزولی ریشه میانگین مربعات خطا طی فرایند آموزش اولیه برای پارامترهای خروجی؛ (الف) پارامتر زمان، (ب) پارامتر نوری قرمز، (ج) پارامتر نوری سفید. کاهش سریع خطا نشان دهنده همگرایی مناسب مدل با استفاده از بهینه ساز آدام است.

Fig. 4. The decreasing trend of the root mean square error during the initial training process for the output parameters: (a) the time parameter, (b) the red-light parameter, and (c) the white-light parameter. The rapid reduction in error indicates proper model convergence using the Adam optimizer.

از عدم وجود سوگیری سیستماتیک در پیش‌بینی‌ها، آمار توصیفی داده‌های واقعی و مقادیر پیش‌بینی شده توسط مدل در جدول (۳) با یکدیگر مقایسه شده‌اند.

جدول ۳- مقایسه آماری (میانگین و انحراف معیار) میان داده‌های واقعی و پیش‌بینی شده

Table 3. Statistical comparison (mean and standard deviation) between the actual and predicted data.

داده‌ها	زمان	قرمز	سفید
میانگین داده‌های واقعی	399.874953	214.636881	143.534561
انحراف معیار داده‌های واقعی	227.201869	0.084891	0.135107
کمینه داده‌های واقعی	20.418796	214.431191	143.212676
بیشینه داده‌های واقعی	761.945243	214.743308	143.698592
میانگین مقادیر پیش‌بینی شده	387.173767	214.630729	143.524160
انحراف معیار مقادیر پیش‌بینی شده	215.604955	0.079103	0.128737
کمینه مقادیر پیش‌بینی شده	23.521255	214.432773	143.212994
بیشینه مقادیر پیش‌بینی شده	731.954758	214.730779	143.677695

نزدیکی بسیار زیاد میانگین‌ها و انحراف معیارهای پیش‌بینی شده با مقادیر واقعی در جدول (۳)، نشان دهنده آن است که مدل توانسته توزیع آماری داده‌ها را به خوبی حفظ کند. اختلاف

جدول ۲- خلاصه معیارهای ارزیابی عملکرد مدل برای خروجی‌های پیش‌بینی شده.

Table 2. Summary of the model performance evaluation metrics for the predicted outputs.

ضریب تعیین	میانگین خطای مطلق	ریشه میانگین مربعات خطا	میانگین مربعات خطا	خروجی
0.993931851	13.41182176	17.47026532	0.000555067	زمان
0.988130246	0.00746032	0.009129375	0.000855557	قرمز
0.990586477	0.011088805	0.012939335	0.000709092	سفید

بررسی جدول فوق نشان می‌دهد که ضریب تعیین برای تمامی خروجی‌ها فراتر از ۰.۹۸ است؛ به این معنا که مدل توسعه یافته توانسته است بیش از ۹۸ درصد از واریانس و پیچیدگی موجود در داده‌های واقعی را توضیح دهد. به‌طور خاص، مقادیر بسیار ناچیز ریشه میانگین مربعات خطا و میانگین خطای مطلق برای پارامترهای نوری قرمز و سفید (کمتر از ۰.۰۲)، گواهی بر دقت فوق‌العاده مدل در شبیه‌سازی پاسخ‌های نوری است. اگرچه برای پارامتر زمانی، مقادیر خطا (حدود ۱۷ واحد برای ریشه میانگین مربعات خطا) کمی بزرگتر به نظر می‌رسد، اما با در نظر گرفتن دامنه وسیع داده‌های این بخش (که بین ۲۰ تا ۷۶۲ متغیر است)، ضریب تعیین بالای ۰.۹۹ نشان می‌دهد که مدل همچنان الگوهای اصلی را با موفقیت شناسایی کرده است. جهت اطمینان

میانگین‌ها برای پارامتر زمان کمتر از ۱۳ واحد و برای پارامترهای نوری کمتر از شش هزارم است که خطای بسیار ناچیزی محسوب می‌شود. در نهایت، برای سنجش میزان هم راستایی تغییرات، تحلیل همبستگی میان خروجی‌های مدل و داده‌های مرجع انجام شد که نتایج آن در جدول (۴) آمده است.

