

XXIV SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

APLICAÇÃO DE REDES NEURAIIS PARA A CLASSIFICAÇÃO E AVALIAÇÃO DO GRAU DE DEGRADAÇÃO DA QUALIDADE DA ÁGUA DE RESERVATÓRIOS RURAIS NO SEMIÁRIDO BRASILEIRO

Maria de Jesus Delmiro Rocha¹ & Francisco de Assis Souza Filho²

Palavras chave: Rede neural multicamadas; Previsão; Fósforo total.

INTRODUÇÃO

Avaliar e prever o comportamento de corpos hídricos por meio de parâmetros físicos e químicos consiste em um potencial instrumento para auxiliar a tomada de decisão no combate aos processos de eutrofização e degradação da qualidade da água. Classificar o grau de degradação da qualidade da água, particularmente, remete primariamente a dois índices mais conhecidos: o Índice de Estado Trófico (IET) e o Índice de Qualidade da Água (IQA) (Lima et al, 2017). Ressalta-se ainda a existência de outros índices com objetivo similar. A utilização de índices de qualidade da água busca identificar uma classificação geral que possibilite entender a condição média em que se encontra a qualidade da água do corpo hídrico.

Pode-se ressaltar, ademais, a Resolução 357/2005 do Conselho Nacional do Meio Ambiente (CONAMA) que delimita valores aceitáveis para uma série de parâmetros físicos e químicos nos corpos hídricos (Brasil, 2005). Assim, a avaliação da classe de degradação do corpo hídrico para parâmetros específicos em relação aos valores limites estabelecidos pelo CONAMA é uma alternativa plausível. O parâmetro concentração de fósforo total (PT), por exemplo, possui relevante impacto para o processo de eutrofização artificial em reservatórios e pode ser melhor explorado quanto a sua resposta de mudança frente a condição e classe de degradação do corpo hídrico.

Entretanto, a complexidade inerente desses sistemas torna esse processo de classificação desafiador. Assim, as Redes Neurais Artificiais (RNA) tornaram-se uma reconhecida ferramenta para a previsão e classificação em diversas áreas, incluindo o setor de recursos hídricos (Velença, 2005). Nesta área as RNA têm sido principalmente utilizadas para descrever o processo de eutrofização em reservatórios (Karul et al., 2000). Estas podem derivar significado de dados complexos, extrair padrões e detectar tendências. Assim, sua aplicação para reconhecimento de padrões da qualidade da água por meio de indicadores físicos dos reservatórios e climáticos pode ser uma ferramenta de auxílio à previsão do grau de degradação do corpo hídrico (Sarkar et al., 2015; Solanki et al., 2015; Dragoi et al., 2018). Ademais, intercalada com as companhas de medição em campo, pode auxiliar na redução de custo do processo de monitoramento dos reservatórios.

A proposta deste trabalho é o desenvolvimento de uma rede neural supervisionada do tipo multicamadas com algoritmo de retro propagação do erro para classificação do grau de degradação da água em corpos hídricos a partir de dados físicos do reservatório e climáticos da região. As classes

1) Mestranda, Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Hidráulica e Ambiental. Av. Mister Hull, bloco 713, Pici, (85) 33669776, mariadelmirochoa@gmail.com

2) Professor, Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Hidráulica e Ambiental. Av. Mister Hull, bloco 713, Pici, (85) 33669776, assis@ufc.br

foram propostas a partir da relação entre a concentração de PT medida no reservatório e o valor limite da resolução CONAMA 357/2005 para esse parâmetro. Os dados utilizados para treinamento e testes da rede foram obtidos a partir de medições regulares realizadas pela Companhia de Gestão dos Recursos Hídricos do Ceará em vinte e dois reservatórios do Estado. A rede treinada e testada poderá prever a condição de degradação da água quanto ao parâmetro fósforo total como: não degradada, leve, baixa, média alta e altíssima.

METODOLOGIA

Área de estudo

A área de estudo abrange as bacias de vinte e dois reservatórios de abastecimento de água monitorados no Estado do Ceará, Brasil, apresentado na Figura 1 e detalhados na Tabela 1. Os dados apresentados na Tabela 1 foram retirados de inventários ambientais levantados para cada reservatório por meio da Companhia de Gestão dos Recursos Hídricos do Estado do Ceará (COGERH). Esses reservatórios estão espalhados nas doze regiões hidrológicas nas quais o Estado do Ceará está dividido para aprimorar a gestão dos recursos hídricos. Suas áreas somadas representam 59,02% da área do estado e uma capacidade total acumulada de 10,19 km³. O reservatório mais raso é o Colina com 12 m de profundidade, o mais profundo é o Castanhão com 71 m. Em média os reservatórios têm profundidade de 23,85 m. Esses reservatórios sustentam a rede que fornece água potável para fábricas, perímetros de irrigação e áreas urbanas.

