

## Previsão de demanda de água: uma revisão de literatura

Water demand forecast: a literature review

Previsión de la demanda de agua: una revisión de la literatura

Recebido: 01/03/2023 | Revisado: 20/03/2023 | Aceitado: 21/03/2023 | Publicado: 25/03/2023

### Angélica Duarte Lima

ORCID: <https://orcid.org/0000-0002-4466-7590>  
Federal University of Technology, Brazil  
Aveiro University, Portugal  
E-mail: [gueia.lima@gmail.com](mailto:gueia.lima@gmail.com)

### Dayane Regina Trage

ORCID: <https://orcid.org/0000-0002-8850-3897>  
Federal University of Technology, Brazil  
E-mail: [dayanereginafrage84@gmail.com](mailto:dayanereginafrage84@gmail.com)

### Fabiane Florencio de Souza

ORCID: <https://orcid.org/0000-0003-0415-590X>  
Federal University of Technology, Brazil  
E-mail: [fabianessouzaa97@gmail.com](mailto:fabianessouzaa97@gmail.com)

### Regina Negri Pagani

ORCID: <https://orcid.org/0000-0002-2655-6424>  
Federal University of Technology, Brazil  
E-mail: [reginapagani@utfpr.edu.br](mailto:reginapagani@utfpr.edu.br)

### Resumo

A previsão de demanda da água é fundamental para o desenvolvimento social e econômico de uma região. A literatura possui diversos estudos com aplicações específicas, porém o tema ainda carece de uma visão abrangente. Portanto, este artigo propõe uma revisão integrativa de literatura, com objetivo de trazer uma visão geral sobre o assunto (métodos, áreas de aplicação, objetivos e outros fatores). Utilizando a metodologia *Methodi Ordinatio* foram selecionados 74 artigos para a análise, sendo a maioria publicados nos EUA, Austrália e Reino Unido. Concluiu-se que no uso dos métodos há um predomínio da abordagem de redes neurais artificiais artificial e análise de regressão. Quanto à aplicação, a maior parte dos estudos foram para previsão da demanda residencial.

**Palavras-chave:** Demanda de água; Previsão de demanda; Série temporal; Redes neurais; Cidades inteligentes.

### Abstract

Forecasting water demand is fundamental to a region's social and economic development. In the literature there are several studies with specific applications, However, the topic still lacks a comprehensive view. Therefore, this article proposes a integrative review of the literature, to obtain an overview of the subject (methods, areas of application, objectives, and other factors). Using *Methodi Ordinatio* methodology, 74 articles with scientific relevance for analysis were selected, most of them published in the USA, Australia, and the United Kingdom. It was concluded that in the use of methods there is a predominance of the approach of artificial neural networks and regression analyzes. As for the application, most studies were for forecasting residential demand.

**Keywords:** Water demand; Demand forecast; Time series; Neural networks; Smart Cities.

### Resumen

La previsión de demanda hídrica es esencial para el desenvolvimiento social y económico de una región. La literatura posee diversos estudios con aplicaciones específicas, más el asunto todavía carece de una visión extendida. Por tanto este artículo propone una revisión integrativa de la literatura, con el objetivo de suministrar una visión general del asunto (métodos, áreas de aplicación, objetivos y otros factores). Utilizando la metodología “*Methodi Ordinatio*”, fueron seleccionados 74 artículos para análisis, siendo la mayoría publicada en los Estados Unidos, Australia y el Reino Unido. Se concluyó que en la utilización de los métodos predomina el abordaje de redes neurales artificiales y análisis de regresión. En relación a la aplicación, la mayoría de los estudios fueron para previsión de demanda residencial.

**Palabras clave:** Demanda de agua; Previsión de la demanda; Series temporales; Redes neuronales; Ciudades inteligentes.

## 1. Introdução

O aumento da população, o crescimento do PIB mundial, as mudanças socioeconômicas, aliados com as evidentes

alterações no ciclo hidrológico, devido ao aquecimento global, impactam diretamente na disponibilidade futura de água. Dentro dessa perspectiva, no período de 2010 a 2050, a demanda global por água deverá sofrer um aumento de 20 a 33%, considerando três panoramas diferentes: de sustentabilidade mundial, de rivalidade regional entre os países, além de um cenário intermediário a estes. Sendo assim, a avaliação desses fatores que afetam o abastecimento de água pode auxiliar no planejamento e execução de medidas rápidas para uma administração eficaz deste recurso (Burek et al., 2016).

