The University of Tehran Press

Journal of Sustainable Energy Systems

Online ISSN: 2980-8693

Home Page: https://ses.ut.ac.ir

Optimization of Biological Wastewater Treatment and Biomass Production by Microalgae *Desmodesmus sp.*: A Comparison of Response Surface Methodology (RSM) and Artificial Neural Network (ANN)

Sina Labbafi[1] | Fatemeh Razi Astaraei[2*]

1. School of Energy Engineering and Sustainable Resources, College of Interdisciplinary Science and Technology, University of Tehran, Tehran, Iran. Email: sinalabbafi@ut.ac.ir
2. Corresponding Author, School of Energy Engineering and Sustainable Resources, College of Interdisciplinary Science and Technology, University of Tehran, Tehran, Iran. Email: razias_m@ut.ac.ir

ARTICLE INFO

Article type:
Research Paper

Article History:
Received: 02 May 2026
Revised: 25 June 2026
Accepted: 24 August 2026
Published Online: 01 January 2027

Keywords:
Optimization,
Wastewater Treatment,
Microalgae,
Biomass.

ABSTRACT

This study investigated the optimization of biological wastewater treatment and biomass production by the microalga *Desmodesmus sp.* while comparing two modeling approaches: Response Surface Methodology (RSM) and Artificial Neural Network (ANN). Samples were collected from Anzali Wetland, pretreated, enriched, and cultivated under controlled laboratory conditions. The operational variables included light intensity, aeration rate, pH, and retention time, which were optimized to achieve the best treatment performance. The results indicated that ANN provided more accurate predictions than RSM and was better able to capture the nonlinear relationships between process variables and responses. The optimal conditions were determined as a light intensity of 352.5 μmol photons $\cdot m^{-2} \cdot s^{-1}$, aeration rate of 1.29 mg $\cdot L^{-1}$, pH 7.79, and retention time of 7.95 days. Under these conditions, the highest predicted efficiencies were 90.2% COD removal, 80.61% TN removal, 91.14% TP removal, and biomass production of 1.27 mg.L^{-1}. Overall, the findings suggest that *Desmodesmus sp.* can serve as an effective system for simultaneous wastewater treatment and valuable biomass production, with ANN offering superior predictive and optimization performance compared with RSM.

Cite this article: Labbafi, S. & Razi Astaraei, F. (2027). Optimization of Biological Wastewater Treatment and Biomass Production by Microalgae *Desmodesmus sp.*: A Comparison of Response Surface Methodology (RSM) and Artificial Neural Network (ANN). *Journal of Sustainable Energy Systems*, 6 (1), 111-136. DOI: http//doi.org/10.22059/ses.2026.416097.1258

© Authors retain the copyright and full publishing rights.
Publisher: University of Tehran Press.
DOI: http//doi.org/10.22059/ses.2026.416097.1258

Introduction

Microalgae-based wastewater treatment has emerged as an environmentally friendly technology capable of simultaneously removing organic pollutants and nutrients while producing valuable biomass. Among freshwater microalgae, *Desmodesmus sp.* has attracted considerable attention because of its rapid growth, adaptability to wastewater environments, and high nutrient uptake capacity. However, treatment efficiency is strongly affected by operating conditions such as light intensity, aeration rate, hydraulic retention time (HRT), and pH, whose interactions are highly nonlinear. Therefore, reliable optimization requires robust predictive models. This study compared the performance of Response Surface Methodology (RSM) and Artificial Neural Networks (ANN) for modeling and optimizing a *Desmodesmus sp.*/ municipal wastewater treatment system.

Materials and Methods

A four-factor, three-level Box–Behnken design consisting of 29 experimental runs was employed. The investigated variables were light intensity (50–450 μmol photons m^{-2} s^{-1}), aeration rate (0.5–1.5 L min^{-1}), HRT (3–10 days), and pH (6–9). The responses included COD removal efficiency, total nitrogen (TN) removal efficiency, total phosphorus (TP) removal efficiency, and algal biomass production. Quadratic models were developed using Design-Expert and evaluated by ANOVA. Feed-forward multilayer perceptron ANN models were independently developed for each response in MATLAB. Hidden neurons were optimized by trial and error, data were normalized using the mapminmax function, and model performance was evaluated through five-fold cross-validation using R^2, RMSE, and MAE. Finally, the optimum condition predicted by RSM together with three additional operating conditions outside the original design matrix were experimentally validated.

Results and Discussion

The RSM models successfully described all responses with coefficients of determination greater than 0.98, indicating excellent agreement between predicted and experimental values within the investigated design space. The optimum operating condition was obtained at a light intensity of 352.5 μmol photons m^{-2} s^{-1}, an aeration rate of 1.29 L min^{-1}, an HRT of 7.95 days, and a pH of 7.79. Under these conditions, the predicted COD, TN, and TP removal efficiencies reached 89.59%, 87.45%, and 91.92%, respectively, while biomass concentration reached 1.36 mg L^{-1}.

The optimized ANN architectures consisted of a single hidden layer containing 3, 4, 8, and 4 neurons for COD removal, biomass production, TN removal, and TP removal, respectively. Cross-validation demonstrated acceptable predictive capability despite the limited dataset. The ANN models achieved R^2 values of 0.758, 0.721, 0.689, and 0.771 for COD, biomass, TN, and TP, respectively, with RMSE values of 5.76, 0.182, 7.82, and 5.81. These findings indicate that ANN successfully captured nonlinear relationships between operational variables and treatment performance; however, its prediction accuracy remained lower than that of the RSM models because the available dataset was relatively small for neural network training.

Experimental validation further confirmed the reliability of both approaches. At the optimum operating condition, the experimentally measured COD removal efficiency reached 90.2%, compared with 89.59% predicted by RSM and 88.65% predicted by ANN. Similar agreement was observed for biomass production, TN removal, and TP removal, while the additional validation experiments demonstrated that both models maintained satisfactory predictive capability under previously unseen operating conditions. Nevertheless, RSM consistently produced predictions closer to the experimental measurements.

Sensitivity analysis revealed that pH was the most influential operating variable affecting all treatment responses, followed by HRT. Light intensity also exhibited considerable practical importance because of its wide operating range, whereas aeration rate showed the weakest overall influence and even a negative effect on phosphorus removal under high aeration conditions. These results demonstrate that evaluating process variables based only on regression coefficients may be misleading and that both coefficient magnitude and operating range should be considered.

Conclusion

Overall, this study demonstrates that integrating experimental design with predictive modeling provides an efficient framework for optimizing microalgae-based wastewater treatment. Under the present experimental conditions, RSM outperformed ANN owing to the limited number of experimental observations and offered higher prediction accuracy together with greater model interpretability. Nevertheless, ANN remains a promising approach for modeling complex nonlinear biological processes and is expected to provide superior performance when trained using larger datasets. The proposed methodology can facilitate the optimization and scale-up of sustainable algal wastewater treatment systems while improving nutrient removal efficiency and biomass production.

انتشارات دانشگاه تهران

فصلنامهٔ سیستم‌های انرژی پایدار

سایت نشریه: https://ses.ut.ac.ir

شاپا الکترونیکی: ۸۶۹۳-۲۹۸۰

بهینه‌سازی تصفیهٔ بیولوژیکی فاضلاب و تولید زیست‌توده توسط ریزجلبک *Desmodesmus sp.*: مقایسهٔ روش سطح پاسخ (RSM) و شبکهٔ عصبی مصنوعی (ANN)

سینا لبافی[۱] | فاطمه راضی آستارایی[۲*]

۱. دانشکدهٔ مهندسی انرژی و منابع پایدار، دانشکدگان علوم و فناوری‌های میان‌رشته‌ای، دانشگاه تهران، تهران، ایران. رایانامه: sinalabbafi@ut.ac.ir

۲. نویسندهٔ مسئول، دانشیار دانشکدهٔ مهندسی انرژی و منابع پایدار، دانشکدگان علوم و فناوری‌های میان‌رشته‌ای، دانشگاه تهران، تهران، ایران. رایانامه: razias_m@ut.ac.ir

اطلاعات مقاله

نوع مقاله:
پژوهشی

تاریخ‌های مقاله:
تاریخ دریافت: ۱۴۰۵/۰۲/۱۲
تاریخ بازنگری: ۱۴۰۵/۰۴/۰۴
تاریخ پذیرش: ۱۴۰۵/۰۶/۰۲
تاریخ انتشار: ۱۴۰۵/۱۰/۱۱

کلیدواژه:
بهینه‌سازی،
تصفیه،
ریزجلبک،
زیست‌توده.

چکیده

این پژوهش به بررسی و بهینه‌سازی تصفیهٔ بیولوژیکی فاضلاب و تولید زیست‌توده توسط ریزجلبک *Desmodesmus sp.* می‌پردازد و عملکرد دو روش مدل‌سازی روش سطح پاسخ (RSM) و شبکهٔ عصبی مصنوعی (ANN) را مقایسه می‌کند. در این مطالعه، نمونه‌ها از تالاب انزلی جمع‌آوری شده و پس از پیش‌تیمار و غنی‌سازی، در شرایط کنترل‌شده کشت شدند. متغیرهای عملیاتی شامل شدت نور، نرخ هوادهی، pH و زمان ماند بودند که برای یافتن شرایط بهینه مورد بررسی قرار گرفتند. نتایج نشان داد مدل ANN نسبت به RSM دقت پیش‌بینی بالاتری دارد و توانست روابط غیرخطی بین متغیرهای فرایند و پاسخ‌ها را بهتر شبیه‌سازی کند. شرایط بهینهٔ به‌دست‌آمده شامل شدت نور ۳۵۲/۵ $\mu molphotons.m^{-2}.s^{-1}$، نرخ هوادهی ۱/۲۹ $mg.L^{-1}$، pH برابر ۷/۷۹ و زمان ماند ۷/۹۵ روز بود. در این شرایط، بیشترین راندمان‌ها شامل ۹۰/۲ درصد حذف COD، ۸۰/۶۱ درصد حذف TN، ۹۱/۱۴ درصد حذف TP و تولید ۱/۲۷ $mg.L^{-1}$ زیست‌توده پیش‌بینی شد. نتایج پژوهش نشان می‌دهد استفاده از ریزجلبک *Desmodesmus sp.* می‌تواند رویکردی مؤثر برای تصفیهٔ فاضلاب همراه با تولید زیست‌توده ارزشمند باشد.

استناد: لبافی، سینا و راضی آستارایی، فاطمه (۱۴۰۵). بهینه‌سازی تصفیهٔ بیولوژیکی فاضلاب و تولید زیست‌توده توسط ریزجلبک *Desmodesmus sp.*: مقایسهٔ روش سطح پاسخ (RSM) و شبکهٔ عصبی مصنوعی (ANN). *فصلنامهٔ سیستم‌های انرژی پایدار*، ۶ (۱) ۱۱۱-۱۳۶.

DOI: http//doi.org/10.22059/ses.2026.416097.1258

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: http//doi.org/10.22059/ses.2026.416097.1258

۱. مقدمه

در سال‌های اخیر، با افزایش فشارهای زیست‌محیطی ناشی از تخلیهٔ پساب‌های شهری و صنعتی، توسعهٔ روش‌های کارآمد، کم‌هزینه و پایدار برای تصفیهٔ فاضلاب و بازیابی منابع به یکی از محورهای اصلی پژوهش‌های مهندسی محیط زیست تبدیل شده است. در این‌میان، کاربرد روش‌های مدل‌سازی و بهینه‌سازی آماری برای پیش‌بینی عملکرد فرایندهای تصفیه و نیز تعیین شرایط عملیاتی بهینه، توجه گسترده‌ای را به خود جلب کرده است. مطالعات پیشین نشان داده‌اند شبکه‌های عصبی مصنوعی و سایر الگوریتم‌های یادگیری ماشین قادر هستند روابط غیرخطی پیچیده میان متغیرهای ورودی و خروجی را با دقت زیادی شناسایی کنند. برای مثال، جامی و همکاران [۱] طی پژوهشی با استفاده از شبکهٔ عصبی مصنوعی[۱] (ANN) برای پیش‌بینی عملکرد تصفیه‌خانهٔ فاضلاب نشان دادند مدل‌های تک‌ورودی و چندورودی می‌توانند با دقت مناسبی پارامترهایی مانند اکسیژن مورد نیاز بیوشیمیایی[۲] (BOD) را پیش‌بینی کنند، به‌ویژه زمانی که داده‌ها به‌درستی غربال و بهینه‌سازی شوند. به طور مشابه، حمدا و همکاران [۲] نیز طی پژوهشی نشان دادند ANN نسبت به رگرسیون خطی چندگانه[۳] (MLR) عملکرد بهتری در پیش‌بینی پارامترهای کیفی پساب تصفیه‌خانه دارد که بیانگر برتری مدل‌های غیرخطی در توصیف رفتار پیچیدهٔ سامانه‌های تصفیه است. همچنین، پیکوتووسکا و همکاران [۳] طی پژوهشی نشان دادند مقایسهٔ ANN و MLR برای پیش‌بینی عملکرد محصول بیانگر آن است که ANN از نظر شاخص‌هایی مانند میانگین قدرمطلق خطا[۴] (MAE)، میانگین درصد خطای قدرمطلق[۵] (MAPE) و ضریب تعیین[۶] (R^2) دقت بیشتری دارد، که این موضوع اهمیت مدل‌سازی غیرخطی را در سامانه‌های وابسته به داده‌های محیطی و عملیاتی تأیید می‌کند.

در کنار ANN، روش سطح پاسخ[۷] (RSM) نیز به عنوان ابزاری کارآمد برای طراحی آزمایش و بهینه‌سازی فرایندها در حوزه‌های تصفیهٔ فاضلاب، هضم بی‌هوازی و زیست‌فرایندهای مبتنی بر ریزجلبک‌ها به طور گسترده استفاده شده است. در مرور ارائه‌شده در مطالعهٔ جسنی و همکاران [۴]، RSM توانست با تعداد آزمایش کمتر، شرایط بهینه برای فرایندهای مختلف را مشخص کند و نشان دهد این روش همچنان یکی از ابزارهای معتبر برای تحلیل اثر متغیرهای عملیاتی بر راندمان حذف آلاینده‌ها است. همچنین در مطالعهٔ حمودا و همکاران [۵] نیز ترکیب ANN، RSM و NSGA-II[۸] برای مدل‌سازی و بهینه‌سازی حذف مواد مغذی در یک بیوراکتور غشایی میکروجلبکی، دقت زیاد مدل‌های هوشمند را در کنار توان RSM در تحلیل اثر متغیرها تأیید کرد. این یافته‌ها نشان می‌دهند رویکردهای ترکیبی، نسبت به روش‌های صرفاً تجربی یا صرفاً آماری، ظرفیت بیشتری برای شناسایی روابط پنهان و تعیین شرایط بهینه دارند.

از سوی دیگر، استفاده از فناوری‌های مبتنی بر میکروجلبک در تصفیهٔ پیشرفتهٔ پساب و بازیافت منابع نیز در سال‌های اخیر به طور قابل توجهی گسترش یافته است. طی پژوهش وانگ و همکاران [۶] یک سویه تازه‌جداسازی‌شده از *Desmodesmus sp.* توانست در تصفیهٔ پساب ثانویه، حذف بسیار بالایی برای آمونیوم، نیتروژن کل و فسفر کل نشان دهد و هم‌زمان زیست‌توده و لیپید قابل توجهی تولید کند. این نتایج بیانگر آن است که سامانه‌های جلبکی نه‌تنها برای حذف آلاینده‌ها، بلکه برای تولید محصولات باارزش نیز قابلیت توسعه دارند. افزون بر این، مطالعهٔ ژانگ و همکاران [۷] با بررسی اثر شوری، pH و نیتروژن بر کلروفیل a در *Isochrysis galbana* نشان داد ترکیب RSM با مدل‌های هوش مصنوعی مانند ANN، SVM[۹] و RBFNN[۱۰] می‌تواند برای پیش‌بینی و بهینه‌سازی پاسخ‌های زیستی بسیار مؤثر باشد. به طور مشابه، در مطالعهٔ پوپا و همکاران [۸] نیز اگرچه

1. Artificial Neural Network
2. Biochemical Oxygen Demand
3. Multiple linear regression
4. Mean Absolute Error
5. Mean Absolute Percentage Error
6. Coefficient of Determination
7. Response Surface Methodology
8. Non-dominated Sorting Genetic Algorithm II
9. Support vector machine
10. Radial basis function neural network

تمرکز بر بهینه‌سازی رشد و ترکیب زیست‌تودهٔ جلبکی با استفاده از تکنیک انبوه‌سازی تصادفی[1] (RF) بود، نتایج نشان داد شرایط شرایط محیطی مانند pH، دما، نور و غلظت CO_2 نقش تعیین‌کننده‌ای در رشد و ترکیب شیمیایی جلبک دارند؛ هرچند قدرت پیش‌بینی مدل در این مطالعه متوسط بود، اما اهمیت یادگیری ماشین در تحلیل متغیرهای زیستی را برجسته کرد.