Figura 1 – Localização dos reservatórios estudados

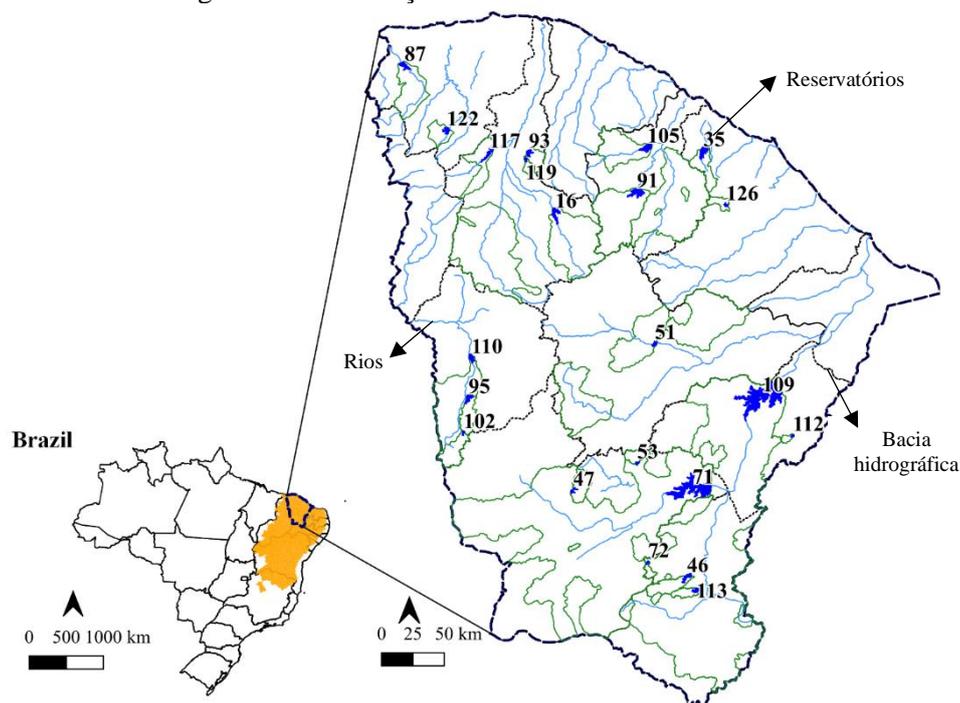


Tabela 1 – Detalhamento dos reservatórios avaliados.

ID	Reservatório	Rio principal	Área da bacia (km ²)	Área média do espelho d'água (km ²)	Profundidade média (km ²)
16	Edson Queiroz	Groaíras	1778	7.90	17.32
35	Sítios Novos	São Gonçalo	446	4.35	10.96
46	Rosário	Rosário	337	3.83	10.40
47	Rivaldo de Carvalho	Rivaldo de Carvalho	318	0.68	9.12
71	Orós	Jaguaribe	24538	61.34	6.51
72	Olho D'água	Machado	72	1.18	12.52
87	Itauna	Timonha	781	11.48	7.30
91	General Sampaio	Curu	1582	10.10	17.54
93	Forquilha	Oficina	191	3.05	7.71
95	Flor do campo	Poti	663	3.82	10.96
102	Colina	Poti	363	1.31	6.00
109	Castanhão	Jaguaribe	44800	123.14	35.50
113	Cachoeira	Caiçara	143	1.92	12.00
116	Banabuiú	Banabuiú	14243	18.86	28.44
117	Ayres de Souza	Jaibaras	1102	6.94	14.45
119	Arrebita	Sabonete	79	1.50	9.10
122	Angicos	Juazeiro	286	5.98	9.45
126	Acarape do Meio	Pacoti	210	1.50	15.04

Dados morfométricos e de qualidade da água

Os dados de concentração de fósforo total foram obtidos a partir de um programa de monitoramento contínuo realizado pela COGERH em que amostras de água do reservatório são coletadas cerca de quatro vezes por ano, a uma profundidade de 0.3 metros próximo à barragem do reservatório ou da estação flutuante de bombeamento, e posteriormente analisadas de acordo com APHA (2005). Os dados morfométricos necessários são o volume do reservatório (m³), o volume percentual do reservatório a área de superfície da água (m²). Calculou-se ainda o parâmetro alfa, definido pela relação entre o volume e o cubo da altura do reservatório. Todos estes dados foram obtidos de CEARÁ (2020.a). A altura evaporada e a velocidade do vento foram quantificadas a partir das normais climatológicas (BRASIL, 2020) das estações mais próximas de cada reservatório. Por fim, como parâmetro espacial de cada reservatório, obteve-se a latitude no centro do barramento dos reservatórios. Todas essas variáveis foram consideradas como potenciais variáveis explicativas para o grau de degradação da qualidade da água.

