

Redes Neurais na gestão das águas em reservatórios hidrelétricos: um estudo de caso na Hidrelétrica Itaipu (Brasil)

Juliana Nascimento Silva¹, Roseli Frederigi Benassi¹, Edmarcio Antonio Belati¹, Patricia Teixeira Leite Asano¹, Ricardo Caneloi dos Santos¹, Ricardo Suyama¹, Simone Frederigi Benassi²

¹Federal University of ABC

Av. Dos Estados, 5001 - Bangú, Santo André, 09210-580, São Paulo, Brasil.

jsilva@ufabc.edu.br, roseli.benassi@ufabc.edu.br, edmarcio.belati@ufabc.edu.br, patricia.leite@ufabc.edu.br, ricardo.santos@ufabc.edu.br, ricardo.suyama@ufabc.edu.br

²Itaipu Binacional – Diretoria de Coordenação, Divisão de Reservatório (MARR.CD)
simonefb@itaipu.gov.br

Resumo. A geração de energia elétrica a partir da água é muito promissora no Brasil. No entanto, em reservatórios hidroelétricos, processos de eutrofização podem ocasionar alterações, prejuízos e comprometer a operação da usina. Nesse cenário, o uso de comunidades biológicas fitoplanctônicas é uma importante ferramenta no biomonitoramento, principalmente pela presença e/ou ausência delas serem um importante elemento para avaliação das condições ambientais. Esse artigo teve como objetivo utilizar Algoritmos Genéticos (AGs) para identificar variáveis físico-químicas relacionadas à densidade de fitoplâncton nas águas do reservatório da Usina de Itaipu e desenvolver um modelo preditivo para a densidade fitoplanctônica utilizando Redes Neurais Artificiais (RNAs). O AG indicou que as variáveis mais importantes para predição de fitoplâncton foram: concentrações de nitrato, nitrogênio amoniacal, oxigênio dissolvido e Demanda Química de Oxigênio (DQO). As previsões da RNA foram coerentes com outros estudos e com os dados reais utilizados no teste da RNA e sustentam a possibilidade de que o modelo pode ser implementado na usina hidrelétrica para auxiliar na gestão das águas no reservatório ao permitir o monitoramento da qualidade da água em intervalos temporais menores que os atuais.

Palavras-chave: fitoplâncton, usina hidrelétrica, redes neurais.

1 Introdução

Equacionar a demanda crescente de água para fazer face aos conflitos gerados pelo avanço da degradação ambiental das águas no Brasil tem sido um grande desafio. Os recursos hídricos podem ser aproveitados para múltiplas finalidades, desde abastecimento e irrigação até a geração de energia elétrica, sendo esta última responsável por mais de 60% da geração de energia consumida no Brasil, que apresenta condições favoráveis à exploração de energia elétrica a partir de fontes renováveis, especialmente por sua grande disponibilidade de recursos hídricos superficiais. Com a implantação do reservatório de uma usina hidrelétrica, distintos ecossistemas envolvidos (aquáticos, terrestres e interfaces) sofrem alterações, pois o ambiente aquático altera seu regime de fluxo de águas correntes para águas paradas, levando a importantes mudanças nas características físico-químicas e na sua estrutura e organização biológica [15]. Aliado a esse fator, os tipos de uso e ocupação na bacia de drenagem em todo reservatório tem mudanças ao longo dos anos e exerce influência sobre a qualidade das águas. As práticas agrícolas e a influência das cidades sobre os recursos hídricos são evidentes, uma vez que podem carrear aos reservatórios elevadas cargas de material orgânico e inorgânico, favorecendo em muitos casos a ocorrência de processos de eutrofização dos corpos d'água e comprometendo a qualidade da água e seus usos múltiplos [1].

Especificamente no caso de reservatórios hidrelétricos, o aporte de matéria orgânica a partir do processo de eutrofização promove o aumento da taxa de sedimentação de partículas, contribuindo para a diminuição da vida útil dos reservatórios. Também não são raras situações de insalubridade em plantas de geração de energia pelo mau cheiro gerado pela decomposição de algas nos picos de eventos de floração [9]. Macrófitas aquáticas, também beneficiadas pelo excesso de nutrientes podem encalhar em grades de proteção de turbinas, aumentando o custo de manutenção, uma vez que a máquina deve ser desligada para limpeza, paralisando assim o processo de geração

de energia [11]. Também a eutrofização de reservatórios hidrelétricos pode ocasionar problemas como a alteração da composição química da água que pode comprometer equipamentos e processos da usina [9]. Na área da saúde pública, o problema de eutrofização está relacionado à elevação na concentração de algas com potencial tóxico e produtoras de enfermidades dermato, hepato e neurológicas. Entre os problemas socioeconômicos podem ser elencados: alteração nas características organolépticas da água (cor, odor e sabor), tornando-a imprópria para consumo e recreação, elevando os custos de tratamento e de manutenção da harmonia paisagística.