جدول ۴- ضرایب همبستگی پیرسون میان مقادیر واقعی و خروجی‌های مدل.

Table 4. Pearson correlation coefficients between the actual values and the model outputs.


پارامتر خروجی	ضریب همبستگی	مربع ضریب همبستگی
زمان	0.999865388	0.999730793
قرمز	0.999017261	0.998035487
سفید	0.999418195	0.998836729

همبستگی نزدیک به یک (بیش از ۰.۹۹۹) برای تمامی پارامترها، تأییدی نهایی بر این مدعاست که الگوریتم یادگیری عمیق پیشنهادی، نه تنها روند کلی داده‌ها را فرا گرفته، بلکه قادر است نوسانات جزئی را نیز با دقت بالا دنبال کند. این سطح از دقت، مدل را به ابزاری قابل اطمینان برای جایگزینی آزمایش‌های پرهزینه فیزیکی در مأموریت‌های فضایی تبدیل می‌کند.


تحلیل بصری خطاها و توزیع داده‌ها

علاوه بر معیارهای کمی، ارزیابی بصری نتایج می‌تواند بینش عمیق‌تری نسبت به رفتار مدل و قابلیت تعمیم پذیری آن فراهم آورد. بدین منظور، ابتدا نمودارهای پراکندگی برای مقایسه نظیر به نظیر مقادیر پیش‌بینی شده در برابر مقادیر واقعی ترسیم گردید.


همان‌طور که در شکل (۵) مشاهده می‌شود، تجمع متراکم نقاط داده در اطراف خط نیمساز (خط قرمز)، نشان دهنده همبستگی بسیار قوی میان پیش‌بینی‌های مدل و واقعیت است. بازه خطای ناچیز (که با خطوط میله‌ای خطا در زیر هر نمودار نمایش داده شده) به ویژه برای پارامترهای نوری قرمز و سفید مشهود است.



(الف)




(ب)



(ج)

شکل ۵- نمودارهای پراکندگی مقادیر پیش‌بینی شده در مقابل مقادیر واقعی برای خروجی‌های مدل؛ انطباق نقاط بر روی خط نیمساز ($y = x$) بیانگر دقت بالای پیش‌بینی است.

Fig. 5. Scatter plots of the predicted values versus the actual values for the model outputs; the alignment of points along the bisector line ($y = x$) indicates high prediction accuracy.



(ج)

شکل ۶- هیستوگرام توزیع فراوانی خطای مطلق؛ تراکم شدید داده‌ها در نمودارها به سمت چپ (نزدیک به صفر) نشان می‌دهد که اکثریت قریب به اتفاق پیش‌بینی‌ها دارای خطای ناچیز هستند.


Fig. 6. Histogram of the absolute error distribution; the strong concentration of data toward the left side of the plots (near zero) indicates that the vast majority of predictions have minimal error.

در گام بعدی اعتبارسنجی، به منظور حصول اطمینان از اینکه مدل توسعه یافته صرفاً یک برازش عددی ساده انجام نداده و توانسته است ماهیت آماری پدیده بیولوژیک رشد را درک کند، از تکنیک تحلیل نمودارهای جعبه‌ای بهره گرفته شد. این نمودارها که در شکل (۷) به تفکیک برای هر سه متغیر خروجی ترسیم شده‌اند، امکان مقایسه چشمی و هم‌زمان شاخص‌های کلیدی آماری نظیر میانه، دامنه میان چارکی و پراکندگی کلی داده‌های واقعی و شبیه‌سازی شده را فراهم می‌آورند.