Resolução CONAMA 357/2020 e classes de degradação

Buscou-se avaliar a qualidade da água e o grau de degradação quanto ao atendimento aos limites estabelecidos pela Resolução CONAMA n° 357/2005 para concentração de fósforo total, considerando Classe II de enquadramento para os corpos hídricos. A partir do valor limite de concentração de 0.03 mg/L para o parâmetro PT estipulado pela resolução para a Classe II, realizou-se a comparação percentual entre o valor da concentração medido em relação a este limite. Pode-se então estabelecer as classes de degradação conforme apresenta a Tabela 2. Ressalta-se a partir da análise da Tabela 2 a existência de uma desproporção na distribuição dos dados disponíveis prevalecendo valores elevados de concentração e, conseqüentemente, classes de maior degradação. Essa desproporção pode incorrer em distorções nos resultados do treinamento de uma rede neural e sua futura aplicação, comprometendo a capacidade preditiva da rede em favor das classes que contém mais amostras. Técnicas de balanceamento podem ser aplicadas, entretanto optou-se por não realizar

tais ajustes uma vez que o grupo de dados abrange um período longo de estiagem. Durante tais períodos reporta-se uma maior degradação da qualidade da água (Lira et al., 2020).

Tabela 2 – Classificação do grau de degradação

Classe	Relação $PT_{\text{medido}}/PT_{\text{classe II}}$	Condição	Total de dados por faixa	Total percentual
0	≤ 1	Não degradada	110	13.4%
1	$1 < x \leq 1.3$	Leve	49	6.0%
2	$1.3 < x \leq 1.6$	Baixa	54	6.6%
3	$1.6 < x \leq 1.9$	Média	46	5.6%
4	$1.9 < x \leq 2.2$	Alta	59	7.2%
5	$x > 2.2$	Altíssima	504	61.3%

Análise de correlação das variáveis do modelo

A análise de correlação objetivou identificar relação significativa que envolva dependência entre duas variáveis de estudo e se as variáveis se apresentam essencialmente independentes com vistas a não impactar a performance do modelo. Ademais, a utilização de múltiplas variáveis explicativas correlacionadas torna-se redundante. Obteve-se então a correlação entre os grupos de variáveis explicativas para cada reservatório avaliando o coeficiente de correlação de Pearson.

Redes neurais artificiais multicamadas (RNA)

As redes neurais multicamadas são caracterizadas pela presença de ao menos uma camada oculta entre as camadas de entrada e saída, com treinamento supervisionado. A topologia e a definição da quantidade de camadas ocultas e o número de nós da rede dependem da classe do problema, das amostras disponibilizadas no treinamento, dos valores de entrada, dos pesos, dentre outros fatores (Da Silva et al., 2010). Pode-se descrever sucintamente que uma rede neural compreende uma estrutura com sinais de entrada, que são as variáveis da aplicação, os pesos sinápticos ponderadores do sinal de entrada, o combinador linear que soma os valores dos sinais de entrada com os pesos sinápticos, a função de ativação que define o intervalo de valores na saída do processamento e a saída apresentando o valor final da rede neural. Adotou-se uma rede neural do tipo multicamadas devido à rápida implementação e pela qualidade de resultados obtidos previamente (Conrads et al., 1999; Young et al., 2001). Sua estrutura compõe uma camada de entrada, duas camadas ocultas e uma camada de saída. O tipo de alimentação da rede é *feedforward* com algoritmo de treinamento de retro propagação do erro (*backpropagation*).

Algoritmos de classificação, funções de ativação e de perda.

Os algoritmos de classificação multiclasse exibem como resultado do processamento a classe mais provável para a qual o grupo de dados de entrada pode direcionar. Cada amostra pode pertencer a uma única classe predefinida. Assim, diante de um problema de qualidade da água, as diversas variáveis de entrada, como por exemplo características morfométricas e climáticas para um reservatório, podem ser melhor interpretadas para determinar uma classificação estabelecida para um corpo hídrico. Redes neurais de classificação, entretanto, necessitam que a camada de saída reproduza apenas uma classe para cada grupo de entrada. Deste modo, existem funções de ativação específicas da camada de saída da rede para tal fim. As funções de ativação são responsáveis pela não linearidade das redes neurais. Esta característica confere maior velocidade na capacidade de aprendizado da rede quanto as relações entre variáveis dependentes e independente. Existe uma diversidade de funções diferentes onde cada uma otimiza uma função matemática (Goodfellow et al., 2016). Para redes de classificação, utiliza-se a função de ativação *softmax* para a camada de saída da rede. Assim, o resultado da rede passa a representar a probabilidade de os dados de entrada levarem a um resultado de saída que pertencer a uma das classes determinadas.

Outro parâmetro essencial à rede, a função de perda sintetiza a complexidade da rede neural indicando o quanto a resposta da rede distancia-se da resposta esperada. Para redes profundas de

classificação, aplica-se a perda de entropia cruzada (*cross-entropy loss*). A busca pelo valor mínimo da função de perda é obtida por meio do cálculo do gradiente, um vetor de derivadas parciais que deve ser igualado a zero ao longo das iterações. Para a rede desenvolvida utilizou-se o método do gradiente estocástico descendente (SGD) que calcula o gradiente através de um batch aleatório de dados. Quanto a função de perda utilizou-se a *Categorical Cross-Entropy*. Essa função de perda é particularmente aplicada para classificação multiclasse.