Portanto, programas de monitoramento das condições físicas, químicas e biológicas são indispensáveis nos reservatórios, pois proveem uma estimativa representativa e confiável das características das águas superficiais e são importantes para a gestão das mesmas, subsidiando ações de controle ambiental [2], além da manutenção dos usos múltiplos do reservatório. As assembleias fitoplanctônicas costumam ser utilizadas para monitorar a qualidade biológica da água, pois são um exemplo de um grupo de organismos encontrados em reservatórios e que estão na base da cadeia alimentar aquática, servindo de alimento para os níveis superiores (zooplâncton e peixes) desempenhando assim papel fundamental nessa dinâmica. Além disso, são organismos sensíveis e capazes de responder prontamente as alterações ambientais ocorridas no meio aquático em curto espaço de tempo, sendo possível avaliar por meio desses organismos as características e a atual dinâmica dos reservatórios. Modificações na estrutura, composição, abundância, tamanho das populações fitoplanctônicas podem alterar, por consequência, a produção de matéria orgânica [8]. Desse modo, o uso de comunidades biológicas fitoplanctônicas (especialmente algas) é uma importante ferramenta no biomonitoramento, principalmente pela presença e/ou ausência delas, e suas respectivas espécies, serem um importante elemento para avaliação das condições ambientais [12, 13], sendo utilizadas para avaliar a saúde do ambiente e inferir as prováveis causas de danos ecológicos [6].

De acordo com Lamparelli [11], a existência de séries históricas, bem como sua interpretação, permite uma maior compreensão da qualidade ambiental do recurso hídrico, sua evolução ao longo do tempo, e suas correlações com fatores climáticos ou econômicos. Conforme Veiga [16], monitoramentos convencionais auxiliam no entendimento das alterações sofridas pelo ecossistema aquático quando da construção de um barramento, no entanto, há uma dinâmica complexa que não é muitas vezes compreendida neste processo. Portanto, metodologias e aplicações que venham a contribuir para a tomada de decisão pelos gestores ambientais auxiliam na concentração de esforços que visam ao planejamento, à distribuição de recursos e à tomada de decisões. Nesse cenário, é de grande interesse o estudo de métodos de previsão de séries temporais, ou seja, conseguir identificar e prever algumas características do processo num ponto futuro. As condições presentes determinam em algum grau o futuro possivelmente envolvendo relações complexas entre as variáveis. Uma situação ideal para a realização de previsões seria o conhecimento das equações que modelam os mecanismos responsáveis pela geração das séries temporais. No entanto, em muitos problemas reais essas informações não são disponíveis, e não se tem condições ideais para construir equações que governam o comportamento das variáveis de interesse. Quando isso acontece, o usual é utilizar uma abordagem baseada em modelos, na qual se tenta identificar ou aproximar o processo gerador dos dados.

Diversos autores já estudaram a relação de fitoplâncton e fatores ambientais em diversos reservatórios, utilizando abordagem baseada em modelos. Fornarelli *et al.* [4] utilizaram de modelagem empírica para encontrar a dinâmica fitoplanctônica de um reservatório no sistema Shoallaven (Austrália). Os autores aplicaram algoritmos de aprendizagem baseados em árvores de decisão para identificar fatores determinantes para explicar o biovolume de clorófitas, cianobactérias e diatomáceas, dentre 77 fatores. Dentre as variáveis identificadas como mais importantes, estão: temperatura da água, nível da água no reservatório, fósforo e nitrato. Wang *et al.* [17] investigaram a composição do fitoplâncton e fatores ambientais relacionados no rio Wujiang, no sudoeste da China, em um sistema de reservatório em cascata, aplicando redes neurais artificiais de retropropagação. As análises indicaram que a temperatura da água, CO₂ dissolvido e o silício foram os principais fatores que influenciam a estrutura da comunidade fitoplanctônicas.

