

Otimização do Cultivo de Microalgas em Lagoa Raceway

Gabriela de Assis Ferreira^{a*}, Argimiro Resende Secchi^a, Roymel Rodríguez Carpio^a

^a COPPE/UFRJ, Programa de Engenharia Química, Rio de Janeiro-RJ, Brasil

* gabriela.ferreira@peq.coppe.ufrj.br

RESUMO

O cultivo de microalgas em lagoas raceway tem despertado crescente interesse industrial devido ao potencial de produção de biomassa para aplicações em biocombustíveis, alimentação animal e captura de carbono. Este trabalho apresenta uma abordagem integrada de otimização para maximização da produção de biomassa em sistemas de cultivo de microalgas, utilizando como estudo de caso uma cianobactéria genérica em lagoa raceway com alimentação contínua. O modelo matemático baseia-se na dinâmica de crescimento celular descrita pelo modelo de Droop, incorporando limitações por luz, carbono e nitrogênio. A otimização foi conduzida em duas etapas: (i) otimização das condições iniciais do cultivo utilizando abordagens híbrida determinística (Nelder-Mead seguido de L-BFGS-B) e metaheurística Bayesiana; e (ii) otimização da programação temporal de coleta de biomassa mediante Grid Search. Os resultados demonstraram que ambas as abordagens alcançaram melhorias significativas, com incremento de aproximadamente 260% na biomassa total, sendo que a abordagem Bayesiana apresentou ligeira vantagem (279,1% de melhoria contra 264,2% da determinística) com menor tempo computacional (44,58 s contra 253,19 s). A otimização da coleta identificou a remoção conjunta de biomassa e volume no 21º dia com fração de 70% como estratégia ótima, proporcionando ganho adicional de 0,51%. Os resultados demonstram o potencial das metodologias propostas para aplicação em sistemas reais de cultivo de microalgas.

Palavras-chave: Otimização; Programação de Coleta; Microalgas; Lagoa Raceway.

1 Introdução

Nos últimos anos, o cultivo de microalgas tem ganhado destaque como uma tecnologia promissora para captura de carbono e produção de biomassa de valor agregado, especialmente no contexto de descarbonização e economia circular (García-Sánchez et al., 2025). Microalgas são microrganismos fotossintetizantes responsáveis por 40 a 50% do oxigênio atmosférico, com metabolismo capaz de converter gás carbônico e óxidos de nitrogênio em biomassa. Dentre os sistemas de cultivo, as lagoas raceway destacam-se por seu menor custo de implementação e facilidade de operação em comparação com biorreatores fechados (Chisti, 2016). No entanto, estes sistemas apresentam desafios significativos relacionados à baixa produtividade, que tipicamente não ultrapassa 15 g/m²/dia, e à dificuldade de manutenção de parâmetros ótimos de operação devido à alta evaporação e contaminações externas (Delrue et al., 2017). Estudos mostram que ao integrar uma corrente de alimentação de CO₂ in situ, a absorção de carbono pode alcançar 86,16%, o que é particularmente interessante para indústrias que possuem correntes de rejeito deste componente (Jimenez et al., 2003). A otimização de processos biológicos como o cultivo de microalgas enfrenta obstáculos particulares, incluindo a não-linearidade das equações que descrevem o crescimento celular, a presença de múltiplos fatores limitantes (luz, carbono, nitrogênio) e o alto custo computacional associado à simulação do sistema (Bernard et al., 2011). Neste contexto, torna-se fundamental o desenvolvimento de estratégias de otimização eficientes que permitam maximizar a produção de biomassa com um número reduzido de avaliações da função objetivo. Este trabalho tem como objetivo desenvolver e comparar duas abordagens de otimização para maximização da produção de biomassa em cultivo de microalgas em lagoa raceway: uma abordagem híbrida determinística, combinando os algoritmos Nelder-Mead e L-BFGS-B, e uma abordagem metaheurística Bayesiana. Adicionalmente, propõe-se a otimização da programação temporal de coleta de biomassa utilizando Grid Search, visando maximizar a biomassa total recuperada.