Treinamento, teste e avaliação de performance

Para o desenvolvimento dos experimentos, os dados foram divididos em grupos de treinamento e teste na proporção de 0.7 e 0.3, respectivamente. A avaliação da performance foi feita para ambos os grupos. Para evitar os desvios de sub ajuste (*underfitting*) e sobreajuste (*overfitting*), a separação dos grupos e a avaliação da performance foi realizada de forma aleatória e iterativa. Uma vez que o resultado da rede é estocástico, a cada iteração há a probabilidade de retorno de um resultado diferente. Assim, para se avaliar a acurácia da rede utilizou um segundo processo iterativo. Assim, cada iteração armazena a acurácia média dos resultados da sub iteração. Por fim, têm-se a média final da acurácia que é utilizada para avaliar os resultados do treinamento e do teste. Com a configuração descrita a rede foi treinada com um total de 225 amostras nas iterações. A Tabela 3 apresenta as características da rede.

Tabela 3 – Características da estrutura da rede neural desenvolvida.

Parâmetro	Valor
Nº de rodadas	225
Nº de neurônios na camada de entrada	20
Nº de neurônios na camada oculta 1	12
Nº de neurônios na camada oculta 2	10
Nº de neurônios na camada de saída	6
Taxa de aprendizagem	0.01

Avaliação do impacto das variáveis em cenários de previsão

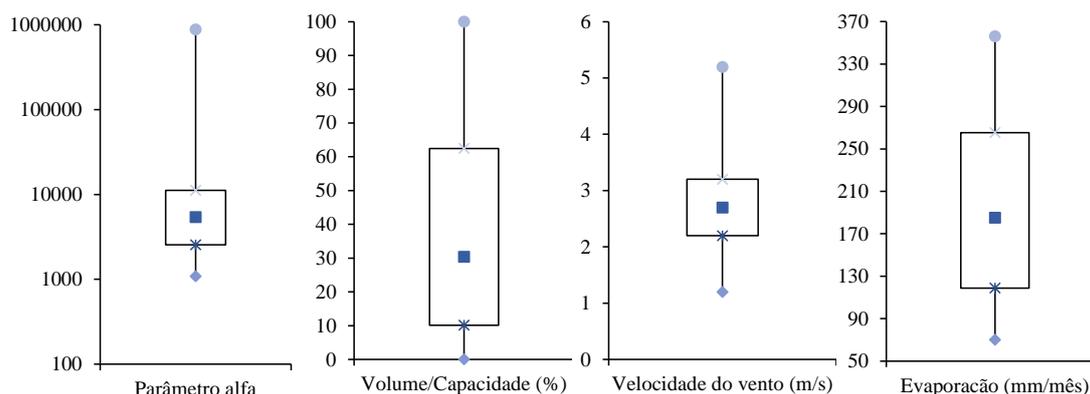
Uma vez com a rede neural definida, definiram-se cenários para avaliação do impacto de variáveis específicas na classe de degradação aplicando a rede treinada para previsão da classe. Avaliou-se o impacto do mês, da velocidade do vento e do volume percentual. Em busca de avaliar essencialmente o impacto da variável de interesse, definiu-se o intervalo de variação mínimo das demais variáveis de $\pm 10\%$ da média para não comprometer a capacidade preditiva da rede. À variável de interesse para teste, a variabilidade foi permitida dentro do intervalo de valores máximo e mínimo dos dados observados.

RESULTADOS

Situação de qualidade da água e característica dos reservatórios

A Figura 2 apresenta as variáveis utilizadas como preditoras das classes adotadas. Foram utilizados ainda como preditoras a latitude dos reservatórios, não apresentada na respectiva figura. Observa-se o intervalo em que essas variáveis oscilaram para os vinte e dois reservatórios estudados e para os dez anos de intervalo de tempo do estudo. Observa-se que o volume percentual dos reservatórios variou de aproximadamente 0%, completamente vazio, a 100%, completamente cheio. Essa grande variabilidade deve-se principalmente ao período de seca prolongada transcorrida durante o período de estudo (Weigand et al., 2020). O parâmetro alfa também apresentou grande variabilidade, o que reforça a diferença, de profundidade ou de volume, entre os reservatórios estudados. Os parâmetros velocidade do vento e taxa evaporativa relacionam-se ao clima na região do reservatório. A evaporação variou de 69.9 mm/mês a 356 mm/mês enquanto a velocidade do vento variou de 1.2 m/s a 5.2 m/s.

Figura 2 – Avaliação das principais variáveis de qualidade da água e da situação hídrica dos reservatórios.



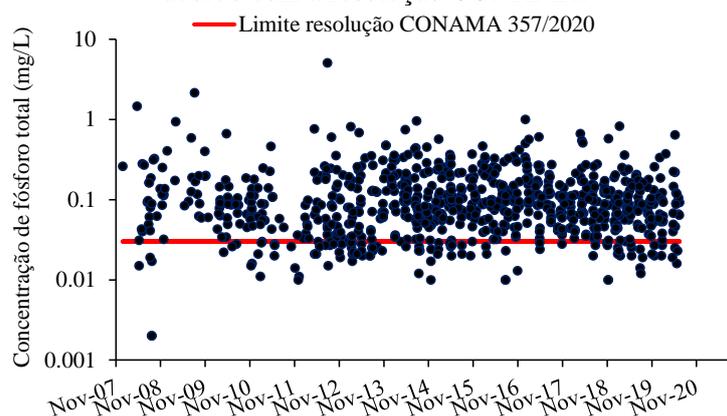
A Tabela 4 apresenta o resumo das análises de correlação performada e do resultado da matriz de correlação entre as variáveis de cada reservatório. Para cada reservatório foi obtida a matriz de correlação entre as variáveis explicativas utilizadas. A partir de então, contabilizou-se o total de pares correlacionados cujo valor do r de Pearson ficou entre as classes apresentadas na Tabela 3. Obteve-se então o percentual que cada grupo representava em relação ao total de pares avaliados. Observa-se que correlações fortes ($r > |0.7|$) foram observadas em 27.4% dos pares testados. Os restantes 72.6% não apresentaram r significativamente forte. Esta primeira análise reforça a independência entre os dados utilizados como variáveis predictoras e sua utilização conjunta para um modelo preditivo.