De acordo com a UNESCO (2019), um aspecto essencial para a gestão da água é o gerenciamento da dinâmica da oferta e demanda deste recurso. Dessa maneira, embora o abastecimento de água possa, nem sempre, atender ao necessário, o uso de uma abordagem norteada pela demanda pode auxiliar na sua distribuição.

Nesse contexto, conforme Lorente-Leyva et al. (2019), a previsão de demanda exerce um papel primordial no planejamento, organização e controle de atividades e processos. A flexibilidade do horizonte de previsão, que pode ser de curto, médio e longo prazo, é capaz de auxiliar a empresa que presta o serviço de distribuição de água no dimensionamento da capacidade de abastecimento, manutenção e melhorias na rede, configurando-se como aparato ao planejamento estratégico.

A maioria dos estudos ligados à previsão de demanda de água apresenta estudos de caso e aplicações pontuais, que dificultam a formação de uma visão abrangente sobre o tema. Dessa forma, este trabalho tem como objetivo trazer um olhar geral sobre as pesquisas feitas nesta área. Assim, este estudo traz uma revisão integrativa da literatura, fazendo a análise dos artigos selecionados através dos protocolos da Methodi Ordinatio.

Este trabalho está estruturado em cinco seções. Esta primeira faz uma contextualização do tema, apresentando a problemática e os objetivos do trabalho. A segunda seção aborda o referencial teórico pertinente. A terceira seção descreve a metodologia utilizada para a seleção dos trabalhos e análise dos dados. A quarta seção apresenta os resultados, fazendo a análise e discussão. A conclusão é feita na seção cinco, onde são também apresentadas as limitações e as sugestões para trabalhos futuros.

## **2. Referencial Teórico**

Esta seção aborda os principais conceitos de previsão de demanda de água no contexto de cidades inteligentes, bem como as técnicas de previsão existentes.

### **2.1 Cidades inteligente e gestão da água**

Os seres humanos vivem em comunidades desde o início da história humana. Com o advento da Primeira Revolução Industrial, vilas e cidades experimentaram um rápido crescimento, principalmente próximo aos rios, onde as indústrias se instalaram para utilizar a força hidrelétrica (Pagani et al., 2018).

Este rápido crescimento trouxe consigo o crescimento econômico para a região, e as cidades desempenham um papel importante nos aspectos econômicos e sociais no desenvolvimento sustentável (Mori & Christodoulou, 2012). Isso se explica uma vez que as cidades são sistemas com metabolismo complexo, com insumos de bens, produtos, matéria-prima, energia, água entre outros, que consomem recursos e os transformam em produtos. Com o fenômeno da urbanização e crescimento populacional ocorre um aumento da demanda por recursos e pela sua manutenção, sendo que um dos recursos mais utilizados é a água.

Estima-se, a partir das projeções recentes, que até 2050, cerca de 70% da população global viverá nas cidades (ONU, 2018). Thus, it is expected that, along with other resources, water will be one of the most used ones. Por isso, há um grande interesse das organizações e dos governos em fazer o uso adequado deste recurso. Nesse sentido, o mesmo pode ser alcançado por meio do monitoramento e gestão adequada dos sistemas de distribuição (Vijai & Bagavathi Sivakumar, 2016).

As cidades inteligentes, conceito de aglomerações urbanas de um futuro já não tão distante, tem sido bastante recorrente na literatura. Um dos pilares de uma cidade inteligente é justamente o smart environment (Batty et al., 2012), onde estão incluídos os conceitos de gestão de recursos naturais, incluindo a água.

Desta forma, torna-se estratégico para a manutenção da qualidade de vida a gestão da demanda de água, sendo necessário o estudo de métodos de previsão de demanda. Assim, a próxima seção apresenta os métodos mais utilizados para previsão de demanda.