با توجه به مجموع مطالعات پیشین، روشن است که هر یک از رویکردهای ANN، RSM، الگوریتم‌های بهینه‌سازی و مدل‌های تجمعی، مزایا و محدودیت‌های خاص خود را دارند. ANN در شناسایی روابط غیرخطی و پیش‌بینی دقیق، RSM در طراحی و بهینه‌سازی آزمایش‌ها و الگوریتم‌های یادگیری تقویتی یا دسته‌ای در تفسیر و ارتقای عملکرد مدل‌ها نقش مهمی ایفا می‌کنند. با این‌حال، هنوز به توسعهٔ چارچوب‌هایی نیاز است که هم‌زمان بتوانند دقت پیش‌بینی بالا، تفسیرپذیری مناسب و قابلیت کاربرد عملی در سیستم‌های واقعی تصفیه را فراهم کنند. بر این‌اساس، پژوهش حاضر با تکیه بر این پیشینهٔ علمی و با الهام از نتایج مطالعات پیشین، در پی ارائهٔ یک مدل‌سازی دقیق‌تر و قابل اعتمادتر برای تحلیل و بهینه‌سازی فرایند مورد بررسی است. نوآوری این پژوهش در ادغام روش سطح پاسخ (RSM)، شبکه‌های عصبی مصنوعی (ANN)، الگوریتم‌های یادگیری تجمعی در قالب یک چارچوب یکپارچه برای مدل‌سازی و بهینه‌سازی تصفیهٔ فاضلاب مبتنی بر ریزجلبک نهفته است. به خلاف مطالعات پیشین که عمدتاً تنها بر بهینه‌سازی آماری یا پیش‌بینی‌های غیرشفاف[2] تمرکز داشتند، پژوهش حاضر به صورت هم‌زمان دقت پیش‌بینی، تفسیرپذیری مدل، و حذف چندگانهٔ آلاینده‌ها را بر مبنای نتایج آزمون‌های تجربی مورد توجه قرار می‌دهد و از این طریق، یک چارچوب کاربردی و قابل انتقال برای پشتیبانی از تصمیم‌گیری در تصفیهٔ پایدار فاضلاب ارائه می‌کند.

۲. روش کار(مواد و روش‌ها)

۲–۱. نمونه‌برداری، پیش‌تیمار و ایزوله‌سازی نمونه

به منظور جداسازی و شناسایی ریزجلبک‌های فیتوپلانکتونی (به‌ویژه سویه‌های متعلق به جنس *Desmodesmus sp.*)، عملیات نمونه‌برداری از تالاب بین‌المللی انزلی واقع در استان گیلان (شمال ایران) صورت گرفت. این تالاب به عنوان یکی از اکوسیستم‌های بزرگ آب شیرین کشور، به دلیل دریافت مداوم زه‌آب‌های کشاورزی و روان‌آب‌های غنی از مواد مغذی، شرایط یوتروفیک مناسبی را برای رشد و شکوفایی ریزجلبک‌ها فراهم می‌کند [۹].

نمونه‌برداری مطابق استاندارد EN 16698:2015 و روش ارائه‌شده توسط چارلز و همکاران [۱۰] انجام شد. لذا به منظور جمع‌آوری نمونه‌ها، تعداد ۳ ایستگاه نمونه‌برداری در وجه شرقی، غربی و مرکزی تالاب با توجه به گرادیان مواد مغذی و مناطق تحت تأثیر زه‌آب‌های کشاورزی تعیین شد. نمونه‌برداری در فصل تابستان انجام شد؛ چرا که بالا بودن دمای آب، شدت تابش نور خورشید و غلظت بالای مواد مغذی در این فصل، شرایط زیستی بهینه‌ای را برای افزایش تراکم فیتوپلانکتون‌ها و به‌ویژه گونه‌های جنس *Desmodesmus sp.* فراهم می‌آورد.

در هر یک از ایستگاه‌ها، نمونه‌های آب سطحی (از عمق ۱۰ تا ۳۰ سانتی‌متری) در ۳ تکرار بیولوژیکی و با استفاده از ظروف پلی‌اتیلن استریل ۱ لیتری جمع‌آوری شد (در مجموع ۹ نمونه آب). برای حفظ سلامت نمونه‌ها و جلوگیری از تغییر در ساختار جمعیت ریزجلبکی، ظروف نمونه‌برداری بلافاصله پس از برداشت در تاریکی و دمای حدود ۴ درجهٔ سانتی‌گراد (داخل یخدان) قرار گرفته و در کوتاه‌ترین زمان ممکن برای مراحل جداسازی و خالص‌سازی به آزمایشگاه منتقل شدند [۱۱].

در آزمایشگاه، نمونه‌ها ابتدا از یک صافی ۱۰۰ میکرومتری عبور داده شدند تا ذرات درشت، بقایای گیاهی و زئوپلانکتون‌ها حذف شوند. این مرحله باعث افزایش نسبت ریزجلبک‌ها در نمونه و تسهیل فرایند غنی‌سازی می‌شود. نمونه‌های صاف‌شده تا زمان شروع آزمایش‌ها در دمای ۴ درجهٔ سانتی‌گراد نگهداری شدند تا فعالیت زیستی ناخواسته به حداقل برسد.

برای غنی‌سازی ریزجلبک‌ها و ایجاد شرایطی که گونه‌های مقاوم نظیر *Desmodesmus sp.* بتوانند بر سایر گونه‌ها غالب شوند، بخشی از نمونهٔ خام در محیط کشت N–BG11 (نسخهٔ فاقد نیتروژن محیط کلاسیک BG11) کشت داده شد. کشت غنی‌سازی‌شده در ارلن‌فلاسک‌های ۵۰۰ میلی‌لیتری در شرایط دمایی ۲۵ ± ۲ درجهٔ سانتی‌گراد، شدت نور ۱۰۰ µmol photons.

1. Random Forest
2. Black-box

$m^{-2}\ s^{-1}$ و دورهٔ روشنایی ۱۶ ساعت و تاریکی ۸ ساعت قرار داده شد. هوادهی مداوم نیز برای جلوگیری از رسوب سلولی و تأمین CO_2 مورد نیاز رشد فراهم شد [۱۲].

فرایند ایزوله‌سازی با هدف به دست آوردن یک کشت تک‌گونه و حذف آلودگی‌های همراه انجام شد. برای دستیابی به این هدف از ترکیبی از روش‌های رقیق‌سازی سریالی، کشت سطحی و جداسازی تک‌سلولی استفاده شد. در نهایت کشت ایزوله‌شده از یک فیلتر ۵ میکرومتری عبور داده شد. این فیلتر اجازهٔ عبور باکتری‌ها را می‌دهد، اما سلول‌های بزرگ‌تر *Desmodesmus sp.* را نگه می‌دارد. پس از این مرحله، سلول‌های جمع‌آوری‌شده در محیط تازه BG11 کشت شدند و درنهایت، پس از چند بار انتقال متوالی، کشت خالص با ظاهر یکنواخت و پایدار آماده شد.

برای تأیید مولکولی گونه، DNA ژنومی سلول‌ها با روش اصلاح‌شده CTAB استخراج شد. سپس ناحیهٔ 18S rRNA با پرایمرهای عمومی تکثیر و محصول PCR، برای تعیین توالی انتخاب شد. توالی‌های به‌دست‌آمده در پایگاه NCBI با استفاده از BLAST بررسی شد و شباهت ۹۸ تا ۹۹ درصدی با گونه‌های گزارش‌شده از جنس *Desmodesmus sp.* تأیید شد. این مرحله به عنوان تأیید نهایی خالص‌سازی و شناسایی گونهٔ مورد استفاده در آزمایش‌های تصفیه در نظر گرفته شد. کشت نهایی در ارلن‌های ۵۰۰ میلی‌لیتری حاوی محیط تازه BG11 منتقل شد و تا رسیدن به تراکم مناسب (OD680 حدود ۰/۸ $mg.L^{-1}$) تکثیر یافت.

۲-۲. مؤلفه‌های ساختار پساب و آلاینده‌ها

پساب مورد استفاده در این پژوهش از خروجی واحد ته‌نشینی ثانویه تصفیه‌خانهٔ فاضلاب شهری جنوب تهران جمع‌آوری شد. این نوع پساب به دلیل داشتن غلظت متعادل نیتروژن، فسفر و مواد آلی، یکی از منابع مناسب برای آزمون کارایی ریزجلبک‌ها در حذف آلاینده‌ها و تولید بیومس به شمار می‌رود. نمونه‌برداری در ساعت‌های اولیه روز انجام شد تا نوسانات روزانه کیفیت فاضلاب به حداقل برسد و داده‌های قابل اتکاتری برای مدل‌سازی فراهم شود.

حدود ۱۰ لیتر از پساب خروجی به کمک ظروف پلی‌اتیلنی استریل جمع‌آوری و بلافاصله درون محفظهٔ سرد قرار داده شد. نمونه‌ها طی مدت کمتر از چهار ساعت به آزمایشگاه منتقل شده و تا زمان آغاز آزمایش‌ها در دمای ۴ درجهٔ سانتی‌گراد نگهداری شدند تا تغییرات ناشی از فعالیت میکروبی یا تبخیر کاهش یابد. پیش از استفاده، پساب از صافی ۱ میلی‌متری عبور داده شد تا ذرات درشت، نخاله و مواد معلق حجیم حذف شده و شرایط یکنواخت‌تری برای رشد ریزجلبک فراهم شود.

به منظور تعیین ویژگی‌های اولیه پساب و فراهم کردن داده‌های دقیق برای مدل‌سازی و تحلیل عملکرد ریزجلبک، مجموعه‌ای از آنالیزهای فیزیکوشیمیایی مطابق روش‌های استاندارد APHA انجام شد. نتایج آنالیزها نشان داد پساب خروجی واحد ته‌نشینی ثانویه دارای ویژگی‌های کیفی (۱۸ ± ۱۵۵ $mg.L^{-1}$ COD)، (۱۰ ± ۶۵ $mg.L^{-1}$ BOD_5)، (۳.۱ ± ۲۲.۴ $mg.L^{-1}$ NH_4^+–N)، (۱.۴ ± ۶.۷ $mg.L^{-1}$ NO_3^-–N)، (۴.۶ ± ۳۴.۸ $mg.L^{-1}$ TN)، (۰.۷ ± ۴.۱ $mg.L^{-1}$ PO_4^{3-}–P)، (۰.۹ ± ۵.۲ $mg.L^{-1}$ TP)، (۶ ± ۴۸ $mg.L^{-1}$ TSS) و (۰.۲ ± ۷.۴) pH است.

نتایج آنالیز نشان داد پساب مورد استفاده، دارای ویژگی‌هایی مشابه پساب شهری متعارف بوده و غلظت قابل توجهی از نیتروژن و فسفر دارد که شرایط مناسبی برای رشد ریزجلبک‌ها و تحلیل کارایی تصفیه فراهم می‌کند. همچنین، COD موجود در محدوده‌ای قرار داشت که برای رشد *Desmodesmus sp.* قابل تحمل بود و امکان بررسی هم‌زمان حذف مواد آلی و تولید بیومس را فراهم می‌کرد.

برای حذف اثر تغییرات pH طی ذخیره‌سازی، pH پساب پیش از شروع هر آزمایش اندازه‌گیری و در صورت نیاز تنها با استفاده از محلول‌های HCl یا NaOH (بدون افزودن مواد مغذی اضافی) تا رسیدن به مقدار تعیین‌شده در طراحی آزمایش تنظیم می‌شد. هیچ‌گونه ضد عفونی یا گندزدایی شیمیایی روی پساب انجام نشد تا ماهیت واقعی و شرایط زیستی آن حفظ شود و عملکرد ریزجلبک در محیط واقعی‌تری مورد ارزیابی قرار گیرد.

۲-۳. طراحی آزمایش

در این مطالعه به منظور بررسی و بهینه‌سازی عملکرد ریزجلبک *Desmodesmus sp.* در فرایند تصفیهٔ پساب و افزایش تولید زیست‌توده و ترکیبات ارزشمند، چند متغیر عملیاتی کلیدی به عنوان متغیرهای مستقل طراحی آزمایش انتخاب شدند. انتخاب این متغیرها بر اساس مطالعات پیشین در حوزهٔ کشت ریزجلبک‌ها، اصول فیزیولوژی جلبک‌ها و همچنین، شرایط عملی فرایندهای فیکورمدیشن انجام شد تا بتوان اثر عوامل محیطی مهم بر رشد جلبک و کارایی حذف آلاینده‌ها را به طور هم‌زمان بررسی کرد.

یکی از متغیرهای انتخاب‌شده شدت نور است. نور منبع اصلی انرژی برای فتوسنتز در ریزجلبک‌ها محسوب می‌شود و نقش تعیین‌کننده‌ای در نرخ رشد، تولید زیست‌توده و تجمع لیپید دارد. در شرایط نور کم، فرایند فتوسنتز محدود می‌شود و رشد سلولی کاهش می‌یابد، در حالی که در شدت‌های بسیار بالا ممکن است پدیدهٔ مهار نوری رخ دهد که به کاهش فعالیت فتوسنتزی منجر می‌شود. به همین‌دلیل در این مطالعه شدت نور در بازه حدود ۵۰ تا ۴۵۰ میکرومول فوتون بر متر مربع بر ثانیه ($\mu mol\ m^{-2}\ s^{-1}$) در نظر گرفته شد.

متغیر مهم دیگر pH محیط کشت است که تأثیر مستقیمی بر فعالیت آنزیمی، دسترسی مواد مغذی و همچنین، تعادل گونه‌های کربنی محلول در محیط دارد. ریزجلبک‌ها معمولاً در شرایط pH نزدیک به خنثی تا کمی قلیایی بهترین عملکرد رشد را نشان می‌دهند. علاوه بر این، pH می‌تواند بر کارایی حذف نیتروژن و فسفر از پساب نیز اثرگذار باشد. بر این‌اساس، pH در بازه ۶ تا ۹ انتخاب شد.

نرخ هوادهی به عنوان یکی از متغیرهای عملیاتی اصلی در سیستم‌های کشت ریزجلبک انتخاب شد، زیرا این پارامتر نقش هم‌زمانی در انتقال جرم، تأمین CO_2 برای فتوسنتز و اختلاط محیط کشت دارد. تأمین CO_2 از طریق هوادهی برای حفظ فعالیت فتوسنتزی و رشد بیومس جلبک ضروری است، در حالی که اختلاط ایجادشده توسط جریان هوا از ته‌نشینی سلول‌ها جلوگیری کرده و توزیع یکنواخت نور و مواد مغذی را در محیط فراهم می‌کند. علاوه بر این، هوادهی باعث بهبود انتقال مواد محلول و تبادل گازها در محیط می‌شود و در نتیجه می‌تواند کارایی حذف آلاینده‌هایی مانند COD، نیتروژن و فسفر را افزایش دهد. با این‌حال، افزایش بیش از حد نرخ هوادهی می‌تواند موجب ایجاد تنش برشی بر سلول‌های جلبکی، کاهش زمان تماس CO_2 با فاز مایع و افزایش مصرف انرژی شود. بر اساس گزارش‌های موجود در مطالعات مربوط به کشت ریزجلبک‌ها در فتوبیوراکتورها، محدودهٔ مناسب نرخ هوادهی معمولاً در بازه حدود ۰/۲ تا ۲ لیتر در دقیقه گزارش شده است.

