

Estimação da temperatura da água: um levantamento dos modelos estatísticos para a aplicação em IOT e Tanques de Aquicultura

Estimation of water temperature: a survey of statistical models for application in IOT and Aquaculture Tanks

Estimación de la temperatura del agua: un relevamiento de modelos estadísticos para aplicación en IOT y Tanques de Acuicultura

Recebido: 22/03/2023 | Revisado: 12/04/2023 | Aceitado: 13/04/2023 | Publicado: 18/04/2023

Jheklos Gomes da Silva

ORCID: <https://orcid.org/0000-0002-7741-8849>
Universidade Federal Rural de Pernambuco, Brasil
E-mail: jheklos@gmail.com

Ricardo André Cavalcante de Souza

ORCID: <https://orcid.org/0000-0002-2639-3143>
Universidade Federal Rural de Pernambuco, Brasil
E-mail: ricardo.souza@ufrpe.br

Obionor de Oliveira Nobrega

ORCID: <https://orcid.org/0000-0003-1721-9669>
Universidade Federal Rural de Pernambuco, Brasil
E-mail: obionor.nobrega@ufrpe.br

Resumo

A temperatura da água é uma propriedade física importante para saúde dos ecossistemas aquáticos por afetar a concentração de saturação de oxigênio dissolvido na água e alterar reações químicas e biológicas que pode fazer com que as espécies tenham seu metabolismo, reprodução, crescimento e sobrevivência ameaçada. Portanto, para garantir que a água esteja em conformidade para as produções aquícolas ou para outras áreas que dependam da temperatura, o monitoramento constante da água é essencial. Existem diversos dispositivos que permitem essa medição, no entanto, não estão presentes em todos locais que tenham essa necessidade. Como alternativa, a estimação da temperatura da água pode ser aplicada nesses ambientes. O objetivo deste estudo é realizar um mapeamento sistemático da literatura que apresente uma revisão dos modelos estatísticos utilizados na estimação da temperatura da água em rios. Diversos modelos estatísticos têm sido empregados para esse fim em diversas partes do mundo, incluindo o Brasil. Este mapeamento visa identificar quais modelos foram utilizados, bem como realizar comparações e análises críticas sobre os usos e avaliações desses modelos.

Palavras-chave: Modelos estatísticos; Temperatura da água; Aquicultura.

Abstract

Water temperature is an important physical property for the health of aquatic ecosystems because it affects the concentration of oxygen saturation dissolved in the water and alters chemical and biological reactions that can cause species to have their metabolism, reproduction, growth and survival threatened. Therefore, to ensure that water is compliant for aquaculture production or other area that depend of the temperature, the constant water monitoring is essential. There are several devices that allow this measurement, however, they are not present in all places that have this need. Alternatively, water temperature estimation can be applied in these environments. The objective of this study is to conduct a systematic literature mapping that presents a review of statistical models used to estimate water temperature in rivers. Several statistical models have been used for this purpose in various parts of the world, including Brazil. This mapping aims to identify which models have been used, as well as to perform comparisons and critical analysis of the uses and evaluations of these models.

Keywords: Statistical models; Water temperature; Aquaculture.

Resumen

La temperatura del agua es una propiedad física importante para la salud de los ecosistemas acuáticos, ya que afecta la concentración de saturación de oxígeno disuelto en el agua y altera las reacciones químicas y biológicas que pueden amenazar el metabolismo, la reproducción, el crecimiento y la supervivencia de las especies. Por lo tanto, para garantizar el cumplimiento del agua para las producciones aquícolas u otras áreas dependientes de la temperatura, es esencial el monitoreo constante del agua. Existen varios dispositivos que permiten esta medición, sin embargo, no están presentes en todos los lugares que tienen esta necesidad. Alternativamente, la estimación de la temperatura del agua se puede

aplicar en estos entornos. El objetivo de este estudio es realizar una revisión sistemática de la literatura que presente un mapeo de los modelos estadísticos utilizados para estimar la temperatura del agua en ríos. Se han utilizado diversos modelos estadísticos para este fin en varias partes del mundo, incluyendo Brasil. Este mapeo tiene como objetivo identificar cuáles modelos se han utilizado, así como realizar comparaciones y análisis críticos de los usos y evaluaciones de estos modelos.

Palabras clave: Modelos estadísticos; Temperatura del agua; Acuicultura.

1. Introdução

A temperatura da água é um fator importante devido ao seu significado para a saúde dos organismos aquáticos. Os peixes são exotérmicos e dependem da temperatura dentro de sua faixa de tolerância (Mcgrath et al., 2016). As mudanças climáticas globais causadas por aumentos nas concentrações de gases e efeito estufa provavelmente aumentarão a temperatura do ar e alterarão os padrões de precipitação e outros parâmetros climáticos (Ali et al., 2015). Essas mudanças dificultarão o controle térmico das águas com isso, sem um monitoramento área como a aquicultura será impactada nas criações das espécies. Uma das características associada ao sucesso da produção é a temperatura da água, pois ela influencia diretamente no metabolismo animal ao condicionar a ingestão de alimentos e, conseqüentemente interfere no desempenho dos peixes cultivados (Frasca-Scorvo et al., 2001; Moura et al., 2007). A temperatura pode influenciar muitos processos químicos e biológicos, como o oxigênio dissolvido, além dos efeitos mais óbvios nos organismos aquáticos que são a taxa de crescimento e sua sobrevivência (Larnier et al., 2010). Diversos dispositivos são utilizados para medir a temperatura da água, no entanto, existe a necessidade de fazer a estimativa quando não há um dispositivo ou quando por algum motivo este venha a falhar.

Torna-se importante encontrar um meio de estimar a temperatura da água por meio de técnicas e modelos que possibilitem essa ação. A medição contínua da temperatura da água seria uma ferramenta para o monitoramento e gestão da qualidade da água. Contudo, na maioria dos casos não é realizada essa medição. Em contrapartida, variáveis meteorológicas como a temperatura do ar e radiação solar, são medidas regularmente em muitos locais (Jeppesen & Iversen, 1987). Com essas variáveis torna-se possível estimar a temperatura da água.

Diversos modelos já foram desenvolvidos para estimar a temperatura da água em ambiente de rios, onde algumas espécies são sempre impactadas pela mudança climática do local. De forma geral, existem modelos determinísticos, que são baseados no balanço de energia e necessitam de muitos dados de entrada e capacidade computacional. Como alternativa, métodos estatísticos ou estocásticos buscam correlacionar a temperatura da água com outra variável e obter uma descrição matemática dessa relação (Colomno & Mannich, 2019). As abordagens estatísticas por serem modelos simples têm sido usados com bons resultados para modelar a temperatura média da água e que muitas vezes requer menos dados de entrada (geralmente temperatura do ar) ou mais variáveis independentes (Ahmadi-Nedushan et al., 2007).