Nesse artigo, foram utilizados dados históricos físico-químicos da água para prever a densidade fitoplanctônica na Usina Hidrelétrica de Itaipu (Brasil), de modo a contribuir com a gestão das águas no reservatório. Foi utilizado Algoritmos Genéticos (AGs) para identificar as variáveis que melhor explicam a variabilidade da densidade fitoplanctônica e, com essas variáveis, foram treinadas Redes Neurais Artificiais (RNAs) com diferentes configurações. O modelo desenvolvido pode subsidiar melhorias nas atuais e futuras medidas de gerenciamento e manejo do reservatório, de forma a buscar continuamente a otimização e maximização dos usos múltiplos das águas, além de promover o desenvolvimento sustentável em toda região do entorno.

2 Metodologia

2.1 Local de estudo

A Usina Hidrelétrica de Itaipu, que na sua característica construtiva e operativa é uma usina a fio-d'água, está localizada na região hidrográfica do Paraná. Essa bacia compreende alguns dos rios de grande importância nesse setor hidrelétrico, como o rio Grande, Tietê, Parnaíba, Paranapanema e Iguazu, nos quais foram construídas mais de 130 barragens [14]. Para esse estudo, foram utilizados dados coletados no braço do rio Passo Cuê (Figura 01), um dos principais afluentes ao reservatório de Itaipu e corresponde ao mais próximo à montante da barragem - aproximadamente 13 km desde sua foz até a tomada d'água da barragem - da margem esquerda (brasileira). O regime d'água neste braço é predominantemente lântico [10].

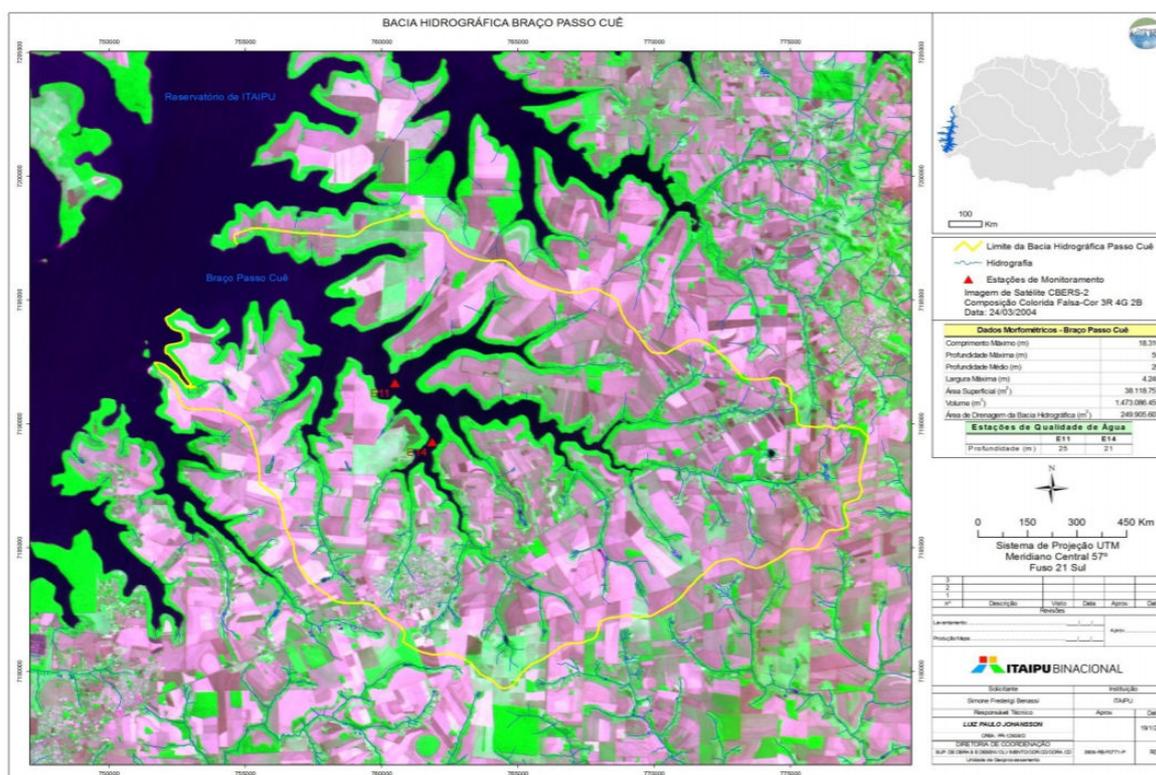


Figura 01: Mapa de localização da bacia hidrográfica do rio Passo Cuê [10].