واکوی دقیق شکل (۷) حاوی نکات ارزشمندی است؛ نخست آنکه ارتفاع جعبه‌ها (که بیانگر واریانس یا تنوع داده‌هاست) در ستون‌های پیش‌بینی شده دقیقاً مشابه ستون‌های واقعی است. این شباهت هندسی اثبات می‌کند که شبکه عصبی توانسته است پیچیدگی و پویایی ذاتی رشد جلبک را حفظ کند و از هموارسازی بیش از حد که خطای رایج در مدل‌های هوش مصنوعی است، اجتناب ورزد. دوم آنکه، هم‌ترازی خطوط میانه در هر دو گروه نشان می‌دهد که مدل دچار تورش یا خطای سیستماتیک نشده و مرکز ثقل پیش‌بینی‌ها دقیقاً بر واقعیت منطبق است. در نهایت، طول بازوهای نمودار که دامنه تغییرات از کمینه تا بیشینه را نشان می‌دهد، در هر دو حالت یکسان است؛ این ویژگی از منظر کاربردی در مأموریت‌های فضایی بسیار حائز اهمیت است، زیرا تضمین می‌کند که مدل قادر است شرایط حدی و بحرانی (مانند کمینه‌ترین و بیشینه‌ترین نرخ رشد) را به درستی پیش‌بینی کرده و هشدارهای لازم را صادر نماید.

برای پارامتر زمانی نیز اگرچه پراکندگی اندکی دیده می‌شود، اما روند خطی به خوبی حفظ شده است. همچنین به منظور درک بصری چگونگی پراکندگی خطاها و ارزیابی رفتار آماری مدل در مواجهه با داده‌های متنوع، نمودارهای هیستوگرام توزیع فراوانی خطای مطلق برای هر سه متغیر خروجی ترسیم و در شکل (۶) ارائه شده است. اهمیت تحلیل این نمودارها در آن است که نشان می‌دهند آیا خطای مدل ناشی از یک ضعف ساختاری (خطای سیستماتیک) است یا صرفاً نوسانات تصادفی (نویز) می‌باشد.

تحلیل دقیق شکل (۶) آشکار می‌سازد که الگوی توزیع خطاها در هر سه پارامتر، به شدت نامتقارن و متمایل به مقادیر نزدیک به صفر است. تمرکز ستون‌های بلند هیستوگرام در محدوده خطای پایین، گواهی بر این واقعیت است که مدل در غالب موارد (بیش از ۹۰ درصد نمونه‌ها) عملکردی بسیار دقیق داشته است. علاوه بر این، دنباله کوتاه نمودار در سمت راست بیانگر آن است که خطاهای بزرگ یا داده‌های پرت، رخدادهایی بسیار نادر و استثنایی بوده‌اند. این رفتار آماری اثبات می‌کند که شبکه عصبی به درستی آموزش دیده و توانسته است بدون گرفتار شدن در تله بیش‌برازش، الگوی عمومی حاکم بر رشد جلبک را فرا بگیرد.




(الف)




(ب)

در نهایت، به منظور ملموس تر شدن دقت عملکرد سامانه هوشمند پیشنهادی، بررسی موردی بر روی نمونه‌های ابتدایی داده‌های آزمون انجام گرفت. تحلیل این نمونه‌ها نشان می‌دهد که الگوریتم یادگیری عمیق کیو توانسته است با ظرافتی کم نظیر، مقادیر واقعی را دنبال کند. به طور مثال، در بسیاری از نقاط داده برداری شده، اختلاف میان مقدار اندازه گیری شده توسط حسگرهای پروازی و مقدار برآورد شده توسط مدل، تنها در حد چند هزارم اعشار بوده است. این سطح از انطباق نقطه به نقطه، به ویژه در پیش‌بینی پاسخ‌های نوری که دارای حساسیت بالایی هستند، تأییدی نهایی بر کارآمدی معماری پیشنهادی است. چنین دقتی نشان می‌دهد که مدل نه تنها روند کلی را آموخته، بلکه قادر است نوسانات لحظه ای و جزئی رشد ریز چلیک را نیز با خطایی قابل چشم پوشی شبیه سازی نماید؛ ویژگی ای که برای کاربرد در سامانه‌های کنترل خودکار زیستی در اعماق فضا، شرطی حیاتی محسوب می‌شود.