همچنین، زمان ماند یا زمان کشت به عنوان یک متغیر عملیاتی مهم در نظر گرفته شد. زمان ماند تعیین می‌کند که ریزجلبک چه مدت در معرض مواد مغذی و شرایط محیطی قرار دارد و بنابراین، بر میزان تجمع زیست‌توده و حذف آلاینده‌ها اثرگذار است. در زمان‌های کوتاه ممکن است رشد جلبک به مرحلهٔ لگاریتمی کامل نرسد و کارایی حذف آلاینده‌ها پایین باشد، در حالی که زمان‌های بسیار طولانی می‌توانند به کاهش بهره‌وری فرایند و افزایش هزینهٔ عملیاتی منجر شوند. بنابراین، زمان ماند در بازه ۳ تا ۱۰ روز انتخاب شد.

برای ارزیابی عملکرد سیستم، چند متغیر پاسخ[1] در نظر گرفته شد. مهم‌ترین پاسخ‌ها شامل راندمان حذف آلاینده‌ها از جمله COD، نیتروژن کل (TN) و فسفر کل (TP) هستند که بیانگر کارایی فرایند تصفیهٔ پساب توسط ریزجلبک هستند. علاوه بر این، تولید زیست‌تودهٔ جلبکی به عنوان شاخصی از رشد و بهره‌وری زیستی سیستم اندازه‌گیری شد، زیرا زیست‌توده حاصل می‌تواند به عنوان منبع بالقوه برای تولید سوخت زیستی یا سایر محصولات زیستی مورد استفاده قرار گیرد. در برخی موارد، درصد یا بازده لیپید نیز به عنوان پاسخ تکمیلی در نظر گرفته می‌شود، زیرا تجمع لیپید در ریزجلبک‌ها نقش مهمی در ارزیابی پتانسیل تولید بیودیزل دارد.

در مجموع، انتخاب این متغیرها و بازه‌های عملیاتی مربوط به آن‌ها بر اساس ترکیبی از ملاحظات فیزیولوژیکی ریزجلبک، شرایط واقعی پساب و یافته‌های گزارش‌شده در مطالعات پیشین انجام شد تا امکان شناسایی شرایط بهینه برای رشد *Desmodesmus sp.* و افزایش کارایی تصفیهٔ پساب فراهم شود. همچنین، استفاده از این متغیرها در طراحی آزمایش این امکان

1. Response variables

را فراهم می‌کند که اثرات متقابل میان عوامل مختلف محیطی بررسی شده و شرایط عملیاتی بهینه برای کاربردهای عملی در مقیاس بزرگ‌تر تعیین شود.

۲-۴. نحوهٔ کشت

به منظور کشت ریزجلبک *Desmodesmus sp.*، از یک فتوبیوراکتور شیشه‌ای استوانه‌ای در مقیاس آزمایشگاهی استفاده شد. حجم کاری راکتور حدود ۲ لیتر در نظر گرفته شد تا امکان تأمین نور یکنواخت و اختلاط مناسب فراهم شود. قبل از شروع هر آزمایش، راکتور و تمام تجهیزات مرتبط شامل لوله‌های هوادهی، اتصالات و ظروف نمونه‌برداری با استفاده از محلول‌های ضدعفونی‌کننده و سپس آب مقطر شست‌وشو داده شدند تا از هرگونه آلودگی میکروبی جلوگیری شود. پس از آماده‌سازی سیستم، پساب مورد نظر پس از فیلتراسیون اولیه برای حذف ذرات درشت وارد راکتور شد.

پس از پر شدن راکتور با پساب، مقدار ۱۰ درصد حجم کاری راکتور از کشت فعال *Desmodesmus sp.* به عنوان تلقیح اولیه به سیستم اضافه شد. پس از تلقیح، سیستم در شرایط کنترل‌شده شامل شدت نور مشخص، دمای محیط آزمایشگاهی (حدود ۲۵±۲ درجهٔ سانتی‌گراد) و هوادهی مداوم قرار گرفت. نور مورد نیاز برای فتوسنتز توسط لامپ‌های LED سفید یا فلورسنت تأمین شد و شدت نور در محدودهٔ تعیین‌شده طراحی آزمایش تنظیم شد. برای تأمین دی‌اکسید کربن و جلوگیری از ته‌نشینی سلول‌ها، هوای فشرده از طریق یک پمپ هوا و سنگ هواده به داخل راکتور تزریق شد که این امر علاوه بر اختلاط مناسب محیط، انتقال جرم مواد مغذی را نیز تسهیل می‌کند. به منظور حفظ یکنواختی شرایط در طول آزمایش، راکتورها از چرخهٔ نوری ۱۲ ساعت روشنایی و ۱۲ ساعت تاریکی استفاده شد. طی دورهٔ کشت، pH محیط نیز به صورت دوره‌ای اندازه‌گیری شد و در صورت نیاز با استفاده از محلول‌های اسیدی یا بازی رقیق تنظیم شد.

نمونه‌برداری از راکتورها به منظور بررسی رشد جلبک و ارزیابی کارایی حذف آلاینده‌ها در فواصل زمانی هر ۲۴ ساعت یک‌بار انجام گرفت تا روند تغییرات پارامترهای مورد مطالعه طی زمان مشخص شود. برای هر بار نمونه‌برداری، حجم ۲۰ میلی‌لیتر با استفاده از پیپت استریل از بخش میانی راکتور برداشت شد تا نمونهٔ نمایندهٔ مناسبی از کل محیط باشد. پس از برداشت نمونه، در صورت نیاز حجم معادل آن با محیط استریل جایگزین شد تا حجم کاری راکتور ثابت باقی بماند.

برای تعیین رشد جلبک و تولید زیست‌توده، چگالی نوری نمونه‌ها در طول موج ۶۸۰ نانومتر با استفاده از اسپکتروفتومتر اندازه‌گیری شد. همچنین، برای اندازه‌گیری پارامترهای کیفی پساب شامل COD، نیتروژن کل و فسفر کل، نمونه‌ها ابتدا در صورت نیاز سانتریفیوژ شده و سپس آنالیزهای مربوطه مطابق با روش‌های استاندارد انجام شد.

به منظور افزایش دقت و قابلیت اعتماد نتایج، تمامی آزمایش‌ها حداقل در سه تکرار مستقل انجام شدند. در هر تکرار، شرایط عملیاتی مشابه شامل شدت نور، pH، زمان ماند و سایر متغیرهای طراحی آزمایش به طور یکسان اعمال شد. داده‌های حاصل از هر تکرار ثبت و میانگین آن‌ها به عنوان نتیجهٔ نهایی گزارش شد و انحراف معیار نیز برای نشان دادن پراکندگی داده‌ها محاسبه شد.

۲-۵. تحلیل عددی و مدل‌سازی

۲-۵-۱. مدل سازی به روش RSM

به منظور بررسی تأثیر پارامترهای عملیاتی مختلف بر رشد ریزجلبک و کارایی حذف آلاینده‌ها از پساب، از روش آماری سطح پاسخ (RSM) برای طراحی آزمایش و مدل‌سازی داده‌ها استفاده شد. این روش یکی از روش‌های پرکاربرد در بهینه‌سازی فرآیندها محسوب می‌شود و امکان بررسی هم‌زمان اثر چندین متغیر مستقل و همچنین اثرات متقابل آن‌ها بر متغیرهای پاسخ را فراهم می‌کند.

در این پژوهش برای طراحی آزمایش‌ها از طرح باکس - بنکن[1] استفاده شد. این طرح به دلیل کارایی بالا در تخمین مدل‌های درجهٔ دوم و نیاز به تعداد آزمایش کمتر نسبت به بسیاری از طرح‌های دیگر، در مطالعات بهینه‌سازی فرایندهای زیستی

1. Box–Behnken Design

و زیست‌محیطی کاربرد گسترده‌ای دارد. بر اساس این روش، چهار متغیر مستقل که بیشترین تأثیر را بر رشد ریزجلبک و حذف مواد آلی و مغذی دارند انتخاب شدند. این متغیرها شامل شدت نور (A)، هوادهی (B)، pH محیط (C) و زمان ماند هیدرولیکی (D) بودند. هر یک از این متغیرها در سه سطح مختلف شامل سطح پایین، متوسط و بالا بررسی شدند.

استفاده از طرح باکس ـ بنکن، در مجموع ۲۹ آزمایش برای بررسی اثر چهار متغیر بر پاسخ‌های مورد نظر طراحی شد. در این طرح پنج نقطهٔ مرکزی در نظر گرفته شد تا امکان برآورد خطای آزمایش و بررسی تکرارپذیری داده‌ها فراهم شود. تمامی آزمایش‌ها در شرایط یکسان و در سه تکرار مستقل انجام شدند و میانگین داده‌ها برای تحلیل آماری مورد استفاده قرار گرفت.

در این مطالعه، چهار متغیر پاسخ برای ارزیابی عملکرد سیستم در نظر گرفته شد. این پاسخ‌ها شامل راندمان حذف COD، راندمان حذف نیتروژن کل، راندمان حذف فسفر کل و میزان تولید زیست‌توده جلبکی بودند. این شاخص‌ها به دلیل اهمیت آن‌ها در ارزیابی کارایی فرایند تصفیهٔ پساب و همچنین، پتانسیل تولید زیست‌توده برای کاربردهای زیست‌انرژی انتخاب شدند.

برای توصیف رابطه بین متغیرهای مستقل و پاسخ‌ها، از یک مدل چندجمله‌ای درجهٔ دوم استفاده شد. فرم کلی این مدل به صورت معادلهٔ ۱ بیان می‌شود.

$$Y = \beta_0 + \Sigma\beta_i X_i + \Sigma\beta_{ii} X_i^2 + \Sigma\beta_{ij} X_i X_j \quad (۱)$$

در این معادله X_i نشان‌دهندهٔ مقدار متغیر، Y نشان‌دهندهٔ مقدار پیش‌بینی‌شدهٔ پاسخ، β_0 ضریب ثابت مدل، β_i ضرایب اثرات خطی متغیرها، β_{ii} ضرایب اثرات درجهٔ دوم و β_{ij} ضرایب اثرات متقابل بین متغیرها هستند. برای ارزیابی معناداری مدل و ضرایب آن از تحلیل واریانس[1] (ANOVA) استفاده شد. همچنین، شاخص‌های آماری مختلفی از جمله ضریب تعیین (R^2)، ضریب تعیین تعدیل‌شده (Adjusted R^2) و ضریب تعیین پیش‌بینی‌شده (Predicted R^2) برای بررسی میزان برازش مدل با داده‌های آزمایشگاهی محاسبه شدند. علاوه بر این، آزمون عدم برازش[2] برای ارزیابی مناسب بودن مدل در توصیف داده‌های تجربی مورد استفاده قرار گرفت.

۲-۵-۲. مدل‌سازی با شبکهٔ عصبی مصنوعی (ANN)

به منظور مدل‌سازی رفتار غیرخطی سیستم و پیش‌بینی راندمان حذف COD، علاوه بر روش سطح پاسخ (RSM)، از شبکهٔ عصبی مصنوعی (ANN) استفاده شد. شبکه‌های عصبی مصنوعی به دلیل توانایی بالا در یادگیری روابط پیچیده و غیرخطی میان متغیرهای ورودی و خروجی، یکی از روش‌های مؤثر در مدل‌سازی فرایندهای زیستی و زیست‌محیطی محسوب می‌شوند.

در این پژوهش از شبکهٔ عصبی نوع پرسپترون چندلایه[3] (MLP) با ساختار پیشخور به صورت جداگانه برای هر پاسخ استفاده شد. ساختار شبکه شامل یک لایهٔ ورودی، یک لایهٔ پنهان و یک لایهٔ خروجی بود. لایهٔ ورودی دارای چهار نورون متناظر با متغیرهای مستقل ورودی شامل شدت نور (A)، هوادهی (B)، زمان ماند هیدرولیکی (C) و pH محیط (D) بود. همچنین، یک نورون در لایهٔ خروجی برای پیش‌بینی پاسخ ها در نظر گرفته شد.

به منظور افزایش پایداری فرایند آموزش و جلوگیری از اختلاف مقیاس بین متغیرها، داده‌های ورودی و خروجی قبل از آموزش با استفاده از تابع mapminmax در محیط نرم‌افزار MATLAB به بازه ۱- تا ۱+ نرمال‌سازی شدند. برای جلوگیری از نشت اطلاعات[4]، پارامترهای نرمال‌سازی در هر مرحله تنها از داده‌های آموزش محاسبه شدند و سپس برای نرمال‌سازی داده‌های آزمون همان مرحله مورد استفاده قرار گرفتند.

با توجه به محدود بودن تعداد داده‌های آزمایشگاهی (۲۹ نمونه)، ارزیابی عملکرد مدل با استفاده از روش اعتبارسنجی متقاطع پنج‌تایی[5] انجام شد. به این‌منظور، داده‌ها به پنج زیرمجموعهٔ تقریباً مساوی تقسیم شدند. در هر تکرار، چهار زیرمجموعه (حدود ۸۰ درصد داده‌ها) برای آموزش شبکه و زیرمجموعهٔ باقی‌مانده (حدود ۲۰ درصد داده‌ها) برای آزمون مدل مورد استفاده قرار

1. Analysis of variance
2. Lack-of-fit
3. Multilayer Perceptron
4. Data Leakage
5. 5-Fold Cross Validation

گرفت. این فرایند پنج مرتبه تکرار شد، به گونه‌ای که هر نمونه تنها یک بار به عنوان داده آزمون مورد استفاده قرار گرفت. در پایان، پیش‌بینی‌های حاصل از تمامی بخش‌ها تجمیع شده و شاخص‌های عملکرد مدل بر اساس پیش‌بینی‌های خارج از مجموعه آموزش[1] محاسبه شدند. این روش برآورد واقع‌بینانه‌تری از توانایی تعمیم مدل نسبت به تقسیم‌بندی ساده داده‌ها به مجموعه‌های آموزش و آزمون ارائه می‌دهد.

به منظور تعیین ساختار بهینهٔ شبکه، تعداد نورون‌های لایهٔ پنهان در بازه ۲ تا ۸ نورون مورد بررسی قرار گرفت و برای هر ساختار، فرایند اعتبارسنجی متقاطع به طور کامل تکرار شد. در نهایت، ساختاری که کمترین مقدار میانگین ریشهٔ میانگین مربعات خطا (RMSE) در مجموعه‌های آزمون را داشت، به عنوان معماری بهینه انتخاب شد.

آموزش شبکه با استفاده از الگوریتم منظم‌سازی بیزین[2] (trainbr) در محیط MATLAB انجام شد. این الگوریتم با اعمال منظم‌سازی در فرایند آموزش، ضمن کاهش احتمال بیش‌برازش، توانایی تعمیم مدل را به‌ویژه در مجموعه داده‌های کوچک افزایش می‌دهد. در لایهٔ پنهان از تابع انتقال غیرخطی تانژانت سیگموئید (tansig) و در لایهٔ خروجی از تابع انتقال خطی (purelin) استفاده شد. عملکرد شبکه بر اساس معیار میانگین مربعات خطا (MSE) ارزیابی شد. حداکثر تعداد دوره‌های آموزش (Epoch) برابر با ۲۰۰۰، مقدار هدف خطا برابر با $۱۰^{-۸}$ و حداقل گرادیان برابر با $۱۰^{-۱۰}$ در نظر گرفته شد. با این‌حال، فرایند آموزش بر اساس معیار توقف داخلی الگوریتم منظم‌سازی بیزین و بر اثر رسیدن پارامتر μ به مقدار بیشینه، پیش از رسیدن به حداکثر تعداد دوره‌های آموزش خاتمه یافت.

پس از انتخاب بهترین معماری بر اساس نتایج اعتبارسنجی متقاطع، یک شبکهٔ عصبی نهایی با همان ساختار و با استفاده از تمامی داده‌های آزمایشگاهی آموزش داده شد. این مدل نهایی برای پیش‌بینی پاسخ در شرایط عملیاتی جدید مورد استفاده قرار گرفت.