2.2 Dados

A rede de monitoramento de qualidade da água a montante de Itaipu iniciou sua operação na década de 70, durante os estudos prévios de viabilidade do empreendimento e realizados em parceria com o atual Instituto de Água e Terra (IAT). Os técnicos, tanto de Itaipu quanto do Instituto, levam em consideração a característica do ecossistema, região e sazonalidade, contemplando as quatro estações climáticas do ano (primavera, verão, outono e inverno) para realizar as coletas. Atualmente a rede de monitoramento do reservatório (corpo central e principais braços) totaliza 13 (treze) estações de amostragem. No braço em que foi realizado o estudo em questão encontram-se duas estações de monitoramento da qualidade da água (nas coordenadas 21J 0.760.488 UTM 7.191.649 e 21J 0.761.845 UTM 7.189.268). Os dados ambientais utilizados nesse artigo foram fornecidos pela Itaipu e contemplam as médias mensais dos anos de 2005 a 2014 e constam de: temperatura do ar ($^{\circ}\text{C}$), nitrito (mg.L^{-1}), nitrato (mg.L^{-1}), oxigênio dissolvido (mg.L^{-1}), demanda biológica de oxigênio (DBO) (mg.L^{-1}), demanda química de oxigênio (DQO) (mg.L^{-1}), pH (Unidades), fósforo total (mg.L^{-1}), sólidos totais (mg.L^{-1}), nitrogênio amoniacal (N-NH_3) (mg.L^{-1}), alcalinidade total (mg.L^{-1}), turbidez (NTU), temperatura da água ($^{\circ}\text{C}$) e densidade fitoplânctônica (org.L^{-1}).

2.3 Análise dos dados

Algoritmos Genéticos (AGs) são uma técnica computacional utilizada para encontrar soluções ótimas ou quasi-ótimas em problemas de otimização e busca são inspirados na forma como os seres vivos sobrevivem e passam seu material genético para as próximas gerações, utilizando princípios de seleção natural e evolução propostos por Charles Darwin. Já as Redes Neurais Artificiais (RNAs) fundamentam-se nos estudos sobre a estrutura do cérebro humano para tentar emular sua forma inteligente de processar a informação. A habilidade das redes neurais em realizar mapeamentos não-lineares entre suas entradas e saídas as tem tornado prósperas no reconhecimento de padrões e na modelagem de sistemas complexos. Devido a sua estrutura, as redes neurais são bastante eficazes no aprendizado de padrões a partir de dados não-lineares, incompletos, com ruído ou mesmo compostos por exemplos contraditórios [7].

Primeiramente foi realizada a normalização dos dados, também chamada de padronização, para atender as entradas e saídas das RNAs (conforme as funções de ativação) e para efetuar a distribuição e o escalonamento dos dados de entrada num intervalo pré-definido (de 0 a 1). Nesse estudo, utilizou-se os AGs para selecionar as variáveis ambientais que melhor explicam a variação na densidade fitoplanctônica na área de estudo. Com essas variáveis foram treinadas RNAs com diferentes configurações a fim de obter um modelo de predição da densidade de fitoplâncton. Para as simulações envolvendo as RNAs, o conjunto de dados disponível foi separado em três partes: uma parte para treinamento, que foi utilizada para determinar os parâmetros da RNA (pesos e bias), uma amostra de verificação e uma amostra de teste (validação preditiva) para verificação da performance preditiva. Da amostra total de dados, foram separados os referentes à 2014 para o teste de RNAs e os demais foram utilizados no treinamento da rede (Figura 02). Os ambientes utilizados para a modelagem e implementação desta proposta foram o *Matlab* e *Statistica 7*.