Como forma de compreender o estado da arte em relação à estimativa da temperatura da água, seus principais modelos, e quais são os mais simples aplicados, e como eles são usados, este trabalho realiza um Mapeamento Sistemático da Literatura (MSL). Segundo Petersen et al. (2008), o objetivo do MSL é ter uma visão geral sobre o que está acontecendo no mundo em determinado assunto. Petersen et al. (2008) também define o mapeamento como uma diretriz bem elaborada para apresentar resultados pertinentes aos estudos de certa área. Além desta seção introdutória, o artigo é organizado nas seguintes seções. Apresenta-se na Seção 2 a execução do mapeamento e seus principais passos. Na Seção 3 traz os principais resultados do estudo. Em seguida na seção 4, é realizada a discussão dos resultados. E por fim na Seção 5 são discutidas as considerações finais.

2. Mapeamento Sistemático da Literatura

O mapeamento sistemático da literatura nesta pesquisa, é apoiado pelas diretrizes e etapas de Petersen et al. (2008). O principal objetivo de um estudo do MSL é fornecer uma visão geral de um assunto e identificar a quantidade e o tipo de pesquisa

e os resultados disponíveis nela. (Petersen et al., 2008).

2.1 Definição do Escopo do Mapeamento

Nesta etapa, foi elaborado um protocolo (Quadro 1) contendo as questões de pesquisa e as estratégias que foram feitas nas buscas com o objetivo de iniciar o processo. O objetivo é identificar quais os estudos primários mais relevantes que argumentam sobre como medir a temperatura da água por meio de dados estatísticos.

Quadro 1 – Protocolo para o Mapeamento Sistemático da Literatura.

Questão de Pesquisa: 1. Quais as abordagens utilizadas para estimar a temperatura da água através de modelos estatísticos? 2. Quais modelos estatísticos são mais utilizados com melhores desempenhos?	
Estratégia de Busca	
Bases de Dados Científicas	Equipe Executora
IEEE Xplore Digital Library; Springer Link; ScienceDirect; Scopus; Web of Science; Taylor & FrancisOnline; researchgate; Emprapa Publicações.	<ol style="list-style-type: none"> 1. Estudante de pós-graduação; 2. Professor orientador; 3. Professor coorientador.
Anos de Publicação	2003 a 2022
Keywords	Palavras-chave
"water temperature", "statistical models temperature", "IOT", "aquaculture water temperature", "water temperature estimation", "water temperature predictions", "water temperature Neural Networks", "Water Temperature Forecasting"	"temperatura da água", "temperatura dos modelos estatísticos", "IOT", "temperatura da água da aquicultura" estimacão da temperatura da água, "previsões da temperatura da água" "temperatura da água Redes Neurais", "Previsão da Temperatura da Água"
Método de Execução da Busca	
<ol style="list-style-type: none"> 1) Pesquisar nas bases de dados através da <i>string</i> de busca (busca automática); 2) Analisar os títulos e resumos dos Estudos Primários (EP) retornados nas buscas e selecionar aqueles que atendem os critérios de inclusão e questão de pesquisa; 3) analisar os estudos que citam o estudo relacionado (<i>backward snowballing</i>); 4) Analisar o corpo do texto dos estudos selecionados e aplicar os critérios de qualidade para identificar os aceitos e rejeitados no contexto do mapeamento sistemático da literatura. 	

Fonte: Autores.

Uma das etapas mais importantes no escopo apresentado no Quadro 1 foi a formulação da questão de pesquisa, que proporcionou o ponto de partida para a estratégia de busca em diversas bases e o desenvolvimento de palavras-chave. Assim, foi possível planejar o método de busca a ser executado.

2.2 Busca por Estudos Primários

Nesta etapa, as buscas dos estudos foram executadas nas bases de pesquisas a fim de encontrar estudos relacionados com a questão de pesquisas. Os resultados trouxeram os estudos primários mais relevantes e que responderam à Questão de pesquisa. O desenvolvimento da *String* (Quadro 2) se deu durante as buscas a partir das palavras-chave nos idiomas português e inglês de acordo com a questão de pesquisa, utilizando os conectores lógicos OR e AND, retornando 281 EP na execução da *String*.

Quadro 2 – String de Busca da Pesquisa.

<i>"water temperature" AND "statistical models" OR IOT AND aquaculture AND estimation AND predictions AND Neural Networks OR Water Temperature Forecasting</i>	"temperatura da água" E "modelos estatísticos" OU IOT E aquicultura E estimação E previsões E Redes Neurais OU Previsão da Temperatura da Água
--	--

Fonte: Autores.

Observa-se que a *String* de busca foi elaborada tanto em português quanto em inglês com o objetivo de identificar estudos realizados por pesquisadores não somente no Brasil, mas em diversos outros países.

2.3 Extração de Dados

Uma vez executada, iniciou-se o estágio da extração de dados para selecionar os EP que foram retornados de acordo com as informações obtidas nele. Além disso, foi utilizado os critérios de exclusão: EP não apresenta argumentos relacionado a medir a temperatura da água através de cálculos estatísticos; e EP não apresenta argumentos relacionado a medir a temperatura utilizando redes neurais; EP não relacionado ao tema da pesquisa; EP repetido; e EP não é um artigo completo. Além disso, foram eliminados os estudos que não tinham no seu título “temperatura da água” o que levou a 86% dos estudos serem eliminados pois não se tratava a respeito de estimação da temperatura da água.

Além do título foi feita a leitura do resumo dos EP e também aplicados os critérios de exclusão. O quantitativo dos estudos selecionados neste estágio é apresentado a seguir (Quadro 3) por base de pesquisa e ano de publicação.

Quadro 3 – Quantidade de EP selecionados na etapa de Extração de Dados.

Base de busca	Quantidade	Ano de Publicação	Quantidade
web of science	18	2003	1
Scopus	6	2007	2
IEEE	3	2009	1
Sciencedirect	5	2010	2
Springerlink	2	2012	3
Taylor&FrancisOnline	1	2013	5
EmprapaPublicações	1	2014	3
researchgate	1	2015	2
Total	37	2016	5
		2017	2
		2018	2
		2019	2
		2020	2
		2021	3
		2022	2
		Total	37

Fonte: Autores.

Conforme apresentado no Quadro 3, foram selecionados estudos dos últimos 20 anos, sendo a maioria proveniente de bases de dados que possibilitam a realização de buscas avançadas, com o intuito de selecionar os estudos mais relevantes.

2.4 Análise e Síntese

Nesta etapa, foram determinados e aplicados critérios qualitativos (CQ) (Quadro 4) que nortearam o estudo qualitativo dos EP.

Quadro 4 – Avaliação da Qualidade.

Crítérios de Qualidade
<ul style="list-style-type: none">• CQ1. EP utiliza alguma abordagem para estimar a temperatura da água semanais ou diárias?• CQ2. EP apresenta de forma apropriada os cálculos e métodos para determinar a temperatura?• CQ3. EP demonstra conteúdo que pode ajudar no problema proposto nessa pesquisa?• CQ4. EP Utiliza modelo com dados de entrada com poucas variáveis (temperatura ar)?

Fonte: Autores.