به منظور ارزیابی قابلیت تعمیم و توانایی پیش‌بینی مدل‌های توسعه‌یافته، پس از تکمیل فرایند مدل‌سازی، چهار نقطهٔ عملیاتی برای اعتبارسنجی انتخاب شدند. این نقاط شامل نقطهٔ بهینهٔ پیش‌بینی‌شده توسط مدل RSM و سه نقطهٔ اعتبارسنجی مستقل بودند که با استفاده از رویکرد پر کردن فواصل[3] به گونه‌ای انتخاب شدند که پوشش مناسبی از فضای طراحی آزمایش فراهم شود. تمامی این نقاط در محدودهٔ متغیرهای طراحی قرار داشتند، اما جزء ۲۹ آزمایش اولیه طراحی‌شده نبودند. سپس، مقادیر پاسخ برای این شرایط توسط مدل‌های RSM و ANN پیش‌بینی شد و آزمایش‌های تجربی متناظر نیز در همان شرایط انجام گرفت. در نهایت، مقادیر پیش‌بینی‌شده توسط هر دو مدل با نتایج تجربی مقایسه شدند تا دقت پیش‌بینی و قابلیت تعمیم مدل‌ها در شرایط عملیاتی جدید ارزیابی شود.

۳. یافته‌ها

۳–۱. نتایج آزمایشگاهی

در این مطالعه، عملکرد ریزجلبک *Desmodesmus sp.* در تصفیهٔ پساب در قالب ۲۹ آزمایش طراحی‌شده با روش باکس ـ بنکن بررسی شد. جدول ۱ نتایج آزمون در شرایط عملیاتی (شدت نور، نرخ هوادهی، pH، زمان ماند) همراه با پاسخ‌های به‌دست‌آمده شامل میزان حذف COD، غلظت بیومس، حذف نیتروژن کل (TN) و فسفات کل (TP) است.

در مجموع، نرخ حذف COD در بازه ۵۵ تا ۸۷ درصد و تولید بیومس بین ۰/۴۵ تا ۱/۳۵ گرم بر لیتر متغیر بود. همچنین، حداکثر مقدار حذف نیتروژن و فسفات به‌ترتیب به ۸۵ درصد و ۹۰ درصد رسید. این نوسانات نشان می‌دهد فاکتورهای عملیاتی تأثیر قابل توجهی بر عملکرد سیستم دارند و نیاز به مدل‌سازی دقیق‌تری است.

1. Out-of-Fold Predictions
2. Bayesian Regularization
3. Space-filling

جدول ۱. طراحی آزمایش و پاسخ‌های اندازه‌گیری‌شده

ردیف	شدت نور (فاکتور A) $\mu molphotons.m^{-2}.s^{-1}$	نرخ هوادهی (فاکتور B) $mg.L^{-1}$	زمان ماند (فاکتور C) روز	میزان pH (فاکتور D)	تولید زیست‌توده $mg.L^{-1}$	میزان حذف COD ٪	میزان حذف TN ٪	میزان حذف TP ٪
۱	۲۵۰	۱	۷.۵	۶.۵	۱.۱۲	۸۲	۷۸	۸۴
۲	۲۵۰	۰.۵	۶	۶.۵	۰.۷	۶۵	۵۶	۶۰
۳	۵۰	۱	۷.۵	۱۰	۰.۸۵	۷۴	۶۷	۷۸
۴	۲۵۰	۱	۷.۵	۶.۵	۱.۱۳	۸۲	۷۸	۸۴
۵	۲۵۰	۱	۷.۵	۶.۵	۱.۱۶	۸۳	۷۹	۸۵
۶	۲۵۰	۱	۶	۱۰	۰.۸۵	۷۲	۶۲	۶۸
۷	۵۰	۱	۹	۶.۵	۰.۵۵	۶۲	۵۵	۶۸
۸	۲۵۰	۱.۵	۷.۵	۱۰	۱.۳	۸۶	۸۳	۸۸
۹	۴۵۰	۱.۵	۷.۵	۶.۵	۱.۳۵	۸۷	۸۵	۹۰
۱۰	۴۵۰	۱	۷.۵	۱۰	۱.۲	۸۴	۸۲	۸۶
۱۱	۴۵۰	۰.۵	۷.۵	۶.۵	۰.۹۵	۷۴	۶۲	۷۴
۱۲	۴۵۰	۱	۷.۵	۳	۰.۹۵	۷۰	۶۶	۷۵
۱۳	۵۰	۱	۷.۵	۳	۰.۵	۵۸	۵۰	۶۰
۱۴	۲۵۰	۱	۷.۵	۶.۵	۱.۱۵	۷۹	۷۹	۸۳
۱۵	۲۵۰	۱	۹	۱۰	۱	۸۰	۷۲	۸۶
۱۶	۲۵۰	۰.۵	۷.۵	۱۰	۰.۸	۷۳	۶۵	۷۴
۱۷	۵۰	۱	۶	۶.۵	۰.۴۸	۵۷	۵۰	۶۰
۱۸	۲۵۰	۰.۵	۹	۶.۵	۰.۶۵	۶۳	۵۱	۷۰
۱۹	۲۵۰	۱	۷.۵	۶.۵	۱.۱	۸۱	۷۷	۸۲
۲۰	۲۵۰	۱.۵	۶	۶.۵	۰.۹۲	۷۲	۶۰	۶۵
۲۱	۲۵۰	۰.۵	۷.۵	۳	۰.۵۲	۶۰	۴۸	۵۸
۲۲	۵۰	۰.۵	۷.۵	۶.۵	۰.۴۵	۵۵	۵۰	۵۵
۲۳	۲۵۰	۱	۹	۳	۰.۶۵	۶۳	۵۵	۷۰
۲۴	۴۵۰	۱	۶	۶.۵	۴۳.۰	۷۴	۶۰	۶۵
۲۵	۲۵۰	۱	۶	۳	۰.۵	۵۸	۴۹	۵۵
۲۶	۴۵۰	۱	۹	۶.۵	۱.۰۵	۷۸	۷۱	۸۷
۲۷	۵۰	۱.۵	۷.۵	۶.۵	۰.۷	۶۸	۶۱	۷۲
۲۸	۲۵۰	۱.۵	۷.۵	۳	۱	۷۴	۶۷	۷۶
۲۹	۲۵۰	۱.۵	۹	۶.۵	۱.۲	۸۲	۷۸	۸۸

۳-۲. مدل‌سازی با روش سطح پاسخ (RSM)

۳-۲-۱. تحلیل واریانس (ANOVA)

مدل‌های چندجمله‌ای درجهٔ دوم بر اساس داده‌های حاصل از طراحی آزمایش باکس ـ بنکن توسعه داده شدند تا رابطهٔ بین متغیرهای عملیاتی و پاسخ‌های سیستم توصیف شود. به منظور ارزیابی معناداری آماری و کفایت مدل‌های توسعه‌یافته، از تحلیل واریانس (ANOVA) استفاده شد و نتایج آن در جدول ۲ ارائه شده است.

جدول ۲. نتایج تحلیل واریانس

مدل	ضریب تعیین (R^2)	ضریب تعیین تعدیل‌شده (R^2_adj)	ضریب تعیین پیش‌بینی‌شده (R^2_pred)	خطای ریشه میانگین مربعات (RMSE)	شاخص F (F-value)		مقادیر احتمال (p-value)	
					مدل	عدم برازش	مدل	عدم برازش
تولید زیست‌توده	۰.۹۸۳۹	۰.۹۶۷۷	۰.۹۱۱۷	۰.۰۴۹	۶۰.۹۸	۵.۵۰	<۰.۰۰۰۱ معنادار	۰.۰۵۷۳ غیر معنادار
میزان حذف COD	۰.۹۸۷۸	۰.۹۷۵۶	۰.۹۳۴۱	۱.۵۳	۸۰.۹۴	۴.۲۷	<۰.۰۰۰۱ معنادار	۰.۰۸۷۱ غیر معنادار
میزان حذف TN	۰.۹۸۰۲	۰.۹۸۱۵	۰.۹۴۹۶	۱.۶۱	۱۰۶.۹۳	۴.۸۰	<۰.۰۰۰۱ معنادار	۰.۰۷۲۱ غیر معنادار
میزان حذف TP	۰.۹۸۲۰	۰.۹۶۴۱	۰.۹۰۳۰	۲.۱۰	۵۴.۷۱	۴.۳۳	<۰.۰۰۰۱ معنادار	۰.۰۸۵۲ غیر معنادار

نتایج تحلیل واریانس نشان داد تمامی مدل‌های توسعه‌یافته از نظر آماری معنادار هستند، به طوری که مقادیر احتمال (p-value) برای تمام پاسخ‌ها کمتر از ۰/۰۰۰۱ به دست آمد. علاوه بر این، آزمون عدم برازش در تمامی مدل‌ها غیرمعنادار ($p > ۰.۰۵$) بود که نشان‌دهندهٔ برازش مناسب مدل‌ها با داده‌های تجربی و کفایت آن‌ها در توصیف روابط بین متغیرهای فرایندی و پاسخ‌ها است.

مقادیر ضریب تعیین (R^2) برای تمامی پاسخ‌ها بالا بود و توانایی مناسب مدل‌ها در توضیح تغییرات داده‌های تجربی را نشان داد. به طور مشخص، مقادیر R^2 برای حذف COD، حذف TN، تولید زیست‌توده و حذف TP به‌ترتیب برابر با ۰/۹۸۷۸، ۰/۹۸۰۲، ۰/۹۸۳۹ و ۰/۹۸۲۰ به دست آمد. این نتایج نشان می‌دهد بیش از ۹۵ درصد از تغییرات پاسخ‌ها توسط مدل‌های رگرسیونی ارائه‌شده قابل توضیح است.

همچنین، مقادیر ضریب تعیین تعدیل‌شده (R^2_adj) برای تمامی پاسخ‌ها بالا گزارش شد که بیانگر پایداری و قابلیت اطمینان مدل‌ها پس از در نظر گرفتن تعداد متغیرهای مستقل در مدل است. از سوی دیگر، مقادیر ضریب تعیین پیش‌بینی‌شده (R^2_pred) نیز با مقادیر R^2_adj اختلاف قابل قبولی داشتند که نشان‌دهندهٔ توانایی مناسب مدل‌ها در پیش‌بینی داده‌های جدید است.

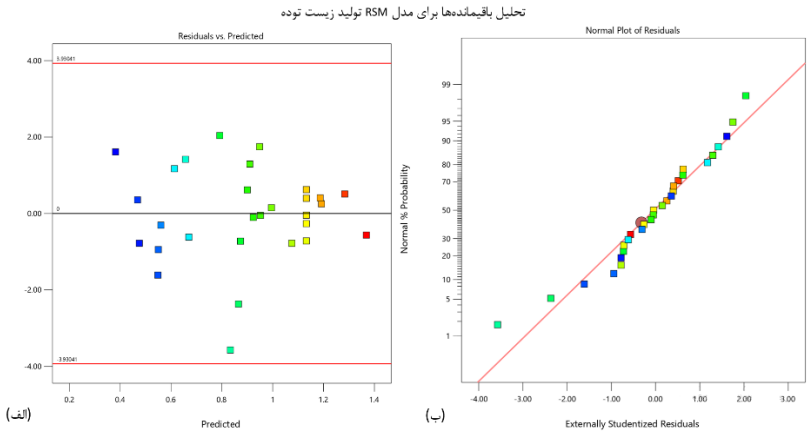
در میان پاسخ‌ها، مدل حذف TN با مقدار F برابر با ۱۰۶/۹۳ بیشترین معناداری آماری را نشان داد، در حالی که مقادیر F برای حذف TP، COD و تولید زیست‌توده به‌ترتیب ۵۴/۷۱، ۸۰/۹۴ و ۶۰/۹۸ گزارش شد که همگی بیانگر استحکام آماری مدل‌های توسعه‌یافته هستند.

علاوه بر این، مقادیر خطای ریشه میانگین مربعات (RMSE) برای تولید زیست‌توده، حذف COD، حذف TN و حذف TP به‌ترتیب برابر با ۰/۰۴۹، ۱/۵۳، ۱/۶۱ و ۲/۱۰ به دست آمد. پایین بودن مقادیر RMSE نشان‌دهندهٔ انطباق مناسب بین مقادیر پیش‌بینی‌شده توسط مدل و داده‌های تجربی است.

در مجموع، شاخص‌های آماری به‌دست‌آمده نشان می‌دهند مدل‌های توسعه‌یافته مبتنی بر روش سطح پاسخ (RSM) از دقت و قابلیت پیش‌بینی مناسبی برخوردار بوده و می‌توانند برای تحلیل اثر متغیرهای عملیاتی و همچنین، پیش‌بینی عملکرد سیستم مورد استفاده قرار گیرند.

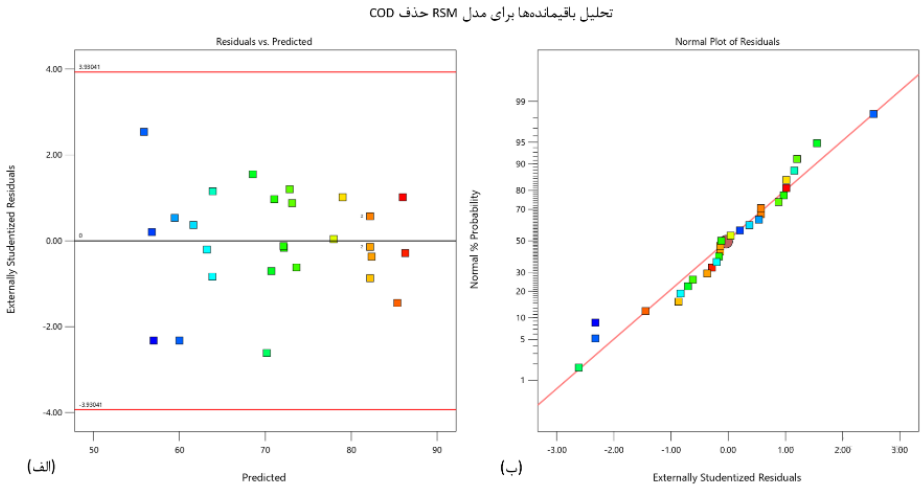
مطابق شکل ۱، پراکندگی باقی‌مانده‌ها در برابر مقادیر پیش‌بینی‌شده عمدتاً به صورت تصادفی و در اطراف خط صفر مشاهده می‌شود و روند مشخصی از قبیل انحنا یا الگوی قیفی در داده‌ها دیده نمی‌شود. این وضعیت نشان می‌دهد تغییرپذیری خطاها در

دامنهٔ پیش‌بینی‌ها نسبتاً ثابت بوده و فرض همگنی واریانس قابل قبول است. همچنین در نمودار نرمال، اغلب نقاط در نزدیکی خط مرجع قرار گرفته‌اند که بیانگر انطباق مناسب باقی‌مانده‌ها با توزیع نرمال است. در مجموع، این نمودارها کفایت آماری مدل را برای توصیف پاسخ مورد نظر تأیید می‌کنند.