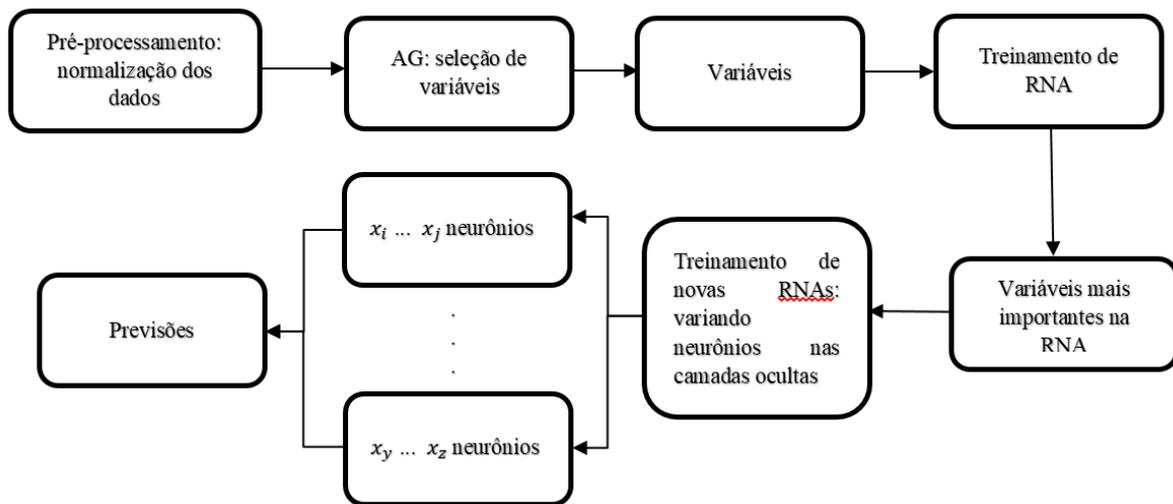


Figura 02: Fluxo seguido para modelagem dos dados de densidade fitoplanctônica.

3 Resultados e Discussão

Nesse estudo, como há muitas variáveis predictoras para densidade de fitoplâncton (13 variáveis no total), primeiramente foi utilizado AGs para seleção das variáveis de entrada na rede neural. Foi considerada uma população de 100 indivíduos e 1000 gerações, com taxa de mutação de 0,1 e crossover de 0,5. As variáveis resultantes foram: alcalinidade (Alcal), temperatura da água (Temp), nitrato, oxigênio dissolvido (OD), turbidez, N-NH, e DQO. Com essas variáveis foi treinada uma RNA com 2 camadas ocultas, com 8 e 11 neurônios e função de ativação linear. Na primeira camada foi utilizado algoritmo *back-propagation* com 20000 *epochs* e taxa de aprendizado de 0,01. Na segunda camada, o *Levenberg-Marquardt*, com 20000 *epochs*. O *momentum* foi de 0,4. Na tabela 01 seguem os parâmetros para avaliação da RNA treinada, com o grau de importância das variáveis para o modelo.

Tabela 01: RNA treinada com duas camadas ocultas com 8 e 11 neurônios (variáveis de entrada: alcalinidade, temperatura da água, nitrato, OD, turbidez, nitrogênio, DQO).

Modelo	Variáveis e grau de importância	Desvio	Erro Médio	Correlação
1	Alcal.(7)+Temp(6)+nitrato(3)+OD(4)+tu rbidez(5)+ N-NH ₃ (1)+DQO(2)	0,082847	-0,023406	0,341073

Das sete variáveis de entrada, foram selecionadas as quatro mais importantes para a predição da densidade fitoplanctônica: OD, nitrato, N-NH₃ e DQO. Com essas variáveis, novas redes neurais foram treinadas, todas com duas camadas ocultas, mas com variação na quantidade de neurônios, sendo: 5 e 10 neurônios, 10 e 10 neurônios e 10 e 15 neurônios. Na primeira camada das RNAs foi utilizado algoritmo *back-propagation* com 20000 *epochs* e taxa de aprendizado de 0,01. Na segunda camada, o *Levenberg-Marquardt*, com 20000 *epochs*. O *momentum* foi de 0,4 e a função de ativação foi linear. Na tabela 02 pode-se observar os parâmetros de avaliação das RNAs e os resultados obtidos.

Tabela 02: RNAs simuladas com diferentes configurações de neurônios nas duas camadas ocultas, para predição de densidade de fitoplâncton partir de dados de OD, nitrato, N-NH₃ e DQO.

	5 e 10 neurônios	10 e 10 neurônios	10 e 15 neurônios
Média	0,040068	0,040068	0,040068
Desvio padrão	0,072968	0,072968	0,072968
Erro Médio	-0,007497	-0,002477	-0,026112
Erro padrão	0,024041	0,085083	0,071647
Erro médio absoluto	0,007844	0,031400	0,027578
Correlação	0,954132	0,656436	0,749959

A configuração com 5 e 10 neurônios nas camadas ocultas foi a que apresentou menor erro médio absoluto. Utilizando essa configuração, os valores de todas as amostragens de dados conduzidas nos anos de 2005 a 2014 deram entrada na rede para obter as previsões. Na Tabela 03 e na Figura 03 é possível visualizar os resultados das previsões fornecidas pela RNA (previsto modelo) nessa configuração, bem como o desvio em relação ao valor real (coletado). Pode-se observar que o desvio foi nulo para os dados de treinamento, o que se deve principalmente ao *overfitting*.