Tabela 4 – Resultado do coeficiente de correlação de Pearson dos testes de correlação realizados.

Coefficiente de correlação de Pearson	$> 0.9 $	$ 0.7 < r < 0.9 $	$ 0.5 < r < 0.7 $	$ 0.3 < r < 0.5 $	$< 0.3 $
Percentual em relação ao total de análises	5.80%	21.60%	10.20%	26.60%	35.80%

A Figura 3 apresenta os valores medidos da concentração de fósforo total de todos os reservatórios estudados durante o período avaliado e a concentração limite desse parâmetro estabelecida pela resolução CONAMA para reservatórios Classe II. Obteve-se que 86.6% das amostras apresentaram valor superior ao limite estabelecido. Esta análise reforça dois aspectos. Inicialmente, quanto a este limite de qualidade estabelecido pela resolução já se observa que os reservatórios apresentam-se marcadamente em desconformidade. As concentrações do terceiro quartil apresentam-se 5x superior ao valor da resolução. Em segundo, o sistema é naturalmente desbalanceado para classes de degradação mais elevadas. Nessas condições, modelos treinados com tais dados tem maior viés para privilegiar grupos mais representativos.

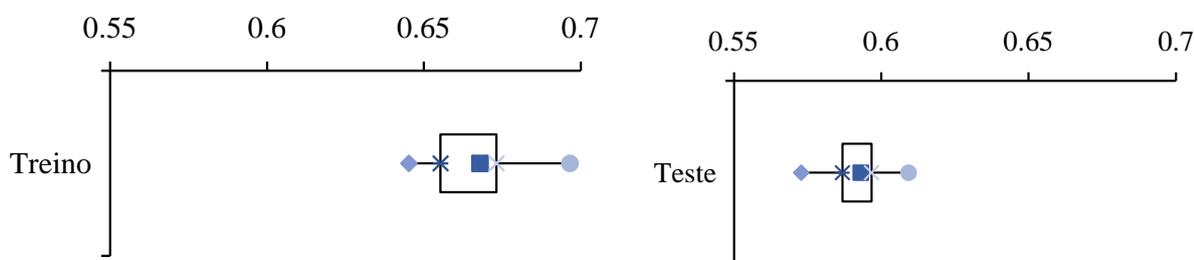
Figura 3 – Grau de degradação da qualidade da água dos reservatórios para o parâmetro fósforo total de acordo com a resolução CONAMA.



Qualidade do treinamento e teste da rede neural

A Figura 4 apresenta a distribuição da acurácia da rede durante as fases de treinamento e teste. Uma vez que o resultado da classificação da rede é estocástico a cada iteração, optou-se por executar o modelo de maneira iterativa e obtendo como métrica a acurácia média das iterações. Deste modo, diversos blocos de iterações foram executados para se obter o diagrama de caixas apresentado na Figura 4. A acurácia representa a porcentagem de elementos classificados corretamente, indica uma performance geral do modelo. Observa-se pela figura que a média para as amostras de treinamento foi de 0.67 e para as amostras de teste de 0.59. As acurácias foram similares para ambos os grupos. Ressalta-se ainda que, a capacidade inferior de predição da rede para as amostras de teste pode ser relativa a maior presença de elementos de classes superiores. Problemas de classificação aplicados à qualidade da água utilizando redes neurais também foram abordados por estudos anteriores. Acurácias de trabalhos anteriores variaram entre 0.27 - 0.98 (Ferreira, 2007), 0.62 - 0.97 (Nepomuceno, 2006), 0.73 - 0.95 (Tanagra, 2006), 0.77 - 0.95 (Melo Filho, 2006). Acredita-se, portanto, que as métricas da rede neste trabalho apresentaram-se satisfatórias.