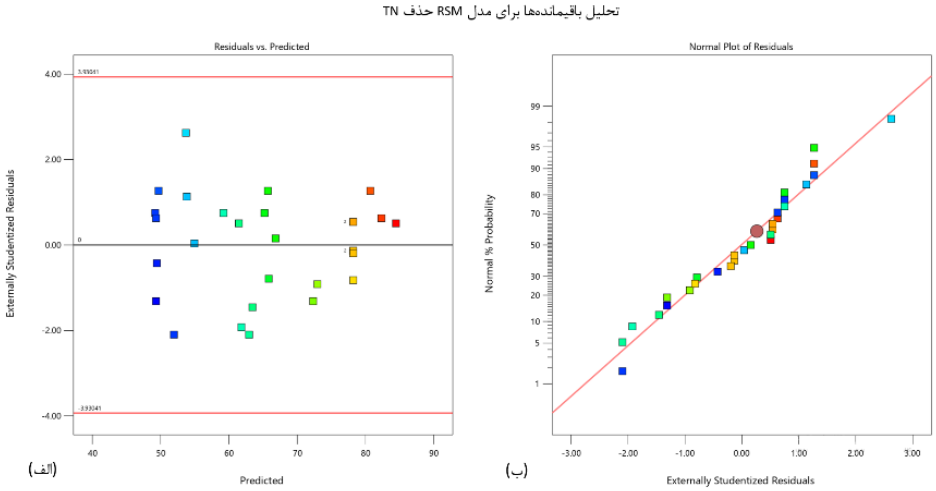
شکل ۱. پراکندگی باقی‌مانده‌ها در برابر مقادیر پیش‌بینی‌شده مدل تولید زیست‌توده

در شکل ۲، نحوهٔ توزیع باقی‌مانده‌ها نشان می‌دهد مقادیر باقی‌مانده در دو سوی صفر بدون الگوی سیستماتیک پخش شده‌اند و نشانه‌ای از افزایش یا کاهش تدریجی پراکندگی در سطوح مختلف مقادیر پیش‌بینی‌شده وجود ندارد. بنابراین، می‌توان نتیجه گرفت که فرض یکنواختی واریانس در این مدل برقرار است. از سوی دیگر، قرارگیری بیشتر نقاط نمودار احتمال نرمال بر امتداد خط مستقیم مرجع، بیانگر آن است که توزیع باقی‌مانده‌ها از نرمالیت قابل قبولی برخوردار است. بر این‌اساس، مدل توسعه‌یافته از دیدگاه تشخیصی، عملکرد رضایت‌بخشی دارد.



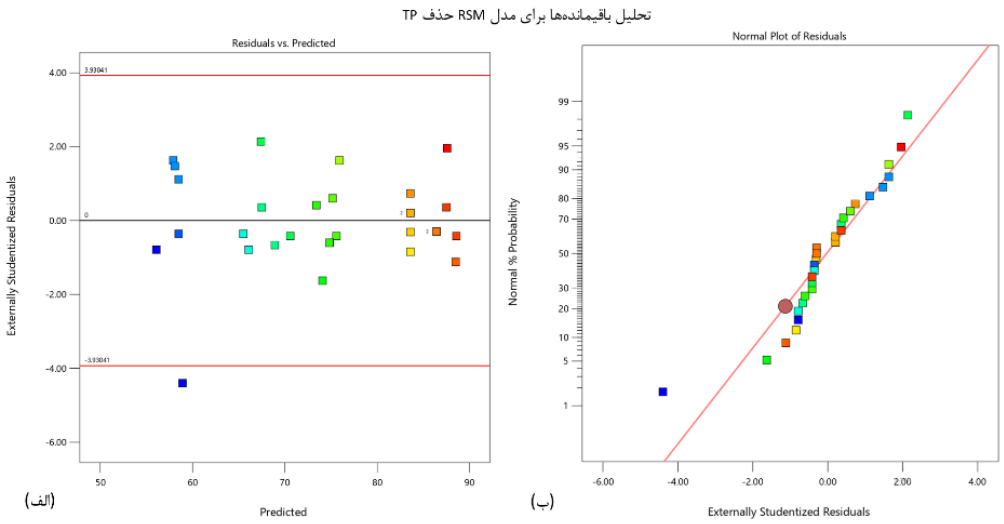
شکل ۲. پراکندگی باقی‌مانده‌ها در برابر مقادیر پیش‌بینی‌شده مدل حذف COD

بررسی شکل ۳ نشان می‌دهد باقی‌مانده‌ها در نمودار «باقی‌مانده در برابر مقدار پیش‌بینی‌شده» به صورت نامنظم اما متعادل پیرامون صفر پراکنده‌اند و الگوی خاصی که بیانگر وجود خطای ساختاری در مدل باشد مشاهده نمی‌شود. نبودِ شکل قیفی یا روند مشخص در پراکندگی نقاط، مؤید برقرار بودن فرض ثبات واریانس است. افزون بر این، در نمودار نرمال، هم‌راستایی مناسب نقاط با خط مرجع نشان می‌دهد باقی‌مانده‌ها تا حد زیادی از توزیع نرمال تبعیت می‌کنند. این شواهد بیانگر آن است که مدل برازش‌شده برای تحلیل این پاسخ از اعتبار مناسبی برخوردار است.



شکل ۳. پراکندگی باقی‌مانده‌ها در برابر مقادیر پیش‌بینی‌شده مدل حذف TN

همان‌طور که در شکل ۴ دیده می‌شود، با وجود آنکه بیشتر باقی‌مانده‌ها در اطراف صفر و بدون الگوی منظم توزیع شده‌اند، یک مشاهدهٔ دورافتاده در بخش انتهایی پایین نمودار قابل تشخیص است. با این‌حال، در کل نمودار پراکندگی، الگوی آشکاری از ناهمسانی واریانس دیده نمی‌شود و می‌توان پذیرفت که این فرض به طور نسبی برقرار است. در نمودار نرمال نیز اکثر نقاط از روند خط مرجع پیروی می‌کنند، هرچند وجود همان نقطهٔ پرت موجب انحراف جزئی در دنبالهٔ پایینی شده است. در نتیجه، با وجود این انحراف محدود، ساختار کلی باقی‌مانده‌ها همچنان نشان‌دهندهٔ قابل قبول بودن مدل است، هرچند توجه به اثر آن نقطهٔ خاص در تفسیر نتایج ضروری خواهد بود.



شکل ٤. پراکندگی باقی‌مانده‌ها در برابر مقادیر پیش‌بینی‌شده مدل حذف TP

۳-۲-۲. معادلات رگرسیونی

به منظور توصیف کمی اثر متغیرهای عملیاتی بر پاسخ‌های سیستم، مدل‌های چندجمله‌ای درجهٔ دوم بر اساس داده‌های حاصل از طراحی باکس ـ بنکن توسعه داده شدند. این معادلات رگرسیونی، رابطهٔ بین متغیرهای مستقل شامل شدت نور (A)، نرخ هوادهی (B)، زمان ماند هیدرولیکی (C) و pH (D) را با پاسخ‌های مورد بررسی شامل حذف COD، تولید زیست‌توده، حذف نیتروژن کل (TN) و حذف فسفر کل (TP) بیان می‌کنند.

مدل‌های توسعه‌یافته شامل اثرات خطی، اثرات متقابل دوگانه و جملات درجهٔ دوم هستند که امکان بررسی رفتار غیرخطی سیستم و برهم‌کنش بین عوامل مختلف را فراهم می‌کنند. وجود جملات درجهٔ دوم در معادلات نشان‌دهندهٔ آن است که پاسخ‌های سیستم تنها به‌صورت خطی به تغییرات متغیرها وابسته نبوده و برای هر پارامتر، محدودهٔ بهینه عملیاتی وجود دارد.

معادلهٔ نهایی مربوط به حذف COD به صورت معادلهٔ ۲ به دست آمد.

$$\text{COD removal} = -177.876 + 0.114315A + 14.8952B + 6.39014C + 51.4742D + 1.25414e^{-17}AB + 0.000714286AC + 0.000833333AD - 0.142857BC + 4BD + 0.142857CD - 0.00017125A^2 - 15.4\,B^2 - 0.426531C^2 - 3.65556D^2 \quad (۲)$$

نتایج این مدل نشان می‌دهد pH و زمان ماند هیدرولیکی اثر مثبت قابل توجهی بر راندمان حذف COD دارند، در حالی که ضرایب منفی جملات درجهٔ دوم بیانگر وجود رفتار غیرخطی و کاهش راندمان در مقادیر بسیار بالا یا پایین متغیرها است.

معادلهٔ رگرسیونی تولید زیست‌توده نیز به صورت معادلهٔ ۳ توسعه یافت.

$$\text{Biomass production} = -5.74501 + 0.0029686A + 0.113595B + 0.211478C + 1.36083D + 25e^{-4}AB - 6.07143e^{-5}\,AC + 5e^{-5}AD + 0.00285714BC + 0.11BD - 1.12064e^{-17}CD + -3.97292e^{-6}A^2 - 0.305667B^2 - 0.0117483C^2 - 0.0961852D^2 \quad (۳)$$

بر اساس ضرایب این مدل، افزایش شدت نور و pH تا محدودهٔ بهینه موجب افزایش تولید زیست‌توده شده است، در حالی که ضرایب منفی جملات درجهٔ دوم نشان‌دهندهٔ وجود نقطهٔ بهینه برای رشد ریزجلبک هستند.

مدل نهایی حذف نیتروژن کل (TN) به صورت معادلهٔ ۴ بیان شد.

$$\text{TN removal} = -254.238 + 0.0602381\,A + 1.39524B + 7.51854C + 71.9008D + 0.03AB - 0.000357143AC + 0.005AD - 0.142857BC + 7.66667BD + 0.190476CD - 0.000173333\,A^2 - 24.2333B^2 - 0.494558C^2 - 5.3037D^2 \quad (۴)$$

نتایج این معادله نشان می‌دهد pH و نرخ هوادهی نقش مهمی در حذف نیتروژن داشته و اثر متقابل بین هوادهی و pH نیز یکی از برهم‌کنش‌های مهم سیستم محسوب می‌شود.

همچنین، مدل حذف فسفر کل (TP) به صورت معادلهٔ ۵ به دست آمد.

$$\text{TP removal} = -197.722 + 0.029375A + 26.906B + 7.00119C + 54.1548\,D - 0.0025AB - 0.0025AC + 0.0116667AD - 0.571429BC + 4.33333BD + 0.142857CD - 0.00012625A^2 - 20.2B^2 - 0.371429\,C^2 - 3.8D^2 \quad (۵)$$

مطابق این مدل، pH و زمان ماند هیدرولیکی بیشترین اثر مثبت را بر حذف فسفر داشتند، در حالی که نرخ هوادهی در برخی محدوده‌ها اثر منفی بر عملکرد حذف TP نشان داد.

به طور کلی، معادلات رگرسیونی توسعه‌یافته توانستند روابط بین متغیرهای فرآیندی و پاسخ‌های سیستم را با دقت مناسبی توصیف کنند. این مدل‌ها علاوه بر پیش‌بینی عملکرد سیستم، ابزار مؤثری برای ترسیم نمودارهای سطح پاسخ، تحلیل برهم‌کنش متغیرها و تعیین شرایط بهینه عملیاتی فراهم می‌کنند.

۳-۳. مدل‌سازی با شبکهٔ عصبی مصنوعی (ANN)

۳-۳-۱. ساختار شبکه و فرایند آموزش

جدول ۳ خلاصهٔ مشخصات شبکه‌های عصبی بهینهٔ مورد استفاده برای مدل‌سازی پاسخ‌های مختلف را ارائه می‌دهد. در تمامی مدل‌ها همان‌طور که گفته شد از ساختار پرسپترون چندلایه پیشخور با یک لایهٔ پنهان و الگوریتم آموزش منظم‌سازی بیزین (trainbr) استفاده شد. تعداد نورون‌های بهینهٔ لایه پنهان و تعداد دوره‌های آموزش برای هر پاسخ به صورت مستقل تعیین شد، در حالی که سایر پارامترهای شبکه ثابت نگه داشته شدند. معماری نهایی هر مدل بر اساس کمترین مقدار RMSE حاصل از اعتبارسنجی متقاطع پنج‌بخشی انتخاب شد.

جدول ۳. ساختار شبکهٔ ANN

پارامتر	مدل حذف COD	مدل تولید زیست‌توده	مدل حذف TN	مدل حذف TP
نوع شبکهٔ عصبی	پرسپترون چندلایهٔ پیشخور			
تعداد نورون‌های لایهٔ ورودی	۴			
تعداد لایه‌های پنهان	۱			
بازه بررسی تعداد نورون‌های لایهٔ پنهان	۲ تا ۸ نورون			
تعداد بهینهٔ نورون‌های لایهٔ پنهان	۳ نورون	۴ نورون	۸ نورون	نورون ۴
تعداد نورون‌های لایهٔ خروجی	۱ نورون	۱ نورون	۱ نورون	۱ نورون
الگوریتم آموزش	منظم‌سازی بیزین (trainbr)			
تابع انتقال لایهٔ پنهان	تانژانت سیگموئید (tansig)			
تابع انتقال لایهٔ خروجی	خطی (purelin)			
تابع عملکرد	میانگین مربعات خطا (MSE)			
روش نرمال‌سازی داده‌ها	تابع mapminmax در بازه ۱− تا ۱+			
روش تقسیم داده‌ها	اعتبارسنجی متقاطع ۵ بخشی			
نسبت آموزش/آزمون در هر بخش	۸۰٪ آموزش و ۲۰٪ آزمون			
روش تقسیم داده در متلب	dividetrain			
حداکثر تعداد دورهٔ آموزش	۲۰۰۰			
توقف دورهٔ آموزش	۳۲۷	۱۱۴	۱۶۲	۲۷۸
هدف خطا	$۱۰^{-۸}$			
حداقل گرادیان	$۱۰^{-۱۰}$			
معیار انتخاب مدل بهینه	کمترین میانگین RMSE در داده‌های آزمون طی اعتبارسنجی متقاطع			
آموزش مدل نهایی	آموزش مجدد شبکهٔ بهینه با استفاده از کل ۲۹ داده آزمایشگاهی			

۳-۳-۲. عملکرد مدل‌های شبکهٔ عصبی مصنوعی

به منظور ارزیابی عملکرد مدل‌های شبکهٔ عصبی مصنوعی، شاخص‌های ضریب تعیین (R^2)، ریشهٔ میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) بر اساس نتایج اعتبارسنجی متقاطع پنج‌بخشی محاسبه شدند. نتایج ارائه‌شده در جدول ۴ نشان می‌دهد مدل‌های توسعه‌یافته توانایی مناسبی در پیش‌بینی پاسخ‌های مختلف سیستم دارند. در میان پاسخ‌های مورد بررسی، مدل پیش‌بینی حذف TP با ضریب تعیین ۰/۷۷۰۵ بالاترین دقت را نشان داد، در حالی که مدل پیش‌بینی حذف TN با ضریب تعیین ۰/۶۸۹۲ کمترین عملکرد را در بین مدل‌ها داشت. همچنین، مدل‌های پیش‌بینی حذف COD و تولید زیست‌توده به‌ترتیب با مقادیر R^2 برابر با ۰/۷۵۷۶ و ۰/۷۲۱۴ عملکرد قابل قبولی در پیش‌بینی داده‌های آزمایشگاهی ارائه کردند. با توجه به محدود بودن تعداد داده‌های تجربی (۲۹ نمونه) و استفاده از اعتبارسنجی متقاطع، نتایج به‌دست‌آمده بیانگر توانایی مناسب مدل‌های ANN در یادگیری روابط غیرخطی و تعمیم به داده‌های جدید است.