Importante ressaltar que cada critério estabelecido teve como finalidade a seleção de estudos que apresentassem a possibilidade de estimar a temperatura da água de forma objetiva, utilizando dados de entrada com variáveis possíveis de serem obtidas, como dados meteorológicos, por exemplo.

Baseado nos critérios definidos, foi possível estabelecer aceitações para aqueles que apresentassem relações com a questão de pesquisa através da leitura de cada um deles. Cada CQ tem um valor de 1 índice de aceitação (IA). A estratégia para a seleção foi estabelecer as condições de atende (AT) e não atende (NA). Os artigos aceitos (AA) foram aqueles que tiveram o IA maior ou igual a 3, e os artigos rejeitados (AR) foram os que tiveram o IA menor que 3. O Quadro 5 apresenta os artigos avaliados com os resultados de cada CQ.

Quadro 5 – Avaliação qualitativa dos EP.

ID	Referência	CQ1	CQ2	CQ3	CQ4	IA	Resultado
01	(Benyahya et al., 2013)	AT	AT	AT	AT	4	AA
02	(Piccolroaz et al., 2016)	NA	AT	NA	NA	2	AR
03	(Cara et al., 2013)	NA	NA	NA	AT	1	AR
04	(Colombo et al., 2019)	AT	AT	AT	AT	4	AA
05	(Yearsley, 2012)	NA	AT	NA	NA	1	AR
06	(Ali et al., 2015)	AT	AT	AT	NA	3	AA
07	(Caldwell et al., 2014)	AT	NA	NA	NA	1	AR
08	(Ferchichi et al., 2022)	AT	AT	NA	NA	2	AR
09	(Mcgrath et al., 2016)	AT	NA	NA	AT	2	AR
10	(Larnier et al., 2010)	AT	AT	NA	AT	3	AA
11	(Caldwell et al., 2013)	AT	AT	AT	NA	3	AA
12	(Ahmadi-Nedushan et al., 2007)	AT	AT	AT	AT	4	AA
13	(Laanaya et al., 2017)	AT	AT	AT	AT	4	AA
14	(Letcher et al., 2016)	AT	AT	NA	NA	2	AR
15	(Merran & Patterson, 2014)	AT	NA	NA	AT	2	AR
16	(Sahoo et al., 2009)	AT	AT	NA	AT	3	AA
17	(Zhu et al., 2020)	AT	AT	AT	AT	4	AA
18	(Heddam et al., 2020)	AT	AT	AT	AT	4	AA
19	(Zhu et al., 2018)	AT	AT	NA	AT	3	AA
20	(Toffolon & Piccolroaz, 2015)	AT	AT	NA	NA	2	AR

21	(Vassilis et al., 2002)	NA	AT	NA	AT	2	AR
22	(Piccolroaz et al., 2014)	NA	AT	AT	AT	3	AA
23	(Tasnim et al., 2021)	AT	AT	NA	NA	2	AR
24	(Harvey et al., 2011)	AT	AT	AT	AT	4	AA
25	(Saeed et al., 2016)	AT	AT	AT	NA	3	AA
26	(Sun & Daoliang, 2012)	NA	AT	AT	NA	2	AR
27	(Liu & Chen, 2012)	AT	AT	AT	NA	3	AA
28	(Wenxian et al., 2010)	NA	AT	AT	NA	2	AR
29	(Mohr et al., 2021)	NA	NA	NA	AT	1	AR
30	(Zhu et al., 2019)	AT	AT	AT	AT	4	AA
31	(Jiang et al., 2022)	AT	AT	NA	NA	2	AR
32	(St-Hilaire et al., 2012)	AT	NA	NA	NA	1	AR
33	(Zhu et al., 2018)	AT	AT	NA	AT	3	AA
34	(Rabi et al., 2015)	AT	AT	AT	AT	4	AA
35	(Toffolon et al., 2015)	AT	AT	NA	AT	3	AA
36	(Jeong et al., 2016)	AT	AT	AT	AT	4	AA
37	(Pike et al., 2013)	AT	AT	NA	NA	2	AR

Fonte: Autores.

No âmbito deste estudo, foi relevante designar um número de identificação (ID) para cada um dos EP selecionados, o que viabilizou a criação de um repositório desses estudos para consultas futuras, identificando-os de maneira mais eficaz.

3. Resultados

Nessa seção são apresentados o estudo aprofundado dos 37 artigos selecionados para o mapeamento sistemático. O Quadro 6 apresenta o panorama dos EP selecionados e o resultado dos aceitos e rejeitados conforme foram analisados.

Quadro 6 – Panorama dos EP analisados.

Etapa	EP analisados	EP aceitos	EP rejeitados
Extração de Dados	281	37 (14%)	244 (86%)
Análise Qualitativa	37	20 (55%)	17 (45%)

Fonte: Autores.