با وجود عملکرد موفق مدل پیشنهادی، این پژوهش با محدودیت‌هایی مواجه است که باید مورد بحث قرار گیرد. نخست، اندازه مجموعه داده محدود به یک مأموریت پرواز زیرمداری (با تعداد نمونه‌های ثبت شده در حدود ۳۳۳ نقطه داده آزمون و پنج هزار اپیزود آموزشی) می‌باشد. هرچند از تکنیک بازپخش تجربه^۱ برای کاهش همبستگی نمونه‌ها و افزایش تنوع مؤثر داده‌ها استفاده شد، اما عدم دسترسی به داده‌های حاصل از مأموریت‌های متعدد یا آزمایش‌های زمینی با شبیه‌ساز گرانش-کم، دامنه تعمیم پذیری مدل را محدود می‌کند. دوم، شرایط ویژه مأموریت (مانند مدت زمان کوتاه گرانش-کم حدود ۳۰۴ دقیقه، پروفایل شتاب ورود به جو و بازگشت، و طیف نوری خاص مورد استفاده) باعث شده است که مدل عمدتاً برای همان سناریوی پروازی تنظیم شود و کاربرد آن برای مأموریت‌های طولانی مدت (مانند ایستگاه فضایی یا سفر به مریخ) نیازمند اعتبارسنجی مجدد با داده‌های مرتبط است. همچنین، تنش‌های مکانیکی ناشی از ضربه‌های بازگشت (شکل ۱) در این مطالعه به عنوان متغیرهای ورودی مدل سازی شدند، اما اثرات تجمعی آن‌ها در دوره‌های طولانی‌تر ناشناخته باقی می‌ماند. به منظور رفع این محدودیت‌ها، پیشنهاد می‌شود در پژوهش‌های آتی داده‌های حاصل از شبیه‌سازهای زمینی گرانش-کم (کلینوستات، دستگاه‌های چرخان تحت شرایط نوری و دمایی محیط عملکردی فضا) و مأموریت‌های فضایی بیشتری به پایگاه داده افزوده شود تا مدل قادر به یادگیری طیف گسترده‌تری از شرایط محیطی شده و به یک ابزار عمومی‌تر برای بهینه‌سازی کشت اسپرولینا در فضا تبدیل گردد.



(الف)



(ب)



(ج)

شکل ۷- نمودارهای جعبه ای مقایسه ای برای ارزیابی تطابق توزیع آماری داده‌های واقعی و پیش‌بینی شده؛ هم راستایی میانه‌ها و دامنه‌های تغییرات، نشانگر صحت عملکرد مدل است.

Fig. 7. Comparative box plots for evaluating the consistency between the statistical distributions of the actual and predicted data; the alignment of medians and variation ranges indicates the accuracy of the model's performance.

¹ Experience Replay

جدول ۵- مقایسه پارامترها و عملکرد مدل پیشنهادی DQN در برابر مدل پایه ANN نظارت شده.

Table 5. Comparison of parameters and performance of the proposed DQN model versus the supervised baseline ANN model.

مدل پیشنهادی Deep Q-Learning	مدل پایه ANN	معیار مقایسه
یادگیری تقویتی (تعامل با محیط، پاداش محور)	یادگیری نظارت شده (نگاشت ورودی- خروجی)	نوع یادگیری
برداری شامل زمان، طیف نوری، رشد گیاه	برداری شامل زمان، طیف نوری، رشد گیاه	فضای وضعیت
انتخاب طیف نوری (تصمیم گیری متوالی)	ندارد (فقط پیش بینی)	فضای کنش
پاداش = MSE- $(\gamma=0.99)$	MSE بدون بازخورد آینده	تابع هزینه / پاداش
۵۰۰۰ اپیزود با بازپخش تجربه	۱۰۰۰ دوره	تعداد اپیزود/دوره آموزش
0.9939	0.9852	ضریب تعیین (R^2) زمان
0.9881	0.9764	ضریب تعیین (R^2) نور قرمز
0.9906	0.9789	ضریب تعیین (R^2) نور سفید
0.00913	0.01521	ریشه میانگین مربعات خطا (نور قرمز)