Tabela 03: Dados observados (real), previstos pelo modelo e residual, para conjunto de teste e treinamento.

Entrada	Observado	Previsto modelo	Residual
Treino	0,032699	0,032699	0,000000
Treino	0,008953	0,008953	0,000000
Treino	0,002679	0,002679	0,000000
Treino	0,004932	0,004932	0,000000
Treino	0,014337	0,014337	0,000000
Treino	0,001504	0,001504	0,000000
Treino	0,003587	0,003587	0,000000
Treino	0,027240	0,027240	0,000000
Treino	0,057691	0,057691	0,000000
Treino	0,012384	0,012384	0,000000
Treino	0,008311	0,008311	0,000000
Treino	0,135237	0,135237	0,000000
Train	0,293334	0,293334	0,000000
Teste	0,004220	0,006995	0,002774
Teste	0,005748	-0,091727	0,097475
Teste	0,028227	0,002976	0,025251

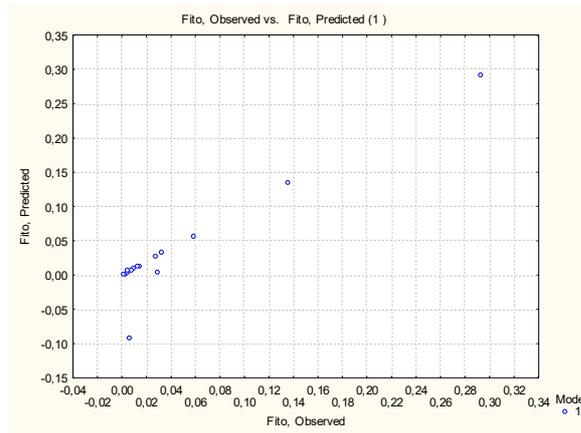


Figura 03: Gráfico dos valores de densidade fitoplânctônica (Fito.observed) versus valores de densidade fitoplânctônica preditos pelo modelo (Fito.predicted). Os dados estão normalizados.

Na Figura 04 pode-se observar a relação entre a variação das concentrações de $N-NH_3$ e nitrato, bem como OD e DQO com a densidade fitoplânctônica, utilizando modelo com a configuração de 5 e 10 neurônios. Valores elevados de $N-NH_3$ e nitrato estão relacionados com densidades mais elevadas de fitoplâncton (4b e 4d). Enquanto que OD e DQO tem uma relação não-linear com densidade de fitoplâncton (4a e 4c), sendo que com valores baixos de DQO a densidade de fitoplâncton tende a zero.