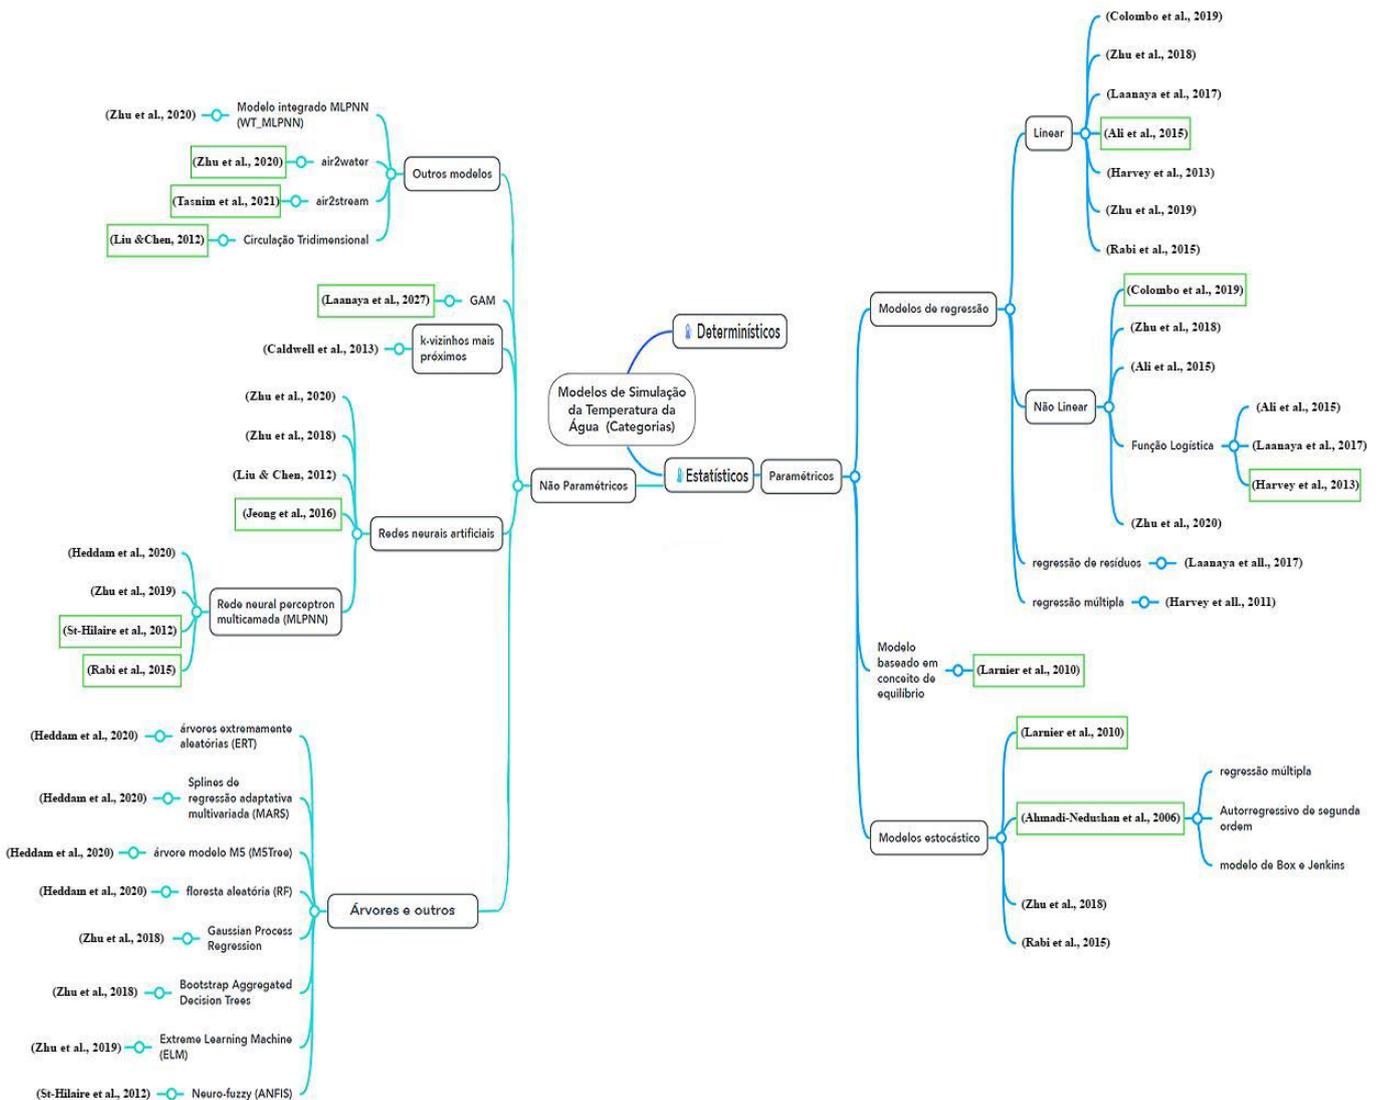
Observa-se que, na análise qualitativa, 45% dos estudos potencialmente relevantes foram rejeitados devido à falta de conformidade com a maioria dos critérios de qualidade estabelecidos. Para tomar essa decisão, foi realizada uma leitura completa de cada estudo que foram aceitos na extração de dados.

Com o aprofundamento dos estudos analisados foi possível elaborar um mapa mental (Figura 1), com o intuito de organizar e estruturar os principais assuntos descritos em cada EP. Os mapas mentais são ferramentas que possibilitam representações da organização do pensamento, de forma livre ou mais elaborada, através de relações entre conceitos, hierarquicamente organizados (Cordovil, 2018).

No mapa mental desse estudo, foi feita uma revisão esquemática das categorias dos modelos de temperatura da água e seus respectivos autores que utilizaram as abordagens encontradas nas análises dos EP selecionados, os autores em destaque verde são os que indicaram o melhor desempenho do modelo nos que estão ligados. A partir disso os modelos foram agrupados

em: Estatísticos – Utilizados nos EP recomendado e usados nas literaturas por terem simples exigências mínima; Determinísticos – descrito no mapa mental apenas para indicar as duas categorias pois apenas foram citados nos estudos não sendo possível utilizá-los porque são complexos e bastante exigentes em termo de dados que segundos os autores geralmente não estão disponíveis. Os modelos estatísticos são subdivididos também em duas categorias: Paramétricos – utilizam modelo estatístico parametrizado; Não paramétricos – A estrutura do modelo não é especificada a priori, mas sim determinada a partir de dados (Benyahya et al., 2013). Os modelos paramétricos também são divididos em categorias: Regressão – usados para modelar a temperatura da água em função de (geralmente temperatura do ar) ou outras variáveis independentes subdividido também em Regressão Linear e Regressão não Linear; Estocásticos – frequentemente baseados em funções estatísticas lineares em que geralmente a única informação necessária é a temperatura do ar (Rabi et al., 2015). Os modelos não paramétricos podem ser divididos também em: Redes Neurais Artificiais – uma estrutura matemática capaz de descrever relações não lineares complexas entre entrada e saída. (Benyahya et al., 2013); K-Vizinhos mais próximos, um método que consiste em encontrar, para um determinado ponto no tempo, um pequeno número de vizinhos mais próximos desse valor, e a previsão é estimada com base nesses vizinhos. Foram encontrados também outros tipos de modelos, como os de árvores.

Figura 1 – Mapa Mental com as categorias de modelos e seus respectivos autores.



Fonte: Autores.

Os EP considerados aprovados estão descritos no Quadro 7 com suas principais contribuições através de uma síntese que relata quais modelos foram utilizados e quais obtiveram melhores resultados.

Quadro 7 – EP analisados pelos critérios qualitativos.