نتایج عملکرد مدل پایه پس از اجرای مجدد بر روی همان داده‌های آزمون (۳۳۳ نمونه) محاسبه شده است. به منظور اعتبارسنجی کارآمدی روش پیشنهادی، عملکرد الگوریتم یادگیری عمیق کیو با یک مدل پایه استاندارد شامل شبکه عصبی پیشخور سه لایه^۱ با معماری ۳-۱۰-۵ نورون در لایه‌های ورودی، پنهان و خروجی مقایسه گردید. مدل پایه با استفاده از الگوریتم بهینه‌ساز آدام و تابع هزینه میانگین مربعات

انتخاب الگوریتم یادگیری عمیق کیو به جای ساختارهای رایج دیگر مانند شبکه‌های عصبی پیشخور، مدل‌های فازی-عصبی یا شبکه‌های بازگشتی نظارت شده، بر اساس ماهیت ذاتی مسئله پژوهش صورت گرفته است. در پژوهش‌های پیشین، هدف عمدتاً پیش‌بینی ایستا بوده است؛ به این معنا که مدل با دریافت یک بردار ورودی (مثلاً دما، نور، زمان)، مقدار رشد گیاه را در همان مقطع زمانی تخمین می‌زند. چنین ساختارهایی هرچند در تقریب توابع غیرخطی توانمندند، فاقد دو ویژگی حیاتی برای کاربرد در مأموریت‌های فضایی هستند: تصمیم‌گیری متوالی و قابلیت تطبیق با پویایی محیط. در مقابل، چارچوب یادگیری تقویتی عمیق کیو، با تعریف یک عامل هوشمند، فضای وضعیت (شامل زمان، طیف نوری و زیست‌توده لحظه‌ای)، فضای کنش (انتخاب نوع نور برای مرحله بعد) و تابع پاداش، به مدل امکان می‌دهد تا از طریق تعامل با محیط و دریافت بازخورد، نه تنها رفتار آینده را پیش‌بینی کند، بلکه بهترین کنش کنترلی را برای بهینه‌سازی رشد در شرایط ناشناخته فضایی بیاموزد. این مزیت به ویژه در مواجهه با پدیده‌هایی مانند بازدارندگی رشد در نور قرمز (مطابق شکل ۲) که نتیجه برهم‌کنش غیرخطی گرانش-کم و طیف نوری است، اهمیت می‌یابد. در حالی که مدل‌های نظارت شده فقط قادر به تکرار الگوهای گذشته‌اند، مدل یادگیری تقویتی عمیق کیو با استفاده از مکانیزم بازپخش تجربه و سیاست اکتشاف-بهره‌برداری، می‌تواند سناریوهای پیش‌بینی نشده را شبیه‌سازی کرده و استراتژی بهینه را بدون نیاز به داده‌های برچسب دار از پیش تعیین شده استخراج کند. به همین دلیل، ساختار منتخب نه تنها از نظر دقت ($R^2 > 0.98$) از مدل‌های پایه پیشی گرفته است، بلکه گامی اساسی از پیش‌بینی به کنترل هوشمند و خودکار در حوزه زیست‌فناوری فضایی محسوب می‌شود.

اعتبارسنجی روش پیشنهادی

به عنوان یک مدل پایه رایج و معتبر در حوزه مدلسازی سیستم‌های زیستی، شبکه عصبی پیشخور سه لایه^۱ با الگوریتم یادگیری نظارت شده^۲ پیشنهاد می‌شود. این مدل در مقالات متعددی برای پیش‌بینی رشد ریزجلبک‌ها به کار رفته است و یک مدل پایه^۳ استاندارد محسوب می‌شود. دلیل انتخاب این مدل به عنوان پایه آن است که ساختار آن ساده، قابل تکرار و فاقد مکانیزم تصمیم‌گیری متوالی مانند یادگیری عمیق کیو می‌باشد، بنابراین مقایسه عملکرد آن با روش پیشنهادی، عملکرد یادگیری تقویتی را به خوبی نشان می‌دهد.