2 Metodologia

O sistema de cultivo de microalgas em lagoa raceway foi modelado considerando a dinâmica de crescimento celular, consumo de nutrientes (CO₂ e NH₄⁺) e variação de volume. O crescimento foi representado pelo modelo

de Droop (Equações 1 a 3), que relaciona a taxa de crescimento à quota intracelular de nutrientes (Bernard et al., 2011).

$$\frac{ds}{dt} = Ds_{in} - \rho_m \frac{s}{s + K_{s,N}} x - Ds \quad (1)$$

$$\frac{dq}{dt} = \rho_m \frac{s}{s + K_{s,N}} - \bar{\mu} \left(1 - \frac{Q_0}{q} \right) q \quad (2)$$

$$\frac{dx}{dt} = \bar{\mu} \left(1 - \frac{Q_0}{q} \right) x - Dx - R_d x \quad (3)$$

onde s é a concentração de NH_4^+ (g/m^3), q a quota intracelular de nitrogênio (g N/g biomassa), x a concentração de biomassa (g/m^3), D a taxa de diluição (d^{-1}), $K_{s,N}$ a constante de meia-saturação (g/m^3), Q_0 a quota mínima de nitrogênio (g N/g biomassa), $\bar{\mu}$ a taxa máxima de crescimento dependente da luz (d^{-1}) e R_d a taxa de respiração (d^{-1}). Para o carbono, as equações análogas são:

$$\frac{dc}{dt} = Dc_{in} - \rho_m \frac{c}{c + K_{s,CO_2}} x - Dc \quad (4)$$

$$\frac{dq_{CO_2}}{dt} = \rho_m \frac{c}{c + K_{s,CO_2}} - \bar{\mu} \left(1 - \frac{Q_{0,CO_2}}{q_{CO_2}} \right) q_{CO_2} \quad (5)$$

A taxa de crescimento dependente da luz é descrita pelo modelo de inibição por alta intensidade: $\bar{\mu} = \tilde{\mu} \cdot I / (K_L + I + I^2/K_I)$. A Tabela 1 apresenta os principais parâmetros do modelo.

Tabela 1: Parâmetros do modelo de cultivo

Parâmetro	Valor	Unidade
$\tilde{\mu}$	4,99	d^{-1}
K_L	154	$\mu\text{mol m}^{-2} \text{s}^{-1}$
K_I	800	$\mu\text{mol m}^{-2} \text{s}^{-1}$
I_0	220	$\mu\text{mol m}^{-2} \text{s}^{-1}$
R_d	0,02	d^{-1}
Q_0	0,03	g N/g biomassa
Q_{0,CO_2}	0,5	g C/g biomassa
$K_{s,N}$	0,154	g/m^3
K_{s,CO_2}	0,011	g/m^3
ρ_m	7,54	d^{-1}

A otimização foi conduzida visando maximizar a biomassa total acumulada ao final do período de cultivo de 30 dias, conforme a Equação 6.

$$\max J = \int_0^{30} \mu_{\text{efetivo}}(t) \cdot x(t) \cdot V(t) dt \quad (6)$$

onde μ_{efetivo} é a taxa de crescimento específica efetiva (d^{-1}), $x(t)$ a concentração de biomassa (g/m^3) e $V(t)$ o volume do reator (m^3). A função objetivo é avaliada numericamente a partir da solução do sistema de EDOs para cada conjunto de parâmetros testado.

Foram otimizadas cinco variáveis de decisão: concentrações iniciais de CO_2 (50-200 mg/L) e NH_4^+ (20-100 mg/L), biomassa inicial (5-20 g/L), volume inicial (50-200 m^3) e salinidade inicial (25-45 g/L). Duas abordagens foram empregadas e comparadas. Na abordagem determinística híbrida, aplicou-se primeiramente o algoritmo Nelder-Mead para uma exploração inicial do espaço de busca, seguido pelo método L-BFGS-B (*Limited-memory Broyden-Fletcher-Goldfarb-Shanno with Bound Constraints*) para refinamento da solução. Ambos foram implementados com a função minimize da biblioteca `scipy.optimize`, com tolerância de 10^{-4} e máximo de 100

iterações para o primeiro estágio, e tolerância de 10^{-6} com 200 iterações para o segundo. Na abordagem metaheurística, empregou-se o algoritmo `gp_minimize` da biblioteca `scikit-optimize`, que constrói um modelo substituto da função objetivo utilizando um processo gaussiano e uma função de aquisição para balancear exploração versus exploração (Brochu et al., 2010; Shahriari et al., 2016). Foram realizadas 50 avaliações da função objetivo, com 10 pontos iniciais para amostragem e ruído de 10^{-6} para evitar avaliações idênticas.

Utilizando as condições iniciais otimizadas na etapa anterior, buscou-se determinar a melhor estratégia de coleta para maximizar a biomassa total recuperada, incluindo tanto a biomassa remanescente no tanque quanto a biomassa removida, conforme a Equação 7.

$$f(\text{Tipo}, t, \phi) = \max \{x(t_f) \cdot V(t_f) + \phi \cdot x(t_{\text{coleta}}) \cdot V(t_{\text{coleta}})\} \quad (7)$$

As variáveis de decisão discretas avaliadas foram: tipo de remoção (biomassa, volume ou ambos), tempo de remoção entre 5 e 25 dias com passo de 2 dias, e fração de remoção entre 0,1 e 0,7 com passo de 0,1. Devido à natureza discreta do problema e ao espaço de busca moderado (231 combinações para remoções individuais, totalizando 307 simulações), adotou-se o método de *Grid Search* (busca exaustiva em grade), que implementa um loop aninhado sobre todas as combinações possíveis, avaliando a função objetivo para cada ponto e selecionando aquela que produz o maior valor (Bergstra e Bengio, 2012). Esta abordagem garante a determinação do ótimo global dentro da grade especificada. Todo o ambiente computacional foi implementado em linguagem Python versão 3.10, com o sistema de EDOs resolvido pelo método BDF da função `solve_ivp` da biblioteca `scipy.integrate` (Byrne e Hindmarsh, 1975).