Figura 4 – Acurácia média das amostras de treinamento e teste



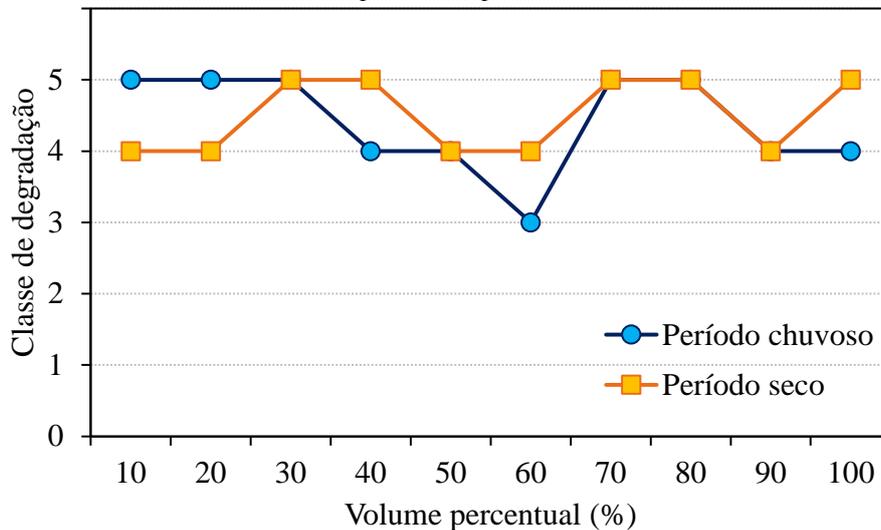
Avaliação dos cenários de previsão

Uma vez com rede treinada e testada, foram testados cenários para avaliar o impacto de algumas variáveis na classe de degradação. A Figura 5 apresenta o primeiro cenário testado em que se avaliou o impacto da variável volume percentual na classe de degradação, subdividindo ainda os dados em período chuvoso e período seco. Observa-se, inicialmente, que para volumes abaixo de 30% os resultados da previsão indicaram a prevalência da classe de degradação 5. A partir desse percentual há um sinal de melhoria na classe, chegando a classe 3 para a faixa de volume percentual em torno de 60%. A partir de então há um aumento na degradação estabilizando na classe 4. Considerando a característica rural com predomínio de cargas de poluição difusa para os reservatórios avaliados, a combinação dos efeitos de aumento do volume pode implicar em duas situações. Para os meses do período chuvoso, inicialmente, o aumento do volume pode levar a consequente diminuição da concentração de fósforo total pelo efeito da diluição. Entretanto, o maior aporte hídrico que favorece o aumento do volume pode carrear maior aporte de nutriente, especialmente em bacias com predomínio de carga difusa. As fontes difusas de poluição para corpos hídricos nas regiões semiáridas são, frequentemente, a principal fonte de nutrientes para os reservatórios durante o período chuvoso (Cavalcante et al., 2018; de Castro Medeiros et al., 2015). Deste modo, pode ocorrer um aumento da concentração nessas condições.

Considerando apenas as previsões para os meses do período seco, observa-se que a degradação é maior e não apresenta padrão de melhoria com aumento do volume. Observou-se que as concentrações no período seco são maiores do que as do período chuvoso e se tornaram continuamente maiores com o avanço dos anos consecutivos de seca. As secas prolongadas têm papel importante na deterioração da qualidade da água devido ao aumento das concentrações de nutrientes (de Lacerda et al., 2018). Além disso, devido à exposição dos reservatórios do semiárido a longos períodos de seca, eles são ainda mais suscetíveis ao aumento da concentração de nutrientes (Esteves, 2011). Assim, há maior probabilidade de ocorrência de classe mais altas. Observa-se que para o

período seco o modelo prevê classes sempre superiores à classe 4. Analisando as elevadas concentrações do período seco, há coerência da resposta da rede com os dados observados.

Figura 5 – Avaliação do impacto da variável volume percentual na classe de degradação para o (a) período chuvoso e para o (b) período seco.



Apresenta-se na Figura 6 o resultado da simulação para o um cenário de análise da variação do mês na classe de degradação. Observa-se um padrão de melhoria na qualidade à medida que avança o primeiro semestre do ano. A classe de degradação varia da classe 5 em janeiro (mês 1) à classe 1 em junho (mês 6). Em seguida, há um aumento significativo à classe de maior degradação, permanecendo uma variação entre as classes 4 e 5 durante todo o segundo semestre. A evolução dos meses do primeiro semestre coincide, usualmente, com a condição de aumento no volume percentual do reservatório. Em concordância com as discussões anteriores, esse processo tem potencial de corroborar para uma diminuição na concentração pelo efeito de diluição do nutriente dado o maior volume do corpo hídrico.

Por fim, a Figura 7 apresenta um cenário em que se avaliou o impacto da variação da velocidade do vento na classe de degradação prevista. As velocidades testadas variaram de 1 m/s a 5 m/s, entretanto, a variabilidade na classe foi pouco expressiva variando entre as classes 4 e 5. Em uma análise qualitativa, o padrão de variação da classe apresenta-se coerente. Maiores velocidades podem impactar em uma maior homogeneização vertical na concentração. Para reservatório profundos, desconsiderando-se então um potencial de ressuspensão, menores concentrações ocorreriam devido a essa mistura na coluna d'água o que implicaria em uma situação menos degradada. Destaca-se ainda que, para os reservatórios do Semiárido Brasileiro, particularmente os reservatórios estudados, possuem um ciclo de mistura diário, o que potencialmente minimiza o efeito acentuado da velocidade do vento na classe de qualidade (Mesquita et al., 2020). De todo modo, a variação entre as classes foi bastante sutil para as diferentes velocidades avaliadas, o que sugere que essa variável demanda uma análise mais profunda para entendimento do seu impacto.