³ Baseline

⁴ ANN

¹ Feedforward Neural Network

² Supervised Learning

استفاده از یادگیری تقویتی را به عنوان جایگزینی مطمئن، سریع و کم هزینه برای آزمایش‌های فیزیکی پر ریسک در فضا تأیید می‌کند. در واقع، مدل ارائه شده می‌تواند به عنوان یک همکار دیجیتال برای بیوراکتورهای فضایی عمل کرده و پیش از پرتاب محموله‌های زیستی، سناریوهای مختلف محیطی را شبیه سازی و بهینه ترین شرایط کشت را پیشنهاد دهد.

با وجود موفقیت‌های چشمگیر، این مطالعه محدودیت‌هایی نیز داشته است که مسیر تحقیقات آینده را روشن می‌سازد. نوسانات مشاهده شده در پیش‌بینی پارامترهای زمانی در برخی اپیزودها، بیانگر نیاز به داده‌های آموزشی حجیم تر و متنوع تر است. از این رو، پیشنهاد می‌شود در پژوهش‌های آتی، پایگاه داده فعلی با نتایج حاصل از آزمایش‌های زمینی شبیه ساز گرانس-کم (نظیر دستگاه‌های کلینوستات و سانتیفریوژهای با قطر بالا) تلفیق گردد تا دامنه تعمیم پذیری مدل گسترش یابد. همچنین، بررسی امکان ادغام این مدل با سایر الگوریتم‌های هوشمند نظیر شبکه‌های عصبی بازگشتی یا مکانیزم‌های توجه، می‌تواند به درک بهتر وابستگی‌های زمانی طولانی مدت در چرخه‌های رشد کمک شایانی نماید.

از منظر کاربردی، پیاده سازی سخت افزاری این الگوریتم بر روی تراشه‌های کم مصرف و تعبیه آن در سامانه کنترلی کاوشگرها و ماهواره‌های کوچک (کیوب ست‌ها)، گامی عملی و تحول آفرین به سوی خودکار سازی مدیریت کامل مزارع زیستی در فضا خواهد بود. چنین سامانه‌هایی قادر خواهند بود به صورت مستقل و بلادرنگ، وضعیت سلامت کشت را پایش کرده و در صورت بروز تنش‌های محیطی پیش‌بینی نشده، اقدامات اصلاحی لازم را به طور خودکار انجام دهند. در نهایت، می‌توان گفت که این پژوهش نه تنها زیر ساخت محاسباتی قدرتمندی را برای زیست فناوری فضایی فراهم آورده، بلکه گامی بلند در جهت تحقق رؤیای خودکفایی انسان در سکونتگاه‌های فرا زمینی و سفرهای میان سیاره ای برداشته است.

مراجع

- [1] M. G. Tadros, W. Smith, P. Mbuthia, and B. Joseph, "Manipulating cyanobacteria: Spirulina for potential CELSS diet," in *Alabama A & M Univ., NASA-HBCU Space Science and Engineering Research Forum Proceedings*, 1989.
- [2] M. Oguchi, K. Otsubo, K. Nitta, and S. Hatayama, "Food production and gas exchange system using