3 Resultados e Discussão


A Tabela 2 apresenta os valores ótimos encontrados por cada abordagem, bem como os tempos computacionais e as melhorias alcançadas. Ambas as abordagens alcançaram melhorias significativas na biomassa total, com incrementos superiores a 260%. A abordagem Bayesiana apresentou ligeira vantagem (279,1% contra 264,2% da determinística) e foi substancialmente mais rápida (44,58 s contra 253,19 s). Este resultado evidencia a eficiência da otimização Bayesiana para problemas com função objetivo de alto custo computacional, característica comum em modelos biológicos.

É importante destacar que a sequência de otimização determinística empregada (Nelder-Mead seguido de L-BFGS-B) pode ser considerada não convencional do ponto de vista teórico. O método de Nelder-Mead, embora não utilize informações de gradiente, é frequentemente empregado em etapas exploratórias devido à sua robustez a superfícies irregulares. Já o L-BFGS-B, por ser baseado em gradiente, apresenta maior taxa de convergência e é mais adequado para refinamento local. Contudo, nenhum dos dois algoritmos possui caráter de otimização global, o que pode limitar a capacidade de fuga de ótimos locais. Apesar dessa limitação teórica, a combinação mostrou-se eficaz no problema estudado, alcançando melhorias expressivas na biomassa total.

Tabela 2: Resultados das abordagens de otimização


Variável	Condição inicial	Determinística	Bayesiana
CO ₂ inicial (mg/L)	100,00	142,43	142,26
NH ₄ ⁺ inicial (mg/L)	50,00	22,38	93,65
Biomassa inicial (g/L)	10,00	20,00	19,95
Volume inicial (m ³)	100,00	199,96	200,00
Salinidade inicial (g/L)	35,00	25,18	45,00
Biomassa total (kg)	5,69	20,73	21,58
Melhoria (%)	-	264,2%	279,1%
Tempo total (s)	-	253,19	44,58

Figura 1: Comparação do desempenho do sistema antes e após o processo de otimização



A Figura 1 apresenta a comparação do desempenho do sistema antes e após o processo de otimização. Observa-se um aumento significativo nas concentrações de CO_2 e NH_4^+ , indicando que estes nutrientes atuavam como fatores limitantes no processo produtivo. A otimização permitiu ajustar estas variáveis para níveis que maximizam a produtividade do sistema.


Figura 2: Relações multidimensionais entre parâmetros do processo e biomassa total



A Figura 2 apresenta uma análise multidimensional das relações entre as variáveis do processo e a biomassa total produzida. Esta visualização tridimensional revela padrões complexos de interação que podem não ser aparentes em análises bidimensionais convencionais, evidenciando a formação de regiões ótimas específicas no espaço de parâmetros, onde combinações particulares de CO_2 e NH_4^+ propiciam condições ideais para maximização

da produtividade. Observa-se que o volume da lagoa e a concentração inicial de biomassa apresentam as maiores correlações positivas com a produção final, com coeficientes de correlação superiores a 0,80, enquanto a salinidade demonstra influência moderada e a concentração inicial de CO₂ tem baixa correlação com a biomassa do sistema, sugerindo que uma otimização dinâmica da alimentação ao longo do cultivo poderia trazer benefícios adicionais.

Figura 3: Trajetória de convergência dos parâmetros durante o processo de otimização



A Figura 3 apresenta a trajetória de convergência das variáveis durante o processo de otimização, mostrando os resultados para a otimização de coleta. Observa-se uma exploração inicial do espaço de busca seguida pela exploração das regiões mais promissoras, com a biomassa total apresentando convergência monotônica para o valor máximo, sendo que aproximadamente 20 iterações foram suficientes para atingir a região ótima principal. Este padrão de convergência rápida com refinamento incremental é característico de problemas onde a função objetivo apresenta uma região promissora bem definida, permitindo ao algoritmo de otimização Bayesiana explorar eficientemente o espaço de parâmetros com um número relativamente reduzido de avaliações da função custosa.