ID	Síntese da Contribuição
1	Forneceu uma visão geral dos modelos estatísticos de temperatura da água existentes com foco nos modelos estáticos mostrando a sua relatividade simplificada e exigência de dados relativa mínima, além de fazer uma comparação entre as vantagens e desvantagens de cada modelo dependendo do problema e da disponibilidade de dados. Destacou que os modelos estocásticos tem um bom desempenho quando a temperatura do ar é o único dado disponível quando é realizado em intervalo de tempo diário.
4	Explorou formas para estimar a temperatura da água, tendo como correlação a temperatura do ar e água. O estudo utilizou regressões linear e não linear, demonstrou um modelo determinístico simplificado além de utilizar um software SWAT que tem uma equação para estimar a temperatura da água. Por fim, mostra que nesse estudo para o rio Passaúna, a utilização da média móvel de 4 dias teve um melhor ajuste das regressões e que a linear teve o melhor ajuste, independente do intervalo de dias que foi utilizado no cálculo da média.
6	Fez um estudo entre a relação da temperatura do ar-água em uma pequena lagoa aquática com o objetivo de avaliar o impacto das mudanças climáticas em diferentes atributos da lagoa. O estudo fez uma simulação da temperatura da água superficial diariamente, semanalmente, mensalmente. Analisou dados de temperatura da água e do ar de 5 anos, e avaliou dois modelos estatísticos paramétricos. Modelo de regressão linear simples (SLR) e regressão logística não linear de quatro parâmetros (NLR). O modelo de regressão simples apresentou melhor desempenho em escalas de tempo semanais e mensais, para escalas de tempo diárias o erro foi considerado relativamente alto.
10	Utilizou e avaliou a eficiência de dois modelos estatísticos para prever a temperatura da água: modelo baseado em conceito de equilíbrio e os modelos estocásticos autorregressivos com o objetivo de avaliar a influência climáticas na temperatura da água do rio verificando se a temperatura do ar é o principal fator que influenciou o regime térmico do rio nas últimas duas décadas. Ambos os modelos mostraram um bom desempenho ao modelar as temperaturas médias diárias da água para rios grandes, com erro médio quadrático para temperaturas acima de 20°.
11	Desenvolveu uma estrutura de modelagem estatística para prever a temperatura diária e horárias. Utiliza dados 1916-2006. Acoplou um modelo linear generalizado na escala de tempo diária com um algoritmo de reamostragem k-vizinho mais próximo que permite a desagregação de valores diários para estimativas horárias de temperatura do fluxo.
12	Comparou a eficiência de vários modelos estocásticos para prever a temperatura média diária da água usando apenas a temperatura do ar como variável exógena, utilizando dados do rio Moisie, além de explorar a possibilidade de incluir mais uma variável a vazão como variáveis independentes adicionais em modelos estocásticos. Os modelos utilizando apenas a temperatura do ar foram: um modelo de regressão múltipla, um modelo autorregressivo de segunda ordem e um modelo Box e Jenkins. O modelo auto regressivo de segunda ordem teve melhor resultado. Para combinar com a vazão do rio e a temperatura do ar, uma metodologia estatística usando regressão é proposta e mostrou uma pequena melhora em relação aos três primeiros que não incluíram índices de vazão.
13	Avaliou um modelo aditivo generalizado não paramétrico de temperatura de água (GAM) com base na temperatura média diária do ar e na vazão média do rio e fez uma comparação com três modelos: modelos logísticos, de regressão de resíduo e de regressão linear. O GAM teve um desempenho melhor entre os outros. O modelo de regressão de resíduos teve melhor resultado do que o logístico, e o modelo linear foi mais adequado do que o de regressão de resíduo e logístico.
16	Desenvolveu um modelo de redes neurais artificiais, um modelo de regressão linear múltipla e algoritmos dinâmicos não lineares e os examinou para prever a temperatura da água do córrego usando variáveis meteorológicas disponíveis, fez a comparação e sugeriu o melhor modelo otimizado. A eficiência de desempenho de IGA-4BPNN foi o mais alto entre todos os algoritmos.
17	Desenvolveu dois modelos (MLPNN) de redes neurais e (WT_MLPNN). Eles foram comparados com dois outros modelos amplamente utilizados. Air2water e um modelo de regressão não linear. Os resultados mostram que o air2water tem o melhor desempenho, seguido pelo (WT_MLPNN), (MLPNN) e o modelo de regressão não linear que teve o pior desempenho.
18	Compara uma nova família de algoritmos de aprendizado de máquina com o modelo air2stream. Os modelos construídos foram: as árvores extremamente aleatórias (ERT), as <i>splines</i> de regressão adaptativa multivariada (MARS), a árvore modelo M5 (M5Tree), a floresta aleatória (RF) e a rede neural <i>perceptron</i> multicamada

	(MLPNN). Utilizando a temperatura do ar como variável de entrada. Os resultados mostraram que o modelo air2stream superou todos os outros modelos de aprendizado de máquina.
19	Estimou a temperatura diária do rio através do desenvolvimento de três modelos padrão: regressão linear, regressão não linear e modelos estocásticos. E três modelos de aprendizagem de máquina: <i>Artificial Neural Network</i> (ANN), <i>Gaussian Process Regression</i> (GPR) e <i>Bootstrap Aggregated Decision Trees</i> (BA-DT). Os resultados mostraram que o modelo estocástico superou os modelos linear padrão e os modelos de aprendizado de máquina, superaram o modelo estocástico
22	Desenvolveu um modelo simples baseado em física Air2Water, para estimar a temperatura da água a partir da temperatura do ar. Os resultados mostram que o modelo representa uma boa alternativa para os modelos baseados em processos completos.
24	Desenvolveu modelos de regressão para prever a temperatura média, máxima e mínima da água e a concentração de oxigênio dissolvido nas escalas de tempo mensal, semanal e diária. Regressão linear, dois modelos logísticos não lineares usando a temperatura do ar e regressão múltipla usando temperatura do ar e o nível de estágio. O primeiro modelo logístico foi melhor que o modelo linear ao lidar com temperaturas máximas e mínimas da água. O modelo de regressão múltipla não supera o modelo logístico.
25	Comparou o desempenho de algumas técnicas de computação suave, para prever temperaturas horárias da água do lago. Usando um conjunto de dados de alguns meses do ano 2008. A técnicas foram: programação de expressão gênica (GEP), sistema de inferência <i>neurofuzzy</i> adaptativo (ANFIS) e redes neurais artificiais (RNAs). Os resultados demonstraram que o GEP forneceu tendências razoavelmente melhores em diferentes profundidades.
27	Usou um modelo de rede neural artificial (RNA), e um modelo de circulação tridimensional para prever a temperatura da água do lago. Os resultados simulados foram comparados e mostraram que o modelo de circulação tridimensional, fornece uma melhor precisão da temperatura da água.
30	Desenvolveu um modelo baseado em <i>Extreme Learning Machine</i> (ELM) para prever a temperatura diária da água de rios. Utilizou como entrada A temperatura do ar (T_a), a vazão (Q) e o dia do ano (DOY). E comparou com modelos de rede neural multicamada <i>perceptron</i> (MLPNN) e regressão linear múltipla simples (MLR). Três cenários foram testados: 1. Usando apenas a temperatura do ar; 2. Usando a temperatura ar e vazão e 3. Usando as duas primeiras e a temperatura do dia. Os resultados mostraram que a inclusão de três produziu a melhor precisão. Além disso, os modelos ELM e MLPNN superaram o modelo MLR, foi concluído que no geral o modelo ELM pode ser usado para previsão de temperatura da água do rio.
33	Foi desenvolvido um modelo de rede neural <i>perceptron</i> multicamadas (MLPNN) e três modelos sistemas de inferência neuro-fuzzy adaptativos (ANFIS). algoritmo de agrupamento <i>fuzzy c-mean</i> (ANFIS_FC), ANFIS com método de partição de grade (ANFIS_GP) e ANFIS com método de agrupamento subtrativo (ANFIS_SC), foram implementados para simular a temperatura diária da água do rio. 1. usando apenas a temperatura do ar (T_a), 2. (T_a) e vazão do rio (Q) e 3. (T_a , Q) e os componentes do calendário gregoriano (CGC) como preditores. Os resultados da modelagem mostraram que a inclusão de três entradas como preditores rendeu a melhor precisão de modelagem entre todos os modelos desenvolvidos. Além disso, o modelo MLPNN foi geralmente o que apresentou os melhores desempenhos.
34	Analisou modelos de regressão linear, modelagem estocásticas e modelagem de redes neurais <i>feedforward</i> de <i>perceptron</i> multicamadas (MPL), para modelar a temperatura diária da água do rio usando apenas a temperatura do ar como parâmetro analisando a relação da temperatura média do ar e diária da água coletadas em alguns pontos do rio. Os resultados mostraram que o modelo estocástico é melhor que o modelo de regressão linear e os modelos MPL superam os modelos estocásticos.
35	Formulou versões do modelo air2stream para prever a temperatura média diária da água do rio em função da temperatura do ar e da vazão.
36	Apresentou um modelo de previsão baseado em rede Neural Artificial (RNA) para a temperatura da água do rio, projetado para facilitar a previsão em tempo real. Foi utilizado apenas dados de previsão do tempo (temperatura do ar e precipitação) que pode facilitar a previsão automatizada e em tempo real da temperatura da água.