جدول ٤. ارزیابی عملکرد مدل‌های شبکهٔ عصبی مصنوعی

مدل	ضریب تعیین (R^2)	خطای ریشهٔ میانگین مربعات (RMSE)	میانگین قدر مطلق خطا (MAE)
تولید زیست‌توده	۰.۷۲۱۴	۰.۱۸۲۰	۰.۱۴۰۷
میزان حذف COD	۰.۷۵۷۶	۵.۷۵۶۴	۴.۸۶۷۸
میزان حذف TN	۰.۶۸۹۲	۷.۸۱۹۴	۶.۵۲۹۲
میزان حذف TP	۰.۷۷۰۵	۵.۸۰۹۳	۴.۳۴۶۲

۳-۴. اعتبارسنجی تجربی مدل‌های RSM و ANN

به منظور ارزیابی قابلیت پیش‌بینی و تعمیم مدل‌های توسعه‌یافته، چهار نقطهٔ عملیاتی شامل نقطهٔ بهینه حاصل از روش RSM و سه نقطهٔ اعتبارسنجی مستقل که در مجموعه داده‌های اولیه طراحی آزمایش حضور نداشتند، انتخاب شدند. سپس مقادیر پاسخ

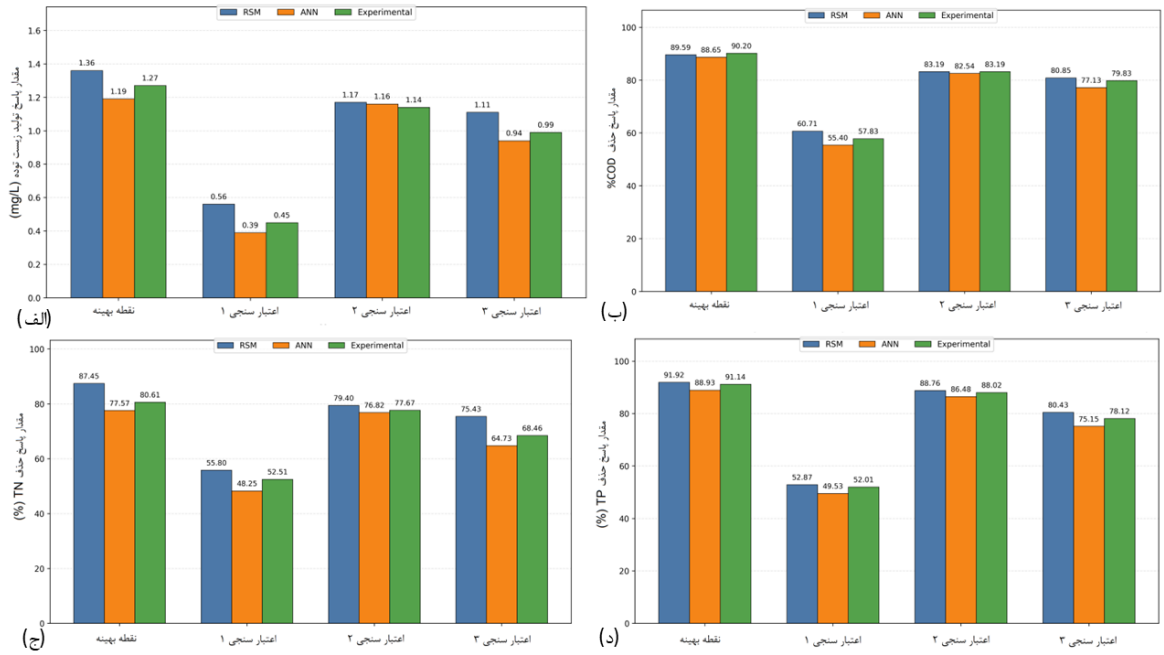
شامل راندمان حذف COD، غلظت زیست‌توده، راندمان حذف نیتروژن کل (TN) و راندمان حذف فسفر کل (TP) توسط مدل‌های RSM و ANN پیش‌بینی و با نتایج آزمایشگاهی مقایسه شدند. نتایج این مقایسه در جدول ۵ ارائه شده است.

جدول ۵. مقایسهٔ مقادیر پیش‌بینی‌شده توسط مدل‌های RSM و ANN با نتایج آزمایشگاهی در نقطهٔ بهینه و نقاط اعتبارسنجی مستقل

نقطه	روش پاسخ	شدت نور $\mu molphotons.m^{-2}.s^{-1}$	نرخ هوادهی $mg.L^{-1}$	زمان ماند روز	pH	حذف COD	غلظت بیومس $mg.L^{-1}$	حذف نیتروژن (TN)	حذف فسفات (TP)
بهینه	RSM	۳۵۲.۵	۱.۲۹	۷.۹۵	۷.۷۹	٪ ۸۹.۵۹	۱.۳۶ $mg.L^{-1}$	٪ ۸۷.۴۵	٪ ۹۱.۹۲
	ANN					٪ ۸۸.۶۵	۱.۱۹ $mg.L^{-1}$	٪ ۷۷.۵۷	٪ ۸۸.۹۳
	آزمون تجربی					٪ ۹۰.۲	۱.۲۷ $mg.L^{-1}$	٪ ۸۰.۶۱	٪ ۹۱.۱۴
اعتبارسنجی ۱	RSM	۹۵.۰۰	۰.۷۲	۴.۰۱	۶.۵۵	٪ ۶۰.۷۱	۰.۵۶ $mg.L^{-1}$	٪ ۵۵.۸۰	٪ ۵۲.۸۷
	ANN					٪ ۵۵.۴۰	۰.۳۹ $mg.L^{-1}$	٪ ۴۸.۲۵	٪ ۴۹.۵۳
	آزمون تجربی					٪۵۷.۸۳	۰.۴۵ $mg.L^{-1}$	٪ ۵۲.۵۱	٪ ۵۲.۰۱
اعتبارسنجی ۲	RSM	۱۸۵.۰۰	۱.۳۸	۸.۸۵	۸.۶۰	٪ ۸۳.۱۹	۱.۱۷ $mg.L^{-1}$	٪ ۷۹.۴۰	٪ ۸۸.۷۶
	ANN					٪ ۸۲.۵۴	۱.۱۶ $mg.L^{-1}$	٪ ۷۶.۸۲	٪ ۸۶.۴۸
	آزمون تجربی					٪ ۸۳.۱۹	۱.۱۴ $mg.L^{-1}$	٪ ۷۷.۶۷	٪ ۸۸.۰۲
اعتبارسنجی ۳	RSM	۳۲۵.۰۰	۰.۸۸	۶.۲۰	۷.۱۵	٪ ۸۰.۸۵	۱.۱۱ $mg.L^{-1}$	٪ ۷۵.۴۳	٪ ۸۰.۴۳
	ANN					٪ ۷۷.۱۳	۰.۹۴ $mg.L^{-1}$	٪ ۶۴.۷۳	٪ ۷۵.۱۵
	آزمون تجربی					٪ ۷۹.۸۳	۰.۹۹ $mg.L^{-1}$	٪ ۶۸.۴۶	٪ ۷۸.۱۲

همان‌گونه که در جدول ۵ مشاهده می‌شود، هر دو مدل RSM و ANN توانایی مناسبی در پیش‌بینی پاسخ‌های سیستم در شرایط عملیاتی جدید داشتند. در نقطهٔ بهینه، مقادیر پیش‌بینی‌شده توسط هر دو مدل اختلاف اندکی با نتایج آزمایشگاهی داشتند؛ به طوری که برای راندمان حذف COD، مقادیر پیش‌بینی‌شده توسط RSM و ANN به‌ترتیب برابر با ۸۹/۵۹ و ۸۸/۶۵ درصد بود، در حالی که مقدار تجربی ۹۰/۲۰ درصد به دست آمد. روند مشابهی برای تولید زیست‌توده و حذف TP نیز مشاهده شد. با این‌حال، در پیش‌بینی حذف TN، مدل RSM در مجموع مقادیر نزدیک‌تری به نتایج تجربی نسبت به مدل ANN ارائه کرد.

شکل ۵ مقایسهٔ مقادیر پیش‌بینی‌شده توسط مدل‌های RSM و ANN با نتایج تجربی را در نقطهٔ بهینه و نقاط اعتبارسنجی مستقل نشان می‌دهد. همان‌گونه که مشاهده می‌شود، هر دو مدل توانایی مناسبی در پیش‌بینی پاسخ‌های سیستم داشتند، اما در اغلب موارد، مقادیر پیش‌بینی‌شده توسط مدل RSM به نتایج تجربی نزدیک‌تر بودند.



شکل ۵. مقایسهٔ نتایج پیش‌بینی‌شده مدل با نتایج آزمون تجربی برای الف) تولید زیست‌توده، ب) حذف COD، ج) حذف TN و د) حذف TP

به طور کلی، نتایج اعتبارسنجی نشان داد هر دو مدل از قابلیت پیش‌بینی مناسبی در شرایطی خارج از مجموعه داده‌های آموزشی برخوردار هستند. با این‌وجود، مدل RSM در اغلب نقاط اعتبارسنجی، به‌ویژه برای پیش‌بینی حذف TN و TP، انطباق بیشتری با نتایج آزمایشگاهی نشان داد، در حالی که مدل ANN نیز با وجود استفاده از اعتبارسنجی متقاطع و مجموعه داده محدود، توانست پیش‌بینی‌هایی با دقت قابل قبول ارائه دهد.

۴. بحث

۴–۱. اثر متغیرهای عملیاتی بر عملکرد سیستم

عملکرد سیستم تصفیهٔ مبتنی بر ریزجلبک *Desmodesmus sp.* به طور معناداری تحت تأثیر متغیرهای عملیاتی شامل شدت نور (A)، نرخ هوادهی (B)، زمان ماند هیدرولیکی (C) و pH (D) قرار گرفت. نتایج مدل‌های رگرسیونی درجهٔ دوم حاصل از تحلیل سطح پاسخ (RSM) نشان داد این پارامترها علاوه بر اثرات مستقل، دارای اثرات متقابل قابل توجهی نیز هستند که رفتار غیرخطی سیستم را کنترل می‌کنند. چنین تعاملاتی در سیستم‌های تصفیهٔ مبتنی بر ریزجلبک امری رایج است، زیرا این فرایندها تحت تأثیر همزمان عوامل بیولوژیکی، انتقال جرم و شرایط فیزیکوشیمیایی قرار دارند.

نتایج تحلیل سطح پاسخ نشان داد عملکرد سیستم در واقع حاصل برهم‌کنش پیچیده میان دسترسی به نور، تأمین کربن معدنی، شرایط محیطی و زمان تماس بین ریزجلبک‌ها و آلاینده‌ها است. بررسی هم‌زمان این عوامل امکان درک بهتر رفتار سیستم و تعیین شرایط عملیاتی بهینه برای کاربردهای تصفیهٔ پساب را فراهم می‌کند.

۴–۱–۱. اثر شدت نور

شدت نور یکی از عوامل مهم کنترل‌کنندهٔ رشد ریزجلبک‌ها و عملکرد سیستم‌های فتوبیولوژیکی است، زیرا انرژی مورد نیاز برای انجام فتوسنتز و تثبیت کربن را فراهم می‌کند. در پژوهش حاضر، افزایش شدت نور در محدودهٔ مورد بررسی موجب افزایش تولید زیست‌توده و بهبود راندمان حذف COD شد که نشان‌دهندهٔ افزایش فعالیت فتوسنتزی و جذب مواد مغذی توسط *Desmodesmus sp.* است. با این‌حال، نتایج مدل RSM نشان داد این رابطه کاملاً خطی نبوده و در شدت‌های بالاتر، روند افزایش عملکرد کاهش یافته است که می‌تواند ناشی از بروز پدیدهٔ فوتوهیبیشن باشد.

این یافته با نتایج مطالعات متعددی همخوانی دارد. وانگ و همکاران [۱۳] گزارش کردند که افزایش شدت نور تا یک محدودهٔ بهینه باعث افزایش رشد *Desmodesmus sp.* و راندمان حذف نیتروژن و فسفر می‌شود، اما در شدت‌های بالاتر، به دلیل آسیب به فتوسیستم II، کارایی فتوسنتز کاهش می‌یابد. همچنین، چنگ و همکاران [۱۴] افزایش حذف COD و تولید زیست‌توده را بر اثر افزایش شدت نور در سامانه‌های ریزجلبکی گزارش کردند. از سوی دیگر، برخی پژوهش‌ها [۱۵] شدت نور بهینهٔ متفاوتی را گزارش کرده‌اند که این اختلاف را می‌توان به تفاوت گونه ریزجلبک، نوع پساب، عمق راکتور، مسیر انتقال نور و چگالی سلولی نسبت داد. بنابراین، تعیین شدت نور بهینهٔ متناسب با شرایط هر سامانه برای دستیابی به بیشترین راندمان ضروری است [۱۶].

۴-۱-۲. اثر نرخ هوادهی

در این مطالعه، افزایش نرخ هوادهی موجب بهبود رشد ریزجلبک و افزایش راندمان حذف آلاینده‌ها شد که این موضوع به تأمین مناسب دی‌اکسیدکربن، افزایش انتقال جرم و جلوگیری از ته‌نشینی سلول‌ها نسبت داده می‌شود. همچنین، اختلاط بهتر محیط موجب قرار گرفتن متناوب سلول‌ها در معرض نواحی روشن و تاریک شده و در نتیجه، بازده فتوسنتز را افزایش می‌دهد. با این‌وجود، افزایش بیش از حد هوادهی می‌تواند به دلیل ایجاد تنش برشی و کاهش زمان تماس حباب‌ها با محیط مایع، اثر معکوس داشته باشد.

این نتایج با یافته‌های بداوی و همکاران [۱۷] و لی و همکاران [۱۸] مطابقت دارد که گزارش کردند افزایش هوادهی تا یک مقدار بهینه باعث افزایش تولید زیست‌توده و حذف COD، TN و TP می‌شود، اما هوادهی بیش از حد موجب کاهش بازده به دلیل آسیب مکانیکی به سلول‌ها و کاهش راندمان انتقال CO_2 خواهد شد. اختلاف میان مقدار بهینهٔ گزارش‌شده در مطالعات مختلف احتمالاً ناشی از تفاوت در طراحی فتوبیوراکتور، اندازهٔ حباب‌ها و ویژگی‌های هیدرودینامیکی سامانه است [۱۹].

۴-۱-۳. اثر زمان ماند هیدرولیکی

نتایج پژوهش حاضر نشان داد افزایش زمان ماند هیدرولیکی موجب افزایش حذف نیتروژن، فسفر و تولید زیست‌توده شد، زیرا فرصت بیشتری برای جذب مواد مغذی و انجام فرایندهای متابولیکی در اختیار سلول‌های ریزجلبک قرار می‌دهد. این نتیجه با مطالعات اشادولا و همکاران [۲۰] همخوانی دارد که افزایش HRT را عامل افزایش حذف مواد مغذی و رشد ریزجلبک معرفی کردند. با این‌حال، برخی پژوهش‌ها نشان داده‌اند افزایش بیش از حد HRT اگرچه راندمان حذف را افزایش می‌دهد، اما ظرفیت تصفیه و بهره‌وری حجمی سامانه را کاهش می‌دهد. بنابراین، انتخاب زمان ماند مناسب باید علاوه بر راندمان حذف، بر اساس ملاحظات اقتصادی و ظرفیت عملیاتی نیز انجام شود [۲۱].

۴-۱-۴. اثر pH

در این مطالعه، بیشترین راندمان حذف آلاینده‌ها و تولید زیست‌توده در محدودهٔ pH نزدیک به خنثی تا کمی قلیایی مشاهده شد. pH از طریق تأثیر بر فعالیت آنزیم‌ها، شکل شیمیایی کربن معدنی و قابلیت جذب مواد مغذی، نقش تعیین‌کننده‌ای در رشد ریزجلبک ایفا می‌کند. در pHهای پایین، تنش اسیدی و در pHهای بالا کاهش دسترسی زیستی CO_2 و تغییر شکل فسفر، موجب افت عملکرد سیستم می‌شود.

نتایج حاضر با یافته‌های کیان و همکاران [۲۲] مطابقت دارد که محدودهٔ pH بین ۷ تا ۸ را مناسب‌ترین شرایط برای رشد *Desmodesmus sp.* و حذف هم‌زمان COD، نیتروژن و فسفر معرفی کردند. با این‌حال، در برخی مطالعات مقدار بهینهٔ pH اندکی متفاوت گزارش شده که این اختلاف احتمالاً ناشی از تفاوت گونهٔ ریزجلبک، نوع پساب، غلظت کربن معدنی و شرایط بهره‌برداری است [۲۳].

۴-۲. تحلیل اثر نسبی هم‌زمان متغیرها بر اساس دامنهٔ عملیاتی واقعی

تحلیل معادلات رگرسیونی نشان داد تمامی متغیرهای عملیاتی اثر معناداری بر عملکرد سیستم تصفیهٔ ریزجلبکی دارند، اما شدت

و نحوهٔ اثرگذاری آن‌ها متفاوت است. به منظور مقایسهٔ واقع‌بینانه میزان اثرگذاری متغیرهای عملیاتی بر پاسخ‌های سیستم، تنها اتکا به ضرایب خطی معادلات رگرسیونی کافی نیست؛ زیرا هر متغیر در دامنهٔ عملیاتی متفاوتی تغییر می‌کند. در مدل‌های سطح پاسخ، ضرایب خطی (β_i) بیانگر میزان تغییر پاسخ به ازای یک واحد تغییر در متغیر هستند. با این‌حال، زمانی که مقیاس و دامنهٔ تغییر متغیرها با یکدیگر تفاوت چشمگیری داشته باشد، مقایسهٔ مستقیم این ضرایب خام می‌تواند به برداشت نادرست از اهمیت نسبی عوامل منجر شود. به عنوان مثال، اگرچه ضریب یک متغیر ممکن است در معادله کوچک باشد، اما در صورتی که دامنهٔ تغییر آن در آزمایش‌ها بزرگ باشد، اثر واقعی آن بر پاسخ کل فرایند می‌تواند بسیار قابل توجه باشد.