A Tabela 3 apresenta os resultados da otimização da coleta de biomassa utilizando Grid Search. A estratégia ótima identificada consiste na remoção conjunta de biomassa e volume no 21º dia de cultivo, com fração de 70%. Embora o ganho adicional seja modesto (0,51%), em escala industrial este incremento pode representar um aumento significativo na receita anual. O método de Grid Search, embora exaustivo, garantiu a determinação do ótimo global dentro do espaço de busca especificado, com tempo computacional de apenas 37,63 segundos para 307 simulações, demonstrando eficiência computacional média de 0,40 segundos por simulação.

Tabela 3: Resultados da otimização da coleta de biomassa

Parâmetro	Valor ótimo
Tipo de remoção	Biomassa + Volume
Tempo de remoção (dias)	21
Fração de remoção	0,7
Biomassa sem coleta (kg)	21,57
Biomassa com coleta otimizada (kg)	21,68
Melhoria adicional (%)	0,51%
Número de simulações	307
Tempo total (s)	37,63

4 Conclusão

Este trabalho apresentou uma abordagem integrada de otimização para maximização da produção de biomassa em cultivo de microalgas em lagoa raceway. Ambas as abordagens de otimização das condições iniciais (híbrida determinística com Nelder-Mead seguido de L-BFGS-B e Bayesiana) alcançaram melhorias significativas, com incrementos superiores a 260% na biomassa total, sendo que a abordagem Bayesiana demonstrou-se mais eficiente, com melhor resultado (279,1% de melhoria) e menor tempo computacional (44,58 s contra 253,19 s), consolidando-se como uma ferramenta promissora para investigações futuras, especialmente por permitir a exploração eficiente de um grande número de variáveis e amplos intervalos de busca. A otimização da programação de coleta identificou a remoção conjunta de biomassa e volume no 21º dia com fração de 70% como estratégia ótima, proporcionando ganho adicional de 0,51%, o que em um processo industrial real representa um fator crítico que impacta a viabilidade econômica. O modelo foi desenvolvido para uma microalga genérica, incorporando parâmetros de diferentes espécies para os cálculos, sendo que a ausência de dados experimentais e industriais limita a validação dos resultados e o ajuste fino do modelo. Como perspectivas futuras, destacam-se a incorporação de dados experimentais para calibração do modelo (Smucker et al., 2021), a otimização dinâmica do sistema de alimentação, a ampliação dos limites das variáveis de projeto, a otimização dos parâmetros de projeto da lagoa raceway, a otimização robusta considerando a presença de distúrbios, e a implementação de estratégias de controle preditivo não-linear (NMPC) para mitigação de perturbações detectadas através de quedas no pH (Caparroz et al., 2024).

Agradecimentos: Os autores agradecem o apoio financeiro do Programa de Formação de Recursos Humanos da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis - PRH-ANP, gerido pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil. Processo nº 2025/26549-6

Referências

- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(2).
- Bernard, O., et al. (2011). Hurdles and challenges for modelling and control of microalgae for CO₂ mitigation and biofuel production. *Journal of Process Control*, 21(10), 1378–1389.
- Brochu, E., Cora, V. M., & de Freitas, N. (2010). A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. *arXiv preprint arXiv:1012.2599*.
- Byrne, G. D., & Hindmarsh, A. C. (1975). A polialgorithm for the numerical solution of ordinary differential equations. *ACM Transactions on Mathematical Software*, 1(1), 71–96.
- Caparroz, M., et al. (2024). A novel data-driven model for prediction and adaptive control of pH in raceway reactor for microalgae cultivation. *New Biotechnology*, 82, 1–13.
- Chisti, Y. (2016). Large-scale production of algal biomass: raceway ponds. Em *Green Energy and Technology* (pp. 21–40). Springer.
- Delrue, F., et al. (2017). Optimization of *Arthrospira platensis* (Spirulina) growth: from laboratory scale to pilot scale. *Fermentation*, 3(4), 59.
- García-Sánchez, I.-M., et al. (2025). Decarbonisation strategies and climate governance: are institutional investors reshaping the business model of multinationals? *Journal of Innovation & Knowledge*, 10(3), 100698.
- Jimenez, C., et al. (2003). Relationship between physicochemical variables and productivity in open ponds for the production of *Spirulina*: a predictive model of algal yield. *Aquaculture*, 221(1-4), 331–345.
- Shahriari, B., Swersky, K., Wang, Z., Adams, R. P., & De Freitas, N. (2016). Taking the human out of the loop: A review of Bayesian optimization. *Proceedings of the IEEE*, 104(1), 148–175.
- Smucker, N. J., et al. (2021). Increasingly severe cyanobacterial blooms and deep water hypoxia coincide with warming water temperatures in reservoirs. *Global Change Biology*, 27(11), 2507–2519.