Fonte: Autores.

As principais contribuições descritas no Quadro 7 consistem na apresentação dos modelos utilizados pelos autores, nas variáveis meteorológicas empregadas e nos modelos que apresentaram melhor desempenho na validação em relação à estimativa da temperatura da água dos rios.

4. Discussões

Nesta seção são apresentadas as análises dos resultados encontrados para responder à questão de pesquisa descrita diante dos trabalhos que foram selecionados, com a proposta de mostrar abordagem para estimar a temperatura da água através de métodos estatísticos. Diante disso, foi possível identificar diversas categorias de modelos estatísticos capazes de prever a temperatura da água em escalas semanais, diárias e mensais e alguns anuais, utilizando mínimo dados de entrada (temperatura do ar) e em alguns casos outras variáveis independentes.

A maioria dos estudos não utilizam apenas um modelo de temperatura da água, eles fazem uma comparação de resultados e mostram quais tiveram um melhor desempenho para um determinado rio e uma escala de tempo. Os dados coletados para variáveis de entradas foram de estações próximas dos rios, no entanto, muitas vezes a falta de dados em alguns períodos de tempos foi um desafio para alguns pesquisadores por deixarem algumas lacunas prejudicando uma melhor eficiência na estimação, vale ressaltar também que a temperatura do ar foi destacada como preditor mais importante para a previsão da temperatura da água.

Diante dos resultados do mapeamento sistemático, com resposta à questão de pesquisa formulada em relação aos modelos estáticos paramétricos, temos que: 16 EP utilizaram modelo de regressão, 7 EP utilizou regressão linear, 7 EP utilizou não linear dentre estes 4 baseados no desenvolvimento de uma função logística e mais 1 de regressão de resíduos e 2 de regressão múltipla. Ainda como modelos paramétricos foi identificado 1 EP utilizando modelo baseado em conceito de equilíbrio e 4 EP que utilizou modelos estocásticos. Em relação aos modelos não paramétricos, temos que: 1 EP utilizou k-vizinhos mais próximos, 8 EP utilizou redes neurais artificiais. 4 EP utilizaram modelos híbridos e 8 EP optaram também por aprendizagem de máquina como árvores.

O objetivo em comum dos estudos foi prever a temperatura da água futura a fim de analisar quais os riscos da temperatura alta do rio pelo aquecimento global e desmatamento, para preservação das espécies e gerenciamento de pesca. Em vista disso, a previsão foi feita baseadas em escalas anual, mensal e diária, o Quadro 8 é o resultado dos modelos que tiveram melhor desempenho para cada escala de tempo.

Quadro 8 – Modelos com melhores desempenho de acordo com as escalas de tempo.

Anual	Mensal	Semanal	Diária
Regressão linear	Regressão linear	Regressão linear	Regressão Não linear
			Estocástico
			Redes Neurais
			Árvores

Fonte: Autores.

Importante ressaltar que para esse estudo as escalas de tempo se referem aos dados meteorológicos extraídos em que os dados diários podem também serem obtidos em dados horários para execução do treinamento dos modelos estatísticos.

Apesar de relativamente eficientes, modelos de regressão em escala de tempo menor que semanal são mais difíceis de aplicar devido às autocorrelações na estrutura das séries temporais de temperatura da água. Nesses casos, modelos estocásticos e não paramétricos como Redes Neurais Artificiais (RNA) apresentaram melhores resultados. (Benyahya et al., 2007; Chenard & Caissie, 2008). Contudo, o modelo de regressão pode ser usado para simular a temperatura diária da água com dois termos defasados de temperatura da água, temperatura do ar e vazão como variáveis exógenas. A maioria dos estudos de regressão reconhece que existe um termo de erro. (Benyahya et al., 2013). Outrossim, modelos de regressão linear podem não prever temperaturas de fluxo em altas temperaturas. No mais alto e temperaturas mais baixas do ar, à temperatura ar-água geralmente não permanecem lineares e muitas vezes se assemelham a uma função em forma de S (Mohseni et al., 1998).

Apesar da previsão da temperatura da água ser essencial para a análise dos riscos das espécies, o monitoramento em tempo real da temperatura é também de extrema importância, no entanto, apenas um EP analisado tratou de uma situação que pode facilitar a previsão automatizada e em tempo real da temperatura da água. A falta de EP relacionado a estimação em tempo real é compreendida pelo fato de ser utilizado sensores de monitoramento, no entanto, torna-se necessário fornecer um meio de estimar a temperatura da água em ambientes de criações aquáticas que resulte em uma tecnologia acessível onde não houver um equipamento de medição como alternativa necessária podendo ser aplicada em diversas áreas onde houver essa necessidade, como nos pequenos produtores de tanques de aquicultura podendo ser visto como oportunidade de pesquisa. Observou-se também que os modelos de previsão de temperatura da água apesar de alguns relataram que visa no gerenciamento de pesca e aquicultura, não foi encontrado estudo com esses modelos em tanques de criação. A previsão da temperatura da água nos tanques também é um fator crucial que pode ajudar o produtor na tomada de decisão.

5. Considerações Finais

Neste trabalho foi apresentado e discutido o planejamento e os resultados de um mapeamento sistemático da literatura com a proposta de encontrar abordagem de modelos estatísticos que pudessem estimar a temperatura da água a partir de poucas variáveis disponíveis e que esses pudessem demonstrar onde, como estes modelos são utilizados. Dentre os modelos existentes analisados, os de regressão e os de redes neurais foram o mais utilizado pela sua popularidade e demonstraram bons resultados em diversos estudos.

Fica evidente a partir dos estudos que o objetivo desses modelos é prever a temperatura futura da água dos rios para tomadas de decisões a fim de preservar as espécies, alguns estudos também relatam a aplicação de modelos em costas marinhas, mas não foi encontrado qualquer relato sobre a aplicação dos modelos em outros cenários em que a temperatura da água é importante fazer o monitoramento. Nos tanques e viveiros de aquicultura o período de criação é curto e depende de um acompanhamento da temperatura contínua sendo o ideal em tempo real. Portanto, constitui-se uma oportunidade de pesquisa desenvolver uma abordagem de estimação da temperatura da água para o pequeno produtor que não possuem um instrumento de medição.