خطا^۱ به صورت نظارت شده بر روی همان مجموعه داده‌های آموزشی مورد آموزش قرار گرفت. همان‌طور که در جدول فوق مشاهده می‌شود، مدل شبکه یادگیری عمیق کیو در تمامی شاخص‌های خروجی (زمان، نور قرمز، نور سفید) ضریب تعیین بالاتری (بیش از ۰٫۹۸۸ در مقابل ۰٫۹۷۶ برای مدل پایه) و ریشه میانگین مربعات خطای کمتری (کمتر از ۰٫۰۰۹۱۳ در مقابل ۰٫۰۱۵۲۱ برای نور قرمز) از خود نشان داد. این برتری به دلیل قابلیت یادگیری تقویتی در بهره‌گیری از بازخورد پاداش و مکانیزم بازپخش تجربه است که به مدل اجازه می‌دهد روابط زمانی و علی حاکم بر رشد میکروچلیک را بهتر از یک نگاشت ایستا یاد بگیرد. بنابراین، روش پیشنهادی نه تنها از نظر دقت پیش‌بینی، بلکه از منظر توانایی تصمیم‌گیری در محیط پویای فضایی به خصوص ایجاد شرایط برخط پروازی، بر مدل‌های ساده‌تر برتری دارد.

نتیجه‌گیری و پیشنهادها

این پژوهش با درک ضرورت حیاتی توسعه سامانه‌های پایدار پشتیبانی حیات برای مأموریت‌های فضایی آینده، رویکردی نوین را در تقاطع زیست فناوری و هوش مصنوعی مورد آزمون قرار داد. هدف غایی، امکان سنجی و پیش‌بینی دقیق رفتار رشد میکرو چلیک راهبردی اسپرولینا در محیط دینامیک و پر چالش پروازهای زیر مداری است. محیطی که با متغیرهای پیچیده ای همچون گرانس-کم، نوسانات شدید شتاب و محدودیت‌های نوری شناخته می‌شود. مدل توسعه یافته در این تحقیق که بر پایه معماری پیشرفته یادگیری عمیق کیو بنا شده است، توانست با موفقیت بر چالش‌های موجود در روش‌های مدل سازی کلاسیک غلبه کرده و کارایی خود را به اثبات برساند.

تحلیل جامع نتایج نشان داد که مدل پیشنهادی با دستیابی به ضریب تعیین میانگین بیش از ۰٫۹۹ و به حداقل رساندن خطای ریشه میانگین مربعات در تمامی شاخص‌های خروجی، از دقتی خیره‌کننده در شبیه سازی پاسخ‌های زیستی برخوردار است. به طور خاص، توانایی شبکه عصبی در تفکیک دقیق الگوهای رشد تحت رژیم‌های نوری متفاوت (سازگاری در نور سفید و بازدارندگی در نور قرمز) و همبستگی بالای پیش‌بینی‌ها با داده‌های تجربی واقعی، نشان از یادگیری عمیق روابط غیرخطی حاکم بر فیزیولوژی چلیک دارد. این دستاورد، اعتبار علمی