Figura 6 – Avaliação do impacto do mês na classe de degradação.

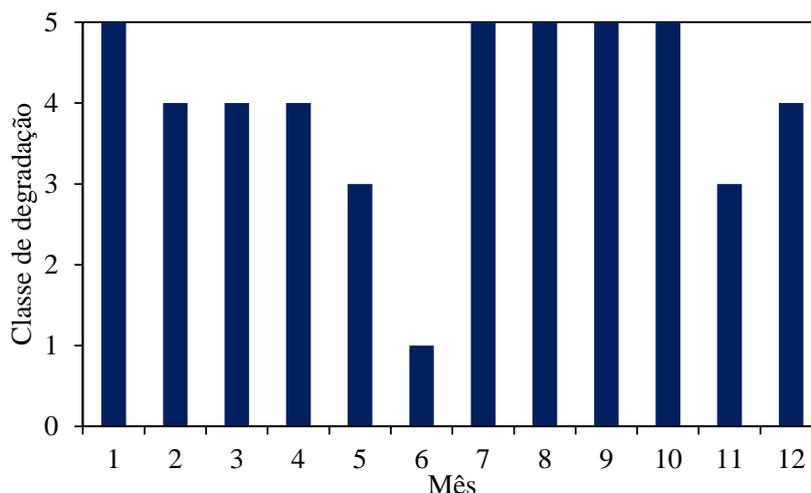
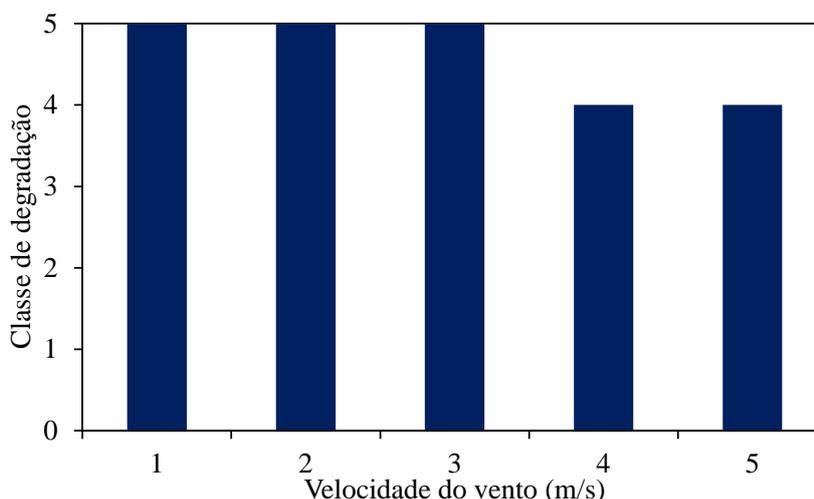


Figura 7 – Avaliação do impacto da variável velocidade do vento na classe de degradação.



CONSIDERAÇÕES FINAIS

Este trabalho objetivou o desenvolvimento de uma rede neural multicamadas para classificação do grau de degradação da água em reservatórios e abastecimento do Estado do Ceará e avaliar as variáveis mais sensíveis nesse processo. Utilizou-se dados físicos do reservatório e climáticos da região como variáveis explicativas. As classes foram propostas a partir da relação entre a concentração de fósforo total medida no reservatório e o valor limite da resolução CONAMA 357/2005 para esse parâmetro. Acredita-se que intercalada com as companhias de medição em campo, redes neurais treinadas e testadas podem ser ferramenta auxiliar processo de previsão do nível de qualidade da água dos reservatórios.

Inicialmente, a análise de correlação entre as variáveis predictoras reforçou a independência entre os dados e sua utilização conjunta para um modelo preditivo. Ademais, a avaliação das concentrações medidas de fósforo total indicou 86.6% das amostras apresentaram valor superior ao limite estabelecido pelo CONAMA de 0.03 mg/L para corpos hídricos Classe II. A rede neural treinada e testada resultou em acurácia média para as amostras de treinamento foi de 0.67 e para as amostras de teste de 0.59.

Para os cenários testados, buscou-se avaliar o impacto de variáveis específicas na classe de degradação. Quanto ao impacto do volume percentual do reservatório, a rede treinada obteve que para volumes abaixo de 30% prevalece a classe de degradação 5. A partir desse percentual há melhoria na classe, chegando a classe 3 para a faixa de volume percentual em torno de 60%. A partir de então há

um aumento na degradação estabilizando na classe 4. A análise do impacto do mês nessa dinâmica resultou que a classe de degradação varia da classe 5 em janeiro à classe 1 em junho. Os resultados obtidos apresentaram-se consistentes e reforçam a aplicação desse tipo de metodologia como ferramenta de auxílio ao entendimento nas questões relativas à qualidade da água.