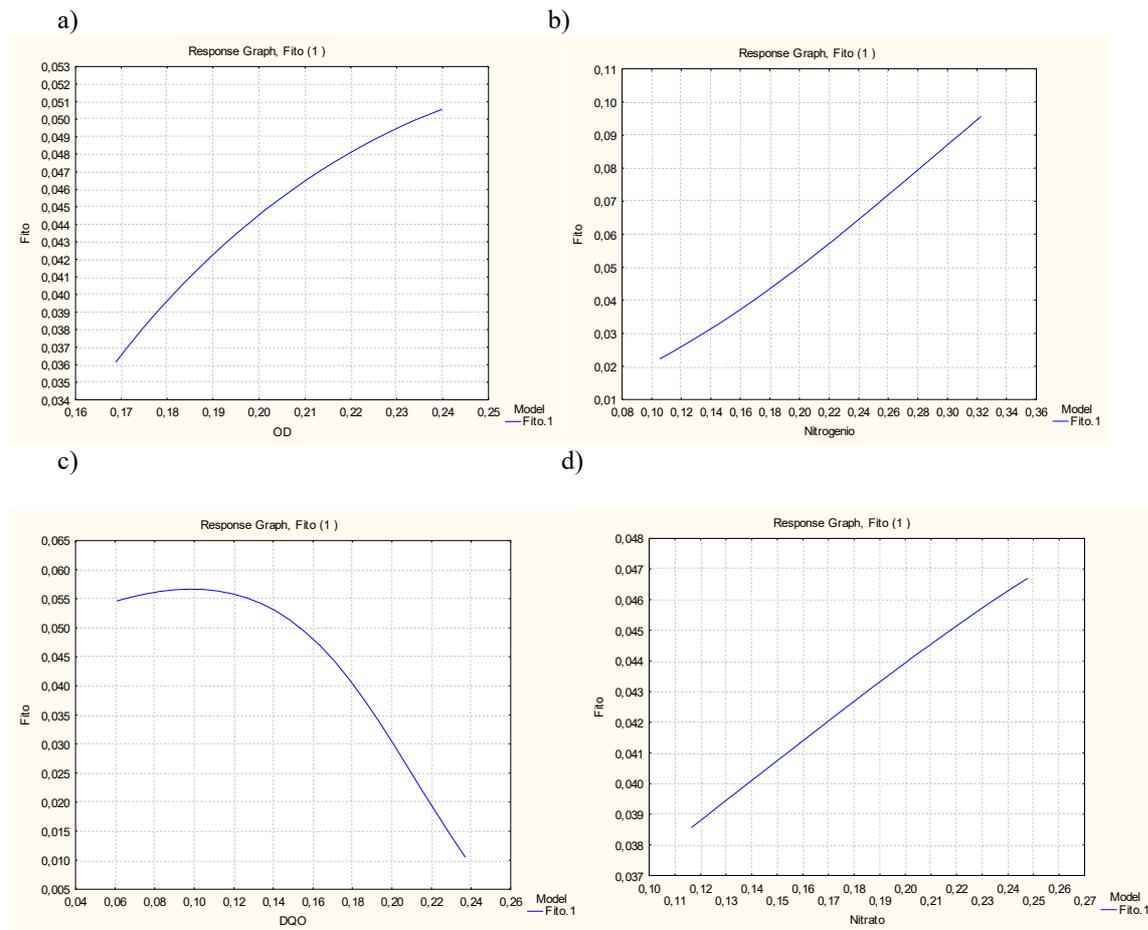


Figura 03: Gráfico dos valores de densidade fitoplânctônica (Fito) vs: OD (a), $N-NH_3$ (b), DQO (c) e nitrato (d). Os dados estão normalizados.

No Reservatório de Itaipu, a correlação entre fitoplâncton e nutrientes foi encontrada por Ribeiro-filho [14] em estudo de longo período (1985-2008), quando o autor identificou as correlações entre cianobactéria *versus* nitrogênio kjedahl e fósforo *versus* cianobactéria. Em trabalho conduzido na região por Maciel [10], cinco correlações com variáveis físico-químicas foram identificadas, sendo elas a riqueza, nitrogênio total kjedahl, nitrato, oxigênio dissolvido e pH. Todas essas variáveis são descritas na literatura como importantes fatores que interferem na estrutura das assembleias fitoplanctônicas [5] principalmente para as duas formas de nutrientes e o oxigênio dissolvido. No presente artigo, foi observado que as variáveis mais importantes relacionadas com a previsão de densidade fitoplanctônica foram: nitrato, N-NH₃, OD e DQO. De acordo com a previsão da rede neural, a densidade de fitoplâncton tende a aumentar com elevadas concentrações de OD e nutrientes (nitrato e N-NH₃) e diminuir com elevadas concentrações de DQO, sendo que com essa última a relação não é linear, ou seja, há um limite a partir do qual a diminuição tende a ser acentuada. Esses resultados foram condizentes com outros estudos conduzidos na região e mostram que o desenvolvimento de modelos baseados em RNAs é promissor nessa área de conhecimento e pode ser uma importante ferramenta a ser utilizada pelos gestores da usina em melhorias nas atuais e futuras medidas de gerenciamento e monitoramento da qualidade das águas do reservatório.

4 Conclusão

Através dos bons resultados obtidos pela ferramenta computacional desenvolvida no presente estudo, foi possível avaliar a aplicabilidade das técnicas de inteligência artificial para a previsão da densidade fitoplanctônica a partir de fatores ambientais, e que os mesmos são condizentes com outros estudos disponíveis na literatura vigente. Quanto às modelagens utilizando RNAs, a escolha da arquitetura da rede é um fator importante e influencia no desempenho do modelo, sendo a configuração de RNA com duas camadas ocultas, com 5 e 10 neurônios respectivamente, a que forneceu resultados satisfatórios.

Agradecimentos. Os autores agradecem o apoio e o incentivo da UFABC - Universidade Federal do ABC e também à Itaipu Binacional pela disponibilização dos dados utilizados no desenvolvimento desse artigo.