- networks and image recognition," *Bioresource Technology*, vol. 403, 2024, Art. no. 130889, <https://doi.org/10.1016/j.biortech.2024.130889>.
- [11] A. Woźniak, K. Szramowiat-Sala, and T. Hirose, "From traditional methods to intelligent control – a comparison of algae cultivation strategies with a focus on reinforcement learning," in *Proceedings Polish–Japanese Symposium on Hydrogen Energy Technologies and Advanced Energy Systems*, Tokyo, Japan, 2025, <https://doi.org/10.1088/1742-6596/3107/1/012027>.
- [12] A. Holloway *et al.*, "The myth of the data-constrained mission: Ten years of data management onboard the Curiosity Rover," in *Proceedings 2024 IEEE Aerospace Conference*, Big Sky, MT, USA, 2024, <https://doi.org/10.1109/AERO58975.2024.10521196>.
- [13] P. A. Oche, G. A. Ewa, and N. Ibekwe, "Applications and challenges of artificial intelligence in space missions," *IEEE Access*, vol. 12, pp. 44481–44509, 2021, <https://doi.org/10.1109/ACCESS.2021.3132500>.
- [14] P. D. Karkos, S. C. Leong, C. D. Karkos, N. Sivaji, and D. A. Assimakopoulos, "Spirulina in clinical practice: Evidence-based human applications," *Evidence-Based Complementary and Alternative Medicine*, vol. 2011, 2011, Art. no. 531053, <https://doi.org/10.1093/ecam/nen058>.
- [15] P. J. Llanos, M. Shilling, K. Andrijauskaite, K. Kidder, and V. V. Duraisamy, "Assessment of scientific payload carrying Spirulina onboard Blue Origin's New Shepard vehicle," *Global Journal of Researches in Engineering: Automotive Engineering*, vol. 22, no. 1, 2022.
- [16] Y. Gao *et al.*, "Hybrid reinforcement learning for performance prediction and degradation analysis of proton exchange membrane fuel cells under real vehicle operating conditions," *Energy Conversion and Management*, vol. 345, 2025, Art. no. 120364, <https://doi.org/10.1016/j.enconman.2025.120364>.
- [17] J. N. Tsitsiklis, "Asynchronous stochastic approximation and Q-learning," *Machine Learning*, vol. 16, no. 3, pp. 185–202, 1994, <https://doi.org/10.1007/BF00993306>.
- [18] V. Mnih *et al.*, "Playing atari with deep reinforcement learning," *arXiv preprint*, 2013, <https://doi.org/10.48550/arXiv.1312.5602>.
- blue-green alga (Spirulina) for CELSS," Advances in Space Research*, vol. 7, no. 4, pp. 7–10, 1987, [https://doi.org/10.1016/0273-1177\(87\)90026-3](https://doi.org/10.1016/0273-1177(87)90026-3).
- [3] K. Fisher, J. Broddrick, and A. M. Settles, "Space Algae-2: Preflight Testing for A Long-Duration, Multi-Omics Analysis of Arthrospira Platensis," in *Annual Meeting of the American Society for Gravitational and Space Research*, 2023.
- [4] W. A. Metekia, A. G. Usman, B. H. Ulusoy, S. I. Abba, and K. C. Bali, "Artificial intelligence-based approaches for modeling the effects of spirulina growth mediums on total phenolic compounds," *Saudi Journal of Biological Sciences*, vol. 29, no. 2, pp. 1111–1117, 2022, <https://doi.org/10.1016/j.sjbs.2021.09.055>.
- [5] J. S. M. Pappu, G. K. Vijayakumar, and V. Ramamurthy, "Artificial neural network model for predicting production of Spirulina platensis in outdoor culture," *Bioresource Technology*, vol. 130, pp. 224–230, 2013, <https://doi.org/10.1016/j.biortech.2012.12.082>.
- [6] M. Ula, F. Fajriana, and J. Ulfah, "Internet of Things and Artificial Neural Network Application for Optimizing Spirulina Cultivation with Palm Oil Mill Effluent," *Journal of Computer Science, Information Technology and Telecommunication Engineering*, vol. 6, no. 1, 2025, <https://doi.org/10.30596/jcositte.v6i1.22389>.
- [7] R. A. Soni, K. Sudhakar, and R. S. Rana, "Spirulina – From growth to nutritional product: A review," *Trends in Food Science & Technology*, vol. 69, pp. 157–171, 2017, <https://doi.org/10.1016/j.tifs.2017.09.010>.
- [8] Y. T. T. Doan, M. T. Ho, H. K. Nguyen, and H. D. Han, "Optimization of Spirulina sp. cultivation using reinforcement learning with state prediction based on LSTM neural network," *Journal of Applied Phycology*, vol. 33, no. 5, pp. 2733–2744, 2021, <https://doi.org/10.1007/s10811-021-02488-y>.
- [9] L. H. Hassan, I. Ahmad, M. El Sheekh, and N. Abdullah, "In silico models on algal cultivation and processing: An approach for engineered optimization," in *Research Anthology on Bioinformatics, Genomics, and Computational Biology*, Hershey, PA: IGI Global, 2024, pp. 1–28, <https://doi.org/10.4018/979-8-3693-3026-5.ch042>.
- [10] Y. Peng *et al.*, "Investigating quantitative approach for microalgal biomass using deep convolutional neural