REFERÊNCIAS

- BRASIL. Ministério do Meio Ambiente: Conselho Nacional de Meio Ambiente, CONAMA. Resolução CONAMA nº 357, de 17 de março de 2005. 2005. Disponível em: <http://www.mma.gov.br>. Acesso em: 04 mar 2020.
- BRASIL. Instituto Nacional de Meteorologia. Normais climatológicas. 2020. Disponível em: <<https://portal.inmet.gov.br/normais>>. Acesso em: 17 jan. 2020.
- CEARÁ. Companhia de Gestão dos Recursos Hídricos: Monitoramento Quantitativo e Qualitativo dos Recursos Hídricos. 2020a. Disponível em: <<http://www.hidro.ce.gov.br>>. Acesso em: 13 fev. 2020.
- CONRADS, P. A. e ROEHL Jr., E. A.; Comparing Physics-Based and Neural Network Models for Simulating Salinity, Temperature, and Dissolved Oxygen in a Complex, Tidally Affected River Basin. Estados Unidos, 1999. Disponível em: http://smig.usgs.gov/SMIG/features_0302/beaufort.html.
- Da SILVA, I. N., SPATTI, D. H., AND FLAUZINO, R. A. (2010). Redes NEurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático. Artliber.
- De LACERDA, L.D., SANTOS, J.A., MARINS, R. V., DA SILVA, F.A.T.F., 2018. Limnology of the largest multi-use artificial reservoir in NE Brazil: The Castanhão Reservoir, Ceará State. An. Acad. Bras. Cienc. 90, 2073–2096. <https://doi.org/10.1590/0001-3765201820180085>
- DRAGOI, E., KOVÁCS, Z., JUZSAKOVA, T., CURTEANU, S., AND CRETESCU, I. (2018). Environmental assesment of surface waters based on monitoring data and neuro-evolutive modelling. Process Safety and Environmental Protection, 120:136–145.
- ESTEVEVES, F. E. Eutrofização Artificial. In: Fundamentos de Limnologia. 3^{ed}. Rio de Janeiro: Interciência, 2011. p. 625-645.
- FERREIRA, A. G. A., 2006. Monitoração de Qualidade de Água com o Uso de Dados Simbólicos. Brasil, 2006.
- KARUL, C., SOYUPAK, S., ÇILESIZ, A. F., AKBAY, N. e GERMEN, E. Case Studies on the Use of Neural Networks in Eutrophication Modeling. Ecological Modelling, 134, pp. 145-152, (2000).
- LIMA, R. S.; ALVES, J. P. H. (2017) Avaliação da qualidade da água dos reservatórios localizados nas bacias hidrográficas dos rios Piauí – Real, utilizando o índice de qualidade da água (IQA). Scientia Plena, v. 13, n. 10, p. 1-2, 30.
- LIRA, C.C.S., MEDEIROS, P.H.A., NETO, I.E.L., 2020. Modelling the impact of sediment management on the trophic state of a tropical reservoir with high water storage variations. An. Acad. Bras. Cienc. 92, 1–18. <https://doi.org/10.1590/0001-3765202020181169>
- MELO FILHO, Aécio Cavalcanti de. ANÁLISE DE QUALIDADE DE ÁGUA UTILIZANDO REDE NEURAL ARTIFICIAL MULTICAMADAS. 2006. 39 f. Monografia (Especialização) - Curso de Ciência da Computação, Universidade Federal de Pernambuco, Recife, 2006.
- MESQUITA, J.B. DE F., LIMA NETO, I.E., RAABE, A., DE ARAÚJO, J.C., 2020. The influence of hydroclimatic conditions and water quality on evaporation rates of a tropical lake. J. Hydrol. 590, 125456. <https://doi.org/10.1016/j.jhydrol.2020.125456>
- NEPOMUCENO, V. S. Classificação de água em reservatórios utilizando um algoritmo de aprendizagem competitiva e não supervisionada. Brasil, 2006.
- SARKAR, A. AND PANDEY, P. (2015). River water quality modelling using artificial neural network technique. Aquatic Procedia, 4:1070–1077.
- SOLANKI, A., AGRAWAL, H., AND KHARE, K. (2015). Predictive analysis of water quality parameters using deep learning. International Journal of Computer Applications, 125(9):0975–8887.
- TANAGRA. TANAGRA - A free DATA MINING software for teaching and research. Disponível em: <http://eric.univ-lyon2.fr/~ricco/tanagra/en/tanagra.html>. Acesso em janeiro de 2006.
- VALENÇA2, M J.S. Prevendo com redes neurais: o estado da arte. Ecological Modelling, in Anais do XVI simpósio Brasileiro de Recursos Hídricos, João Pessoa, Nov. pp. 1-11, 2005. CDROM.
- WIEGAND, M.C., DO NASCIMENTO, A.T.P., COSTA, A.C., LIMA NETO, I.E., 2021. Trophic state changes of semi-arid reservoirs as a function of the hydro-climatic variability. J. Arid Environ. 184. <https://doi.org/10.1016/j.jaridenv.2020.104321>
- YONG, C. K. e LIM, C. M.; An Integrated Water Quality Monitoring System using Artificial Neural Networks. Singapura, 2001. Disponível em: http://www.np.edu.sg/~yck/nn_waterquality.pdf