Como limitação, é importante ressaltar que uma pesquisa desta natureza possui riscos e ameaças à sua validade dos resultados. Para este estudo, apesar de serem utilizados critérios de inclusão e exclusão no processo de seleção dos estudos primários devido o número de artigos encontrados nas bases de dados, as palavras-chave e *string* de buscas mesmo sendo refinada pode não ter contemplado todos os estudos existentes e pesquisas importantes não terem sido incluídas. Além disso, alguns títulos e resumos não apresentaram de forma adequada o conteúdo que respondesse à questão de pesquisa, impossibilitando encontrar todos os estudos relevantes.

Desta forma, essa pesquisa apresentou uma busca e análise atual dos trabalhos relacionados ao assunto descrito das abordagens de estimação da temperatura da água. Como trabalhos futuros, pode-se tomar como base as investigações feitas dos diversos modelos a fim de desenvolver uma abordagem de estimação de temperatura da água com o intuito de desenvolver alternativa mais eficiente para tomada de decisão que impactem em um manejo da água e produção do pescado mais sustentável em um ambiente de aquicultura 4.0.

Referências

- Ali, S., Mishra, P. K., Islam, A., & Alam, N. M. (2016). Simulation of water temperature in a small pond using parametric statistical models: implications of climate warming. *Journal of Environmental Engineering*, 142(3), 04015085. [https://ascelibrary.org/doi/abs/10.1061/\(ASCE\)EE.1943-7870.0001050](https://ascelibrary.org/doi/abs/10.1061/(ASCE)EE.1943-7870.0001050)
- Ahmadi-Nedushan, B., St-Hilaire, A., Ouarda, T. B., Bilodeau, L., Robichaud, E., Thiémonge, N., & Bobée, B. (2007). Predicting river water temperatures using stochastic models: case study of the Moisie River (Québec, Canada). *Hydrological Processes: An International Journal*, 21(1), 21-34. <https://onlinelibrary.wiley.com/doi/abs/10.1002/hyp.6353>

- Antonopoulos, V. Z., & Gianniou, S. K. (2003). Simulation of water temperature and dissolved oxygen distribution in Lake Vegoritis, Greece. *Ecological modelling*, 160(1-2), 39-53. <https://www.sciencedirect.com/science/article/abs/pii/S0304380002002867>
- Benyahya L., Caissie D., St-Hilaire A., Ouarda T.B.M.J. and Bobee B., 2007a. A review of statistical water temperature models. *Can. Water Resources J.*, 32, 179–192. <https://www.tandfonline.com/doi/abs/10.4296/cwrj3203179>
- Caldwell, J., Rajagopalan, B., & Danner, E. (2015). Statistical modeling of daily water temperature attributes on the Sacramento River. *Journal of Hydrologic Engineering*, 20(5), 04014065. [https://ascelibrary.org/doi/abs/10.1061/\(asce\)he.1943-5584.0001023](https://ascelibrary.org/doi/abs/10.1061/(asce)he.1943-5584.0001023)
- Caldwell, R. J., Gangopadhyay, S., Bountry, J., Lai, Y., & Elsner, M. M. (2013). Statistical modeling of daily and subdaily stream temperatures: Application to the Methow River Basin, Washington. *Water Resources Research*, 49(7), 4346-4361. <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1002/wrcr.20353>
- Cordovil, v. R. D. S., & Francelin, m. M. (2018). Organização e representações: uso de mapa mental e mapa conceitual. *Xix encontro nacional de pesquisa em ciência da informação (xix enancib); xix encontro nacional de pesquisa em ciência da informação (xix enancib)*, 24(2). <https://brapci.inf.br/index.php/res/v/103035>
- Chenard J.F. and Caissie D., 2008. Stream temperature modelling using artificial neural networks: application on Catamaran Brook, New Brunswick, Canada. *Hydrol. Process.*, 22, 336. <https://onlinelibrary.wiley.com/doi/abs/10.1002/hyp.6928>
- Colombo, G. T., & Mannich, M. (2019). Estimativa da temperatura da água em rios utilizando a média móvel da temperatura do ar. *Proceedings of the XXIII SBRH 2019*. <https://s3-sa-east-1.amazonaws.com/abrh/Eventos/Trabalhos/107/XXIII-SBRH0387-1-20190502-111941.pdf>
- de Cara, B. E. D., Luiz, A. J. B., & Neves, M. C. (2013). Método para expansão de uma série temporal de temperatura da água a partir de dados do sistema automático de monitoramento de variáveis ambientais (SIMA): aplicação em aquicultura no reservatório de Furnas. <https://www.alice.cnptia.embrapa.br/handle/doc/963340>
- Frasca-Scorvo, C. M., Carneiro, D. J., & Malheiros, E. B. (2001). Comportamento alimentar do matrinxã (*Brycon cephalus*) no período de temperaturas mais baixas. *Boletim do Instituto de pesca*, 27(1), 1-5.
- Ferchichi, H., St-Hilaire, A., Ouarda, T. B., & Lévesque, B. (2022). Prediction of coastal water temperature using statistical models. *Estuaries and Coasts*, 45(7), 1909-1927. <https://link.springer.com/article/10.1007/s12237-022-01070-0>
- Harvey, R., Lye, L., Khan, A., & Paterson, R. (2011). The influence of air temperature on water temperature and the concentration of dissolved oxygen in Newfoundland Rivers. *Canadian Water Resources Journal*, 36(2), 171-192. <https://doi.org/10.4296/cwrj3602849>
- Hague, M. J., & Patterson, D. A. (2014). Evaluation of statistical river temperature forecast models for fisheries management. *North American Journal of Fisheries Management*, 34(1), 132-146. <https://www.tandfonline.com/doi/abs/10.1080/02755947.2013.847879>
- Heddam, S., Ptak, M., & Zhu, S. (2020). Modelling of daily lake surface water temperature from air temperature: Extremely randomized trees (ERT) versus Air2Water, MARS, M5Tree, RF and MLPNN. *Journal of Hydrology*, 588, 125130. <https://www.sciencedirect.com/science/article/abs/pii/S0022169420305904>
- Jeppesen, E., & Iversen, T. M. (1987). Two simple models for estimating daily mean water temperatures and diel variations in a Danish low gradient stream. *Oikos*, 149-155. <https://www.jstor.org/stable/3566020>
- Jiang, D., Xu, Y., Lu, Y., Gao, J., & Wang, K. (2022). Forecasting Water Temperature in Cascade Reservoir Operation-Influenced River with Machine Learning Models. *Water*, 14(14), 2146. https://www.mdpi.com/2073-4441/14/14/2146?utm_campaign=releaseissue_waterutm_medium=emailutm_source=releaseissueutm_term=doilink54
- Larnier, K., Roux, H., Dartus, D., & Croze, O. (2010). Water temperature modeling in the Garonne River (France). *Knowledge and Management of Aquatic Ecosystems*, (398), 04. <https://www.kmae-journal.org/articles/kmae/abs/2010/03/kmae100021/kmae100021.html>
- Laanaya, F., St-Hilaire, A., & Gloaguen, E. (2017). Water temperature modelling: comparison between the generalized additive model, logistic, residuals regression and linear regression models. *Hydrological sciences journal*, 62(7), 1078-1093. <https://www.tandfonline.com/doi/full/10.1080/02626667.2016.1246799>
- Letcher, B. H., Hocking, D. J., O'Neil, K., Whiteley, A. R., Nislow, K. H., & O'Donnell, M. J. (2016). A hierarchical model of daily stream temperature using air-water temperature synchronization, autocorrelation, and time lags. *PeerJ*, 4, e1727. <https://peerj.com/articles/1727/>
- Liu, W. C., & Chen, W. B. (2012). Prediction of water temperature in a subtropical subalpine lake using an artificial neural network and three-dimensional circulation models. *Computers & Geosciences*, 45, 13-25. <https://www.sciencedirect.com/science/article/pii/S0098300412000982>
- Mohseni, O., Stefan, H. G., and Erickson, T. R. (1998). "A nonlinear regression model for weekly stream temperature." *Water Resour. Res.*, 34(10), 2685–2692. <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/98WR01877>
- Mohr, S., Drainas, K., & Geist, J. (2021, December). Assessment of Neural Networks for Stream-Water-Temperature Prediction. In *2021 20th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 891-896). IEEE. <https://ieeexplore.ieee.org/abstract/document/9680252>
- Moura, G. D. S., Oliveira, M. G. A., Lanna, E. T. A., Maciel Júnior, A., & Maciel, C. M. R. R. (2007). Desempenho e atividade de amilase em tilápias-do-nylo submetidas a diferentes temperaturas. *Pesquisa Agropecuária Brasileira*, 42, 1609-1615.
- McGrath, E. O., Neumann, N. N., & Nichol, C. F. (2017). A statistical model for managing water temperature in streams with anthropogenic influences. *River Research and Applications*, 33(1), 123-134. <https://onlinelibrary.wiley.com/doi/abs/10.1002/rra.3057>
- Petersen, K.; Feldt, R.; Mujtaba, S.; Mattsson, M. (2008) Systematic Mapping Studies in Software Engineering. 12th International Conference on Evaluation and Assessment in Software Engineering (EASE). University of Bari, Italy. <https://www.scienceopen.com/hosted-document?doi=10.14236/ewic/EASE2008.8>