به همین‌دلیل، برای ارزیابی اثر عملی هر متغیر در محدودهٔ واقعی آزمایش‌ها، تغییر تقریبی پاسخ ناشی از تغییر کامل آن متغیر در دامنهٔ عملیاتی محاسبه شد. این مقدار از حاصل‌ضرب ضریب خطی متغیر در دامنه تغییر آن طبق معادلهٔ ۶ به دست آمد.

$$\Delta Y_i \approx \beta_i \left(X_{\max} - X_{\min} \right) \quad (۶)$$

که در آن ΔY_i تغییر تقریبی پاسخ ناشی از متغیر i ، β_i ضریب خطی آن متغیر در مدل رگرسیونی، و $\left(X_{\max} X_{\min} \right)$ دامنهٔ واقعی تغییر آن متغیر در طراحی آزمایش است.

بر اساس شرایط آزمایش، دامنهٔ تغییر متغیرها به‌ترتیب برابر با ۴۰۰ واحد برای شدت نور (۵۰ تا ۴۵۰ $\mu molphotons.m^{-2}.s^{-1}$)، یک واحد برای نرخ هوادهی (۰/۵ تا ۱/۵ $L.min^{-1}$)، هفت روز برای زمان ماند هیدرولیکی (۳ تا ۱۰ days) و سه واحد برای pH (۶ تا ۹) است.

سپس اثر تقریبی هر متغیر با ضرب ضریب خطی در دامنهٔ مربوطه محاسبه شد و نتایج آن در جدول ۶ گزارش شد. این رویکرد امکان مقایسهٔ اثر واقعی متغیرها را در محدودهٔ عملیاتی سیستم فراهم می‌کند. در مدل حذف COD، ضریب خطی شدت نور برابر با ۰/۰۱۰۱۴ بود که ضرب آن در دامنهٔ ۴۰۰ واحدی، اثر عملی تقریبی ۴/۰۶+ را نشان می‌دهد. در مقابل، ضریب خطی pH برابر با ۱۷/۴۷+ بود که با ضرب در دامنهٔ ۳ واحدی آن، اثر عملی معادل ۵۲/۴۱+ را تولید می‌کند. این تحلیل نشان می‌دهد اهمیت نسبی عوامل باید بر اساس ترکیب ضریب مدل و دامنهٔ تغییر آن‌ها تفسیر شود، نه فقط بر اساس مقدار ضریب خام در معادلهٔ رگرسیون.

همان‌طور که نتایج جدول ۶ نشان می‌دهد، pH (فاکتور D) مهم‌ترین و تأثیرگذارترین عامل بر تمامی پاسخ‌های سیستم است و بیشترین اثر عملی را بر حذف COD، حذف TN، حذف TP و تولید زیست‌توده دارد. نقش غالب pH را می‌توان به تأثیر مستقیم آن بر فعالیت آنزیمی، انتقال مواد مغذی از دیوارهٔ سلولی، تغییر تعادل شیمیایی گونه‌های محلول نیتروژن و فسفر و همچنین کارایی فتوسنتزی ریزجلبک‌ها نسبت داد. علاوه بر این، pH در بسیاری از برهم‌کنش‌های دوگانه حضور مؤثر دارد که نشان‌دهندهٔ نقش تنظیم‌کنندهٔ مرکزی این متغیر در کل سامانه است. این نتیجه همسو با نتایج گزارش‌شده توسط یو و همکاران [۲۴] است.

همسو با گزارش وانگ و همکاران [۱۳] نور و زمان ماند بعد از pH بیشترین اهمیت را داشتند. زمان ماند هیدرولیکی (فاکتور C) اثر مثبت و پایداری بر تمامی پاسخ‌ها نشان داد. افزایش HRT موجب افزایش زمان تماس بین ریزجلبک و آلاینده‌ها شده و فرصت بیشتری برای جذب مواد مغذی، تثبیت زیستی و رشد سلولی فراهم می‌کند. اثر این متغیر به‌ویژه در حذف TN و TP برجسته است که بیانگر وابستگی فرایندهای حذف زیستی مواد مغذی به زمان کافی برای متابولیسم سلولی است [۲۵].

اگرچه ضرایب خام شدت نور (فاکتور A) در معادلات ریاضی نسبتاً کوچک بودند، اما به دلیل دامنهٔ عملیاتی وسیع آن (۵۰ تا ۴۵۰)، اثر واقعی و عملیاتی آن بر پاسخ‌ها پس از اعمال معادلهٔ ۶ بسیار چشمگیر ارزیابی شد، زیرا نور نقش اساسی و اصلی در تأمین انرژی فتوسنتزی، تولید ATP و تنظیم مسیرهای متابولیکی ریزجلبک‌ها دارد [۲۶].

نرخ هوادهی (فاکتور B) نیز اثر مثبتی بر حذف COD، حذف TN و تولید زیست‌توده داشت، زیرا موجب بهبود اختلاط، افزایش انتقال جرم و تأمین CO_2 مورد نیاز فتوسنتز می‌شود. با این‌حال، اثر مستقیم آن بر حذف TP منفی ارزیابی شد (جدول ۶). این رفتار احتمالاً ناشی از آشفتگی هیدرودینامیکی شدید در دبی‌های بالا، کاهش زمان تماس مؤثر فسفر با سطح سلول و یا تغییر تعادل شیمیایی رسوب‌دهی فسفات در نرخ‌های بالای هوادهی است [۲۷].

تحلیل هم‌زمان اثرات متقابل نشان داد تعامل بین هوادهی و pH مؤثرترین اثر هم‌افزایی را در اغلب پاسخ‌ها ایجاد کرده است. این نتیجه نشان می‌دهد کارایی هوادهی به‌شدت وابسته به شرایط pH بوده و انتقال جرم و جذب مواد مغذی تنها در محدودهٔ مناسب pH به حداکثر می‌رسد. از سوی دیگر، منفی بودن اکثر ضرایب درجهٔ دوم در مدل‌های نهایی، نشان‌دهندهٔ وجود رفتار غیرخطی و یک نقطهٔ بهینهٔ مشخص برای متغیرها است؛ به طوری که افزایش بیش‌ازحد متغیرهای عملیاتی، از یک آستانهٔ مشخص به بعد، به تنش فیزیولوژیکی، پدیدهٔ اشباع نوری یا اختلال در انتقال جرم منجر می‌شود و در نهایت راندمان سیستم را کاهش می‌دهد.

برای درک بهتر رفتار سیستم در اطراف شرایط طراحی و ارزیابی حساسیت محلی پاسخ‌ها، نمودارهای تحلیل اختلال[1] (شکل ۶) تهیه شدند. این نمودارها چگونگی تغییر هر پاسخ را هنگام انحراف یک متغیر از نقطه مرجع (در حالی که سایر متغیرها در مقدار مرکزی خود ثابت نگه داشته شده‌اند) نشان می‌دهند.

نمودار الف شکل ۶ نشان‌دهندهٔ حساسیت بالای این پاسخ به انحرافات متغیرها از نقطه مرکز است. عوامل A (شدت نور) و B (نرخ هوادهی) روندی افزایشی دارند، در حالی که عامل C (زمان ماند) شیب ملایم‌تری دارد. عامل D (pH) رفتاری کاملاً سهموی نشان می‌دهد پس از نقطهٔ مرجع دچار افت می‌شود. این انحنای شدید فاکتور D با اثر عملی قالب آن در جدول ۶ همخوانی دارد.

در اطراف نقطهٔ مرجع شکل ۶ (ب)، انحراف فاکتورهای A، B و C اثرات مثبت و صعودی ملایمی را نشان می‌دهند. با این حال، فاکتور D (pH) حساسیت غیرخطی شدیدتری دارد و پس از عبور از نقطهٔ مرجع (۰/۲۵+ کدگذاری‌شده)، روند نزولی به خود می‌گیرد که نشان‌دهندهٔ لزوم کنترل دقیق pH برای جلوگیری از افت راندمان حذف کربن آلی است.

در شکل ۶ (ج)، فاکتور D بیشترین شیب و انحراف را در نمودار تحلیل اختلال به خود اختصاص داده است. روند صعودی متغیرهای A، B و C در کل بازه حفظ می‌شود، اما افزایش فاکتور D به بیش از نقطهٔ مرجع، به سقوط شدید نمودار حذف نیتروژن کل منجر می‌شود که با اهمیت بسیار بالای آن در رتبه‌بندی جدول ۶ تطابق کامل دارد.

روند تغییرات در شکل ۶ (د) نشان می‌دهد حذف فسفر کل بیشترین حساسیت محلی را به متغیر D دارد. در حالی که فاکتور B (نرخ هوادهی) روند نزولی ملایمی را در اطراف نقطه مرجع نشان می‌دهد (که مؤید اثر عملی منفی آن در جدول ۶ است)، فاکتور D دارای شدیدترین رفتار غیرخطی و انحنا است.

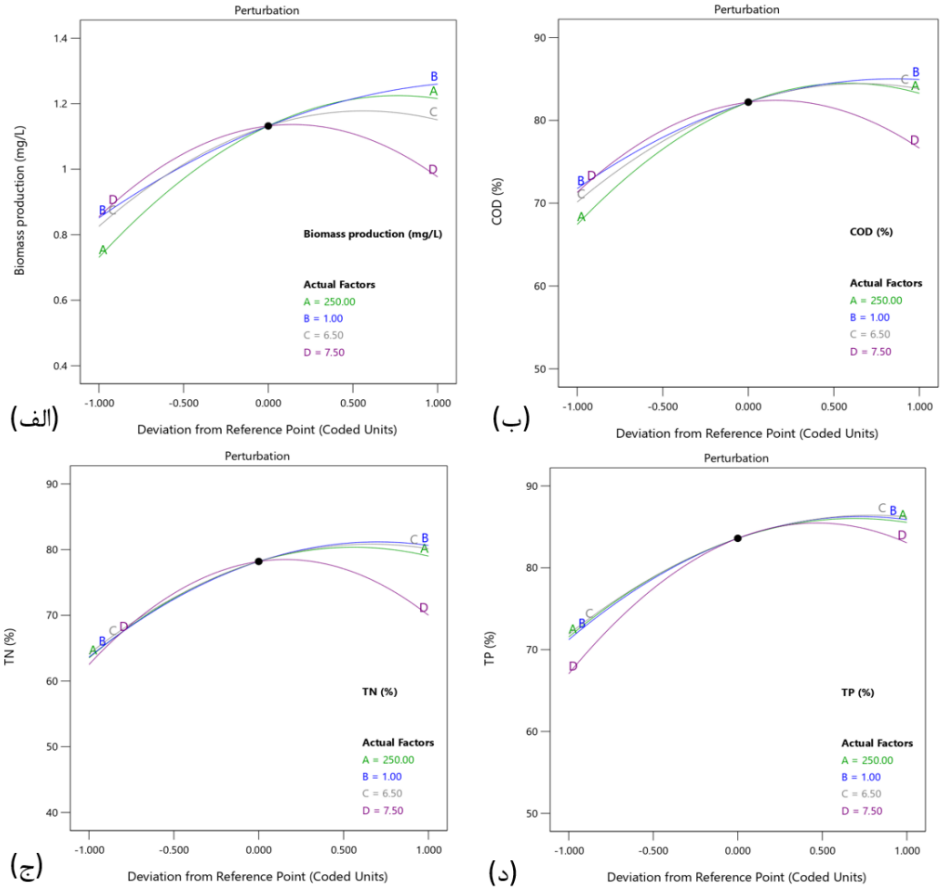
در نهایت، تطابق بسیار خوبی میان تحلیل محلی نمودارهای تحلیل اختلال و ارزیابی جامع اثر عملی (جدول ۶) مشاهده می‌شود. هر دو ابزار تأیید می‌کنند که pH (فاکتور D) و زمان ماند (فاکتور C) نقش‌های کلیدی و تعیین‌کننده را در تصفیهٔ ریزجلبکی ایفا می‌کنند، در حالی که فاکتورهای شدت نور و هوادهی باید در محدوده‌های بهینه و کنترل‌شده تنظیم شوند تا از بروز اثرات بازدارنده ثانویه جلوگیری شود.

۴-۳. عملکرد مدل RSM در برابر مدل ANN

به منظور ارزیابی قابلیت پیش‌بینی مدل‌های توسعه‌یافته، مقادیر پیش‌بینی‌شده توسط مدل‌های RSM و ANN با نتایج تجربی حاصل از نقطهٔ بهینه و سه نقطهٔ اعتبارسنجی مستقل مقایسه شدند. نتایج (جدول ۵) نشان داد هر دو مدل توانایی مناسبی در پیش‌بینی پاسخ‌های سیستم دارند، با این‌حال در اکثر شرایط بررسی‌شده، مقادیر پیش‌بینی‌شده توسط مدل RSM به نتایج تجربی نزدیک‌تر بودند. این موضوع به‌ویژه در پیش‌بینی حذف COD، حذف فسفر کل و تولید زیست‌توده در نقطهٔ بهینه و دو نقطهٔ اعتبارسنجی دیگر مشاهده شد.

عملکرد بهتر مدل RSM در این مطالعه را می‌توان به تعداد محدود داده‌های آزمایشگاهی نسبت داد. روش سطح پاسخ بر پایهٔ برازش یک مدل درجهٔ دوم روی داده‌های طراحی‌شده با طرح باکس ـ بنکن توسعه می‌یابد و در مجموعه داده‌های کوچک معمولاً پایداری بیشتری نسبت به شبکه‌های عصبی مصنوعی دارد. در مقابل، شبکه‌های عصبی برای یادگیری روابط پیچیدهٔ غیرخطی به داده‌های آموزشی بیشتری نیاز دارند و در مجموعه داده‌های کوچک ممکن است قابلیت تعمیم آن‌ها کاهش یابد.

1. Perturbation



شکل ٦. نمودارهای تحلیل اختلال الف) تولید زیست‌توده، ب) حذف COD، ج) حذف TN و د) حذف TP

جدول ٦. میزان قدرت متغیرها بر اساس دامنهٔ عملیاتی واقعی

مدل	شدت نور (فاکتور A)	نرخ هوادهی (فاکتور B)	زمان ماند (فاکتور C)	میزان pH (فاکتور D)	رتبه‌بندی تأثیر پارامتر
تولید زیست‌توده	+۴۷.۱۱	+۱۶.۲۳	+۱۵۷.۷۶	+۴۵.۴۲	C >> A ≈ D > B
میزان حذف COD	+۱.۰۴	+۰.۱۲	+۴.۰۶	+۱.۳۵	C > D ≈ A > B
میزان حذف TN	+۳۲.۶۳	+۱۵.۹۸	+۲۰۹.۵۴	+۵۱.۹۱	C >> D > A > B
میزان حذف TP	+۱۴.۰۴	−۹.۷۶	+۱۳۱.۳۰	+۵۲.۴۱	C > D > A > B

اگرچه مقادیر ضریب تعیین حاصل از اعتبارسنجی متقاطع برای مدل ANN در محدودهٔ ۰/۶۹ تا ۰/۷۷ قرار گرفت، این مدل توانست روند کلی تغییرات هر چهار پاسخ را به‌خوبی بازسازی کند. همچنین، اختلاف پیش‌بینی‌های ANN با داده‌های تجربی در اغلب نقاط اعتبارسنجی محدود بود که نشان می‌دهد شبکهٔ عصبی قادر به استخراج بخش قابل توجهی از روابط غیرخطی موجود در سامانه است، هرچند برای دستیابی به دقت بیشتر به مجموعه داده‌های آموزشی بزرگ‌تری نیاز خواهد بود.