Referências

- [1] Arruda, N. M. B. de. Avaliação de variáveis de qualidade de água dos reservatórios das usinas hidrelétricas de Foz do Areia, Segredo e Caxias, como instrumento de gestão de bacias hidrográficas. Tese (Doutorado em Engenharia Florestal) - Departamento de Ciências Agrárias, Universidade Federal do Paraná, Curitiba. 2014.
- [2] Boyacioglu, H.; Boyacioglu, H.; Gunduz, O. Application of factor analysis in the assessment of surface water quality in Buyuk Menderes river basin. *European Water*, v. 9/10: p. 43-39. 2005.
- [3] Cunha, G. B. Redes neurais artificiais aplicadas à previsão da incidência de malária no estado de Roraima. Tese (Doutorado em Ciências), Universidade Federal de Uberlândia, Uberlândia. 2010.
- [4] Fornarelli, Roberta, Galelli, Stefano, Castelletti, Andrea, Antenucci, Jason, Marti, Clelia. An empirical modeling approach to predict and understand phytoplankton dynamics in a reservoir affected by interbasin water transfers. *Water Resources Research*. 49. 2013.
- [5] Gemelgo, M. C. P.; Mucci, J. L. N & Navas-Pereira, D. Population dynamics: seasonal of phytoplankton functional groups in Brazilian reservoirs (Billings and Guarapiranga, São Paulo). *Acta Limnologica Brasiliensia*, v. 69, p. 1001-1013. 2009.
- [6] Gentil, R. C., Tucci, A. & Sant'Anna, C. L. Dinâmica da comunidade fitoplanctônica e aspectos sanitários de um lago urbano eutrófico em São Paulo, SP. *Hoehnea*, v.35: 265-280. 2008.
- [7] Haykin, S. Redes Neurais: princípios e prática. Trad. Paulo Martins Engel. 2ª Ed. Porto Alegre: Bookman. 2001.
- [8] Henry, R.; Nunes, M. A.; Mitsuka, P. M.; Lima, N. DE & Casanova, S. M. C. Variação espacial e temporal da produtividade primária pelo fitoplâncton na represa de Jurumirim (Rio Paranapanema, SP). *Rev. Brasil. Biol.* v. 58, p. 571-590. 1998.
- [9] Khan, F.A., Ansari, A.A. Eutrophication An Ecological Vision. *The Botanical Review*, v. 71: 449-482. 2005.
- [10] Maciel, J. N. Assembleias fitoplanctônicas como ferramenta de avaliação da qualidade da água em um braço do reservatório da UHE Itaipu Binacional – Estudo de Longo Período. Dissertação (Mestrado em Energia), Universidade Federal do ABC, Santo André. 2010.
- [11] Lamparelli, M. C. Grau de eutrofia em corpos d'água do estado de São Paulo: avaliação dos métodos de monitoramento. Tese (Doutorado em Ecologia) - Departamento de Ecologia, Universidade de São Paulo, São Paulo. 2004.
- [12] PADISAK, J., BORICS, G., GRIGORSZKY, I. & SOROCZKI-PINTER, E. Use of phytoplankton assemblages for monitoring ecological status of lakes within the Water Framework Directive: The assemblage index. *Hydrobiologia*, v. 553: 1–14. 2006.
- [13] Reynolds, C. S.; Huszar, V.; Kruk, C., Naselli-Flores, L. & Melo, S. Towards a functional classification of the freshwater phytoplankton. *Journal of Plankton Research*. v. 24: 417–428. 2002.

- [14] Ribeiro-filho, R. Relações Tróficas e Limnológicas no Reservatório de Itaipu: uma análise do impacto da biomassa pesqueira nas comunidades planctônicas. 154 p. Tese (Doutorado em Ciências da Engenharia Ambiental), Escola de Engenharia de São Carlos da Universidade de São Carlos, São Carlos. 2006.
- [15] Straskraba, M. & Tundisi, J. G. Gerenciamento da qualidade da água de represas. In: Tundisi, J. G. ed. Diretrizes para o gerenciamento de lagos. São Carlos, *ILEC/EE*. v.9, 280p. 2000.
- [16] Veiga, B. V. Fatores intervenientes na dinâmica do fósforo em ambientes lênticos - Investigação sobre o reservatório de Alagados no Estado do Paraná. 112 f. Tese (Doutorado em Engenharia Civil) - Departamento de Engenharia Hidráulica e Sanitária, Escola Politécnica da Universidade Federal de São Paulo, São Paulo. 2010.
- [17] Wang L, Li H, Zhao C, Li S, Kong L, Wu W, Kong W, Liu Y, Wei Y, Zhu JK, Zhang H. The inhibition of protein translation mediated by AtGCN1 is essential for cold tolerance in *Arabidopsis thaliana*. *Plant Cell Environ* v. 40(1):56-68. 2017.