- Piccolroaz, S., Calamita, E., Majone, B., Gallice, A., Siviglia, A., & Toffolon, M. (2016). Prediction of river water temperature: a comparison between a new family of hybrid models and statistical approaches. *Hydrological Processes*, 30(21), 3901-3917. <https://onlinelibrary.wiley.com/doi/abs/10.1002/hyp.10913>
- Piccolroaz, S., Toffolon, M., & Majone, B. (2013). A simple lumped model to convert air temperature into surface water temperature in lakes. *Hydrology and earth system sciences*, 17(8), 3323-3338. <https://hess.copernicus.org/articles/17/3323/2013/>
- Pike, A., Danner, E., Boughton, D., Melton, F., Nemani, R., Rajagopalan, B., & Lindley, S. (2013). Forecasting river temperatures in real time using a stochastic dynamics approach. *Water Resources Research*, 49(9), 5168-5182. <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1002/wrcr.20389>
- Rabi, A., Hadzima-Nyarko, M., & Šperac, M. (2015). Modelling river temperature from air temperature: case of the River Drava (Croatia). *Hydrological sciences journal*, 60(9), 1490-1507. <https://www.tandfonline.com/doi/full/10.1080/02626667.2014.914215>
- St-Hilaire, A., Ouarda, T. B., Bargaoui, Z., Daigle, A., & Bilodeau, L. (2012). Daily river water temperature forecast model with ak-nearest neighbour approach. *Hydrological Processes*, 26(9), 1302-1310. <https://onlinelibrary.wiley.com/doi/abs/10.1002/hyp.8216>
- Saeed, S., Honeyeh, K., Ozgur, K., & Wen-Cheng, L. (2016). Water temperature prediction in a subtropical subalpine lake using soft computing techniques. *Earth Sciences Research Journal*, 20(2), 1-11. http://www.scielo.org.co/scielo.php?pid=S1794-61902016000200005&script=sci_arttext&tIng=en
- Sahoo, G. B., Schladow, S. G., & Reuter, J. E. (2009). Forecasting stream water temperature using regression analysis, artificial neural network, and chaotic non-linear dynamic models. *Journal of hydrology*, 378(3-4), 325-342. <https://www.sciencedirect.com/science/article/abs/pii/S0022169409006118>
- Sun, M., Chen, J., & Li, D. (2012, May). Water temperature prediction in sea cucumber aquaculture ponds by RBF neural network model. In *2012 International Conference on Systems and Informatics (ICSAI2012)* (pp. 1154-1159). IEEE. <https://ieeexplore.ieee.org/abstract/document/6223239>
- Tasnim, B., Jamily, J. A., Fang, X., Zhou, Y., & Hayworth, J. S. (2021). Simulating diurnal variations of water temperature and dissolved oxygen in shallow Minnesota lakes. *Water*, 13(14), 1980. <https://www.mdpi.com/2073-4441/13/14/1980>
- Toffolon, M., & Piccolroaz, S. (2015). A hybrid model for river water temperature as a function of air temperature and discharge. *Environmental Research Letters*, 10(11), 114011. <https://iopscience.iop.org/article/10.1088/1748-9326/10/11/114011/meta>
- Wenxian, G., Hongxiang, W., Jianxin, X., & Wensheng, D. (2010, May). PSO-BP neural network model for predicting water temperature in the middle of the Yangtze river. In *2010 International Conference on Intelligent Computation Technology and Automation (Vol. 2, pp. 951-954)*. IEEE. <https://ieeexplore.ieee.org/abstract/document/5522936>
- Yearsley, J. (2012). A grid-based approach for simulating stream temperature. *Water Resources Research*, 48(3). <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1029/2011WR011515>
- Zhu, S., Ptak, M., Yaseen, Z. M., Dai, J., & Sivakumar, B. (2020). Forecasting surface water temperature in lakes: A comparison of approaches. *Journal of Hydrology*, 585, 124809. <https://www.sciencedirect.com/science/article/abs/pii/S0022169420302699>
- Zhu, S., Nyarko, E. K., & Hadzima-Nyarko, M. (2018). Modelling daily water temperature from air temperature for the Missouri River. *PeerJ*, 6, e4894. <https://peerj.com/articles/4894/>
- Zhu, S., Heddam, S., Wu, S., Dai, J., & Jia, B. (2019). Extreme learning machine-based prediction of daily water temperature for rivers. *Environmental Earth Sciences*, 78, 1-17. <https://link.springer.com/article/10.1007/s12665-019-8202-7>
- Zhu, S., Heddam, S., Nyarko, E. K., Hadzima-Nyarko, M., Piccolroaz, S., & Wu, S. (2019). Modeling daily water temperature for rivers: comparison between adaptive neuro-fuzzy inference systems and artificial neural networks models. *Environmental Science and Pollution Research*, 26, 402-420. <https://link.springer.com/article/10.1007/s11356-018-3650-2>