مطالعات متعددی نیز نشان داده‌اند در مجموعه داده‌های محدود، مدل‌های RSM معمولاً عملکردی مشابه یا حتی بهتر از شبکه‌های عصبی دارند، در حالی که با افزایش حجم داده‌ها، برتری ANN آشکارتر می‌شود. این موضوع توسط حمودا و همکاران [۵] در کاربردهای RSM و همچنین نصیر و همکاران [۲۸] در مقایسهٔ RSM و ANN در فرایندهای زیستی گزارش شده است. بنابراین نتایج پژوهش حاضر نیز با این روند کلی همخوانی دارد.

در مجموع، نتایج این پژوهش نشان می‌دهد RSM به دلیل قابلیت تفسیر ضرایب مدل، امکان تحلیل اثر متغیرها و دقت مناسب در مجموعه داده‌های کوچک، ابزار مناسبی برای بهینه‌سازی شرایط عملیاتی این سامانه محسوب می‌شود. در مقابل،

ANN با وجود دقت نسبتاً پایین‌تر در این مطالعه، ظرفیت بالایی برای مدل‌سازی روابط غیرخطی پیچیده دارد و انتظار می‌رود با افزایش تعداد داده‌های آموزشی و توسعهٔ ساختار شبکه، عملکرد پیش‌بینی آن بهبود یابد.

۵. نتیجه‌گیری

در این پژوهش، عملکرد سامانهٔ ریزجلبکی *Desmodesmus sp.* در تصفیهٔ پساب سنتتیک شهری با تمرکز بر حذف COD، نیتروژن کل (TN)، فسفر کل (TP) و تولید زیست‌توده مورد بررسی قرار گرفت. به منظور ارزیابی و بهینه‌سازی عملکرد سامانه، اثر چهار پارامتر عملیاتی شامل شدت نور، نرخ هوادهی، pH و زمان ماند هیدرولیکی با استفاده از طراحی آزمایش باکس ـ بنکن و روش سطح پاسخ (RSM) مدل‌سازی شد و سپس، نتایج با مدل شبکهٔ عصبی مصنوعی (ANN) مقایسه شد. ترکیب این دو رویکرد امکان بررسی هم‌زمان روابط آماری، اثرات متقابل عوامل و قابلیت پیش‌بینی رفتار سیستم را فراهم ساخت.

نتایج نشان داد مدل‌های درجهٔ دوم حاصل از RSM برای هر چهار پاسخ از برازش مناسبی برخوردار بودند و آزمون تحلیل واریانس، معناداری آماری مدل‌ها را تأیید کرد. همچنین، تحلیل ضرایب مدل، نمودارهای پاسخ سطحی و نمودارهای تحلیل اختلال نشان دادند pH و زمان ماند هیدرولیکی مهم‌ترین عوامل کنترل‌کنندهٔ عملکرد سامانه هستند، در حالی که شدت نور و نرخ هوادهی نیز نقش مؤثری در بهبود حذف آلاینده‌ها و رشد ریزجلبک ایفا می‌کنند. تحلیل اثر نسبی متغیرها بر اساس دامنهٔ عملیاتی واقعی نیز این موضوع را تأیید کرد و نشان داد فقط مقایسهٔ ضرایب رگرسیونی برای تعیین اهمیت عوامل کافی نیست و دامنهٔ تغییر هر متغیر باید در تفسیر نتایج لحاظ شود.

بهینه‌سازی هم‌زمان پاسخ‌ها با استفاده از تابع مطلوبیت شرایط عملیاتی بهینه را شامل شدت نور حدود ۳۵۲/۵ $\mu mol\ photons.m^{-2}.s^{-1}$، نرخ هوادهی حدود ۱/۲۹ $L.min^{-1}$، زمان ماند هیدرولیکی حدود ۷/۹۵ روز و pH برابر با ۷/۷۹ معرفی کرد. در این شرایط، مدل RSM راندمان حذف COD، حذف TN، حذف TP و غلظت زیست‌توده را با دقت مناسبی پیش‌بینی کرد و نتایج آزمایش تجربی نیز تطابق قابل قبولی با مقادیر پیش‌بینی‌شده نشان داد که بیانگر اعتبار مدل توسعه‌یافته در محدودهٔ طراحی آزمایش است.

در بخش مدل‌سازی هوشمند، شبکهٔ عصبی مصنوعی با ساختار پرسپترون چندلایه، یک لایهٔ پنهان، الگوریتم آموزش منظم‌سازی بیزین (trainbr) و اعتبارسنجی متقاطع پنج‌بخشی توسعه داده شد. نتایج نشان داد با وجود عملکرد مناسب ANN در مدل‌سازی رفتار غیرخطی سامانه، دقت پیش‌بینی آن در این پژوهش از مدل RSM کمتر بود. اعتبارسنجی چهار نقطهٔ مستقل خارج از مجموعه طراحی آزمایش نیز نشان داد پیش‌بینی‌های RSM در اکثر پاسخ‌ها به مقادیر تجربی نزدیک‌تر از ANN بودند. این موضوع احتمالاً ناشی از محدود بودن حجم داده‌های آموزشی (۲۹ آزمایش) است؛ زیرا شبکه‌های عصبی برای استخراج روابط غیرخطی پیچیده معمولاً به مجموعه داده‌های بزرگ‌تری نیاز دارند، در حالی که مدل‌های RSM در مجموعه داده‌های کوچک و طراحی‌شده عملکرد پایدارتری از خود نشان می‌دهند.

یکی از دستاوردهای مهم این پژوهش، اعتبارسنجی تجربی هر دو مدل در شرایط عملیاتی جدید بود. به خلاف بسیاری از مطالعات که ارزیابی مدل را تنها به داده‌های طراحی آزمایش محدود می‌کنند، در این تحقیق علاوه بر نقطهٔ بهینه، سه نقطهٔ مستقل دیگر نیز انتخاب و به صورت آزمایشگاهی بررسی شدند. نتایج نشان داد هر دو مدل توانایی قابل قبولی در پیش‌بینی رفتار سامانه دارند، اما مدل RSM در محدودهٔ طراحی‌شده از قابلیت تعمیم و دقت بیشتری برخوردار است. این رویکرد، قابلیت اطمینان نتایج و امکان استفاده از مدل‌ها در طراحی و بهره‌برداری از سامانه‌های واقعی را افزایش می‌دهد.

از دیدگاه کاربردی، نتایج این مطالعه نشان می‌دهد استفاده از ریزجلبک *Desmodesmus sp.* می‌تواند گزینه‌ای مناسب برای حذف هم‌زمان مواد آلی و مغذی از پساب باشد و در عین حال امکان تولید زیست‌توده با ارزش افزوده را نیز فراهم کند. همچنین، استفاده از روش‌های مدل‌سازی و بهینه‌سازی، نیاز به انجام تعداد زیادی آزمایش تجربی را کاهش داده و می‌تواند هزینه و زمان توسعهٔ سامانه‌های تصفیه را به میزان قابل توجهی کم کند.

با وجود نتایج امیدوارکننده، این مطالعه دارای محدودیت‌هایی نیز بود. تعداد داده‌های آزمایشگاهی نسبتاً محدود بود و آزمایش‌ها در مقیاس آزمایشگاهی و با پساب سنتتیک انجام شدند. بنابراین، پیشنهاد می‌شود در پژوهش‌های آینده، عملکرد

مدل‌ها با استفاده از داده‌های بیشتر، پساب واقعی شهری یا صنعتی، شرایط نیمه‌صنعتی و صنعتی، و همچنین، الگوریتم‌های پیشرفته‌تر یادگیری ماشین مانند Random Forest، XGBoost، Support Vector Regression و شبکه‌های عصبی عمیق مورد بررسی قرار گیرد. همچنین، توسعهٔ مدل‌های ترکیبی RSM–ANN و انجام تحلیل حساسیت جهانی می‌تواند به درک بهتر روابط پیچیده میان متغیرهای عملیاتی و افزایش دقت پیش‌بینی سامانه‌های ریزجلبکی کمک کند.

در مجموع، این پژوهش نشان داد RSM ابزار مناسبی برای طراحی آزمایش، تحلیل اثر عوامل و بهینه‌سازی فرایند در مجموعه داده‌های محدود است، در حالی که ANN ظرفیت بالایی برای مدل‌سازی روابط غیرخطی دارد اما بهره‌گیری مؤثر از آن مستلزم وجود داده‌های آموزشی کافی است. استفادهٔ هم‌زمان از این دو رویکرد می‌تواند چارچوبی قابل اعتماد برای طراحی، بهینه‌سازی و توسعهٔ سامانه‌های تصفیهٔ پساب مبتنی بر ریزجلبک در مقیاس‌های بزرگ‌تر فراهم سازد.

منابع

[1]. M. S. Jami, I. A. Husain, N. A. Kabashi, and N. Abdullah, "Multiple inputs artificial neural network model for the prediction of wastewater treatment plant performance," *Australian Journal of Basic and Applied Sciences*, vol. 6, no. 1, pp. 62-69, 2012.

[2]. M. Hamada, H. Adel Zaqoot, and A. Abu Jreiban, "Application of artificial neural networks for the prediction of Gaza wastewater treatment plant performance-Gaza strip," *Journal of Applied Research in Water and Wastewater*, vol. 5, no. 1, pp. 399-406 ,2018.

[3]. M. Piekutowska *et al.*, "The application of multiple linear regression and artificial neural network models for yield prediction of very early potato cultivars before harvest," *Agronomy*, vol. 11, no. 5, p. 885, 2021.

[4]. A. B. Jasni, H. Kamyab, S .Chelliapan, N. Arumugam, S. Krishnan, and M. F. M. Din, "Treatment of Wastewater Using Response Surface Methodology: A Brief Review," *CET Journal-Chemical Engineering Transactions*, vol. 78, 2020.

[5]. N. G. Hammouda *et al.*, "Computational artificial intelligence modeling and optimization of nutrient removal in microalgae membrane bioreactors using ANN and RSM," *Scientific Reports*, 2026.

[6]. P. Wang *et al.*, "Advanced treatment of secondary effluent from wastewater treatment plant by a newly isolated microalga Desmodesmus sp. SNN1," *Frontiers in Microbiology*, vol. 14, p. 1111468, 2023.

[7]. L. Zhang, J. Liu, X. Shen, S. Li, W. Li, and X. Xiao, "Response surfaces method and artificial intelligence approaches for modeling the effects of environmental factors on chlorophyll a in isochrysis galbana," *Microorganisms*, vol. 11, no. 8, p. 1875, 2023.

[8]. M. D. Popa, I.-A. Simionov, S. M. Petrea, P.-L. Georgescu, G. A. Ifrim, and C. Iticescu, "Efficiency of microalgae employment in nutrient removal (nitrogen and phosphorous) from municipal wastewater," *Water*, vol. 17, no. 2, p. 260, 2025.

[9]. M. Makaremi, J. Sabkara, and T. Kafash Mohmmadjani, "Phytoplankton species in Anzall Lagoon and Caspian Sea coastal waters," *Iranian Scientific Fisheries Journal*, vol. 15, no ,۱ .pp. 129-150, 2006.

[10]. D. F. Charles, C. Knowles, and R. S. Davis, "Protocols for the analysis of algal samples collected as part of the US Geological Survey National Water-Quality Assessment Program," *Patrick Center for Environmental Research Report* ,no. 02-06, 2002.

[11]. Y.-K. Lee, "Microalgal mass culture systems and methods: their limitation and potential," *Journal of applied phycology*, vol. 13, no. 4, pp. 307-315, 2001.

[12]. A. Zahedi and S. Labbafi, "Optimization of biomass growth for a novel quadruple renewable geothermal/hydro/biomass/solar hybrid system," *Fuel*, vol. 306, p. 121694, 2021/12/15/ 2021, doi: https://doi.org/10.1016/j.fuel.2021.121694.

[13]. P. Wang *et al.*, "Advanced treatment of secondary effluent from wastewater treatment plant by a newly isolated microalga Desmodesmus sp. SNN1," (in English), *Frontiers in Microbiology*, Original Research vol. Volume 14 - 2023, 2023-January-26 2023, doi: 10.3389/fmicb.2023.1111468.

[14]. C. C. Chong *et al.*, "Anaerobic digestate as a low-cost nutrient source for sustainable microalgae cultivation: A way forward through waste valorization approach," *Science of The Total Environment*, vol. 803, p. 150070, 2022/01/10/ 2022, doi: https://doi.org/10.1016/j.scitotenv.2021.150070.

[15]. L. Gouveia *et al.*, "Microalgae biomass production using wastewater: Treatment and costs: Scale-up considerations," *Algal Research*, vol. 16, pp. 167-176, 2016.

[16]. A. Nikolaou, P. Hartmann, A. Sciandra, B. Chachuat, and O. Bernard, "Dynamic coupling of photoacclimation and photoinhibition in a model of microalgae growth," *Journal of theoretical biology*, vol. 390, pp. 61-72, 2016.

[17]. A. K. Badawi, B. Ismail, O. Baaloudj, and K. Z. Abdalla, "Advanced wastewater treatment process using algal photo-bioreactor associated with dissolved-air flotation system: A pilot-scale demonstration," *Journal of Water Process Engineering*, vol. 46, p. 102565, 2022/04/01/ 2022, doi: https://doi.org/10.1016/j.jwpe.2022.102565.

[18]. P. Li *et al.*, "Aeration strategies for microalgae in wastewater treatment: Enhancing pollutant removal and community dynamics," *Journal of Environmental Management,* vol. 377, p. 124629, 2025.

[19]. A. Kumar *et al.*, "Hydrothermal liquefaction of wastewater-grown algae to produce synthetic aviation fuel: A combined experimental study and techno-economic assessment," *Energy Conversion and Management: X,* p. 101096, 2025.

[20]. A. Ashadullah, M. Shafiquzzaman, H. Haider, M. Alresheedi, M. S. Azam, and A. R. Ghumman, "Wastewater treatment by microalgal membrane bioreactor: evaluating the effect of organic loading rate and hydraulic residence time," *Journal of environmental management,* vol. 278, p. 111548, 2021.

[21]. B. Hu *et al.*, "Influence of exogenous CO 2 on biomass and lipid accumulation of microalgae Auxenochlorella protothecoides cultivated in concentrated municipal wastewater," *Applied biochemistry and biotechnology,* vol. 166, no. 7, pp. 1661-1673, 2012.

[22]. J. Qian *et al.*, "pH treatments in continuous cultivation to maximize microalgal production and nutrient removal from anaerobic digestion effluent of aquatic macrophytes," *Journal of Applied Phycology,* vol. 32, no. 5, pp. 3349-3362, 2020.

[23]. E. Touloupakis, B. Cicchi, A. M. S. Benavides, and G. Torzillo, "Effect of high pH on growth of Synechocystis sp. PCC 6803 cultures and their contamination by golden algae (Poterioochromonas sp.)," *Applied microbiology and biotechnology,* vol. 100, no. 3, pp. 1333-1341, 2016.

[24]. H. Yu, J. Kim, C. Rhee, J. Shin, S. G. Shin, and C. Lee, "Effects of different pH control strategies on microalgae cultivation and nutrient removal from anaerobic digestion effluent," *Microorganisms,* vol. 10, no. 2, p. 357, 2022.

[25]. F. Gao *et al.*, "Continuous microalgae cultivation in aquaculture wastewater by a membrane photobioreactor for biomass production and nutrients removal," *Ecological engineering,* vol. 92, pp. 55-61, 2016.

[26]. S. F. Mohsenpour, S. Hennige, N. Willoughby, A. Adeloye, and T. Gutierrez, "Integrating micro-algae into wastewater treatment: A review," (in eng), *Sci Total Environ* ,vol. 752, p. 142168, Jan 15 2021, doi: 10.1016/j.scitotenv.2020.142168.

[27]. M. Plöhn *et al.*, "Wastewater treatment by microalgae," (in eng), *Physiol Plant,* vol. 173, no. 2, pp. 568-578, Oct 2021, doi: 10.1111/ppl.13427.

[28]. F. B. Nasir and J. Li, "Comparative analysis of machine learning models and explainable artificial intelligence for predicting wastewater treatment plant variables," *Advances in Environmental and Engineering Research,* vol. 5, no. 4, pp. 1-23, 2024.