## 2.2 Métodos de previsão de demanda

A literatura sobre métodos de previsão é bastante ampla. Uma das classificações mais encontradas na literatura é a que divide os métodos de previsão em qualitativa e quantitativa. Segundo Russel e Taylor (2011), a qualitativa possui como base o próprio julgamento, a opinião ou uma experiência anterior para fazer previsões. Por outro lado, métodos de previsão quantitativos, baseadas em dados, também estão disponíveis para auxiliar no planejamento e na tomada de decisões.

Partindo para uma classificação mais específica, Qi e Chang (2011) realizaram um estudo para estimar a demanda municipal de água. Em sua revisão de literatura, os autores dividem os métodos de previsão para este caso em: análise de regressão, análise de séries temporais, inteligência computacional, abordagem híbrida e simulação de Monte Carlo.

Montgomery et al., (2012) afirma que a análise de regressão é um dos métodos mais utilizados para avaliar dados referentes a mais de um fator. Basicamente, esta técnica usa uma equação para explicar o comportamento de uma variável de interesse por meio de um conjunto de variáveis, ditas como preditoras, relacionadas à primeira.

Dentro da abordagem de séries temporais existem diversos métodos aplicáveis, sendo os principais: médias móveis, suavização exponencial e ARIMA (autoregressivo integrado a médias móveis). De acordo com Hyndman e Athanasopoulos (2013), o modelo de médias móveis faz uma estimativa do ciclo de tendência, através da média de  $n$  valores da série temporal.

Já a suavização exponencial descreve um conjunto de métodos de previsão, sendo alguns dos melhores modelos baseados neste conceito. Este método descreve as previsões como combinações ponderadas de observações anteriores, em que as observações mais recentes levam um peso maior comparado com as observações mais antigas, por isso do nome “suavização exponencial” (Hyndman et al., 2008)

E, por último, o modelo ARIMA (autoregressivo integrado a médias móveis), proposto por Box e Jenkins (1970), é uma metodologia mais complexa aplicada à análise e previsão de séries temporais (Makridakis et al., 1998). Segundo Palit e Popovic (2005), este é utilizado em casos de séries temporais não estacionárias, que após sua diferenciação torna-se um conjunto de dados considerado estacionário. A diferenciação transforma a série temporal em um novo conjunto de dados a partir das diferenças de valores sucessivos, genericamente dito como  $X(t) - X(t-1)$ .

A inteligência computacional também abrange vários modelos de previsão, baseados, principalmente, em inteligência artificial. Entre eles: redes neurais artificiais (RNA) e lógica *fuzzy*.

Redes neurais artificiais são ferramentas computacionais relativamente novas que encontraram ampla utilização na solução de muitos problemas complexos do mundo real. A atratividade das RNAs vêm de seu notável processamento de informações, características pertinentes principalmente à não linearidade, alto paralelismo, tolerância a falhas e ruído e capacidade de aprendizagem e generalização (Basheer & Hajmeer, 2000).

Já a teoria dos conjuntos fuzzy aborda o conceito de pertencimento parcial de um objeto ou variável em um conjunto, e portanto, permite uma transição de uma associação total para uma não associação total. Desse modo, nesta lógica, um objeto ou variável pode pertencer parcialmente a vários conjuntos *fuzzy* no mesmo domínio e, assim, fornece uma estrutura para uma lógica multivariada (Palit & Popovic, 2005).

Os métodos de Monte Carlo descrevem uma categoria de modelos que podem resolver problemas matemáticos com a

ajuda de amostras aleatórias. Um exemplo simples é o cálculo do valor esperado de uma variável aleatória; em vez de calcular esse valor de acordo com sua definição (que pode ser muito complexa), observa-se o comportamento da variável aleatória. Assim, as amostras são coletadas e seu valor é estimado com base nelas (Amelin, 2013).

A abordagem híbrida refere-se a integração de mais de um método de previsão, com o objetivo de obter vantagens sobre a aplicação de modelos individuais. Neste caso, a maioria dos trabalhos utilizam a abordagem computacional para fazer a combinação de métodos, como por exemplo RNA e *fuzzy* (Qi & Chang, 2011).

A previsão da demanda de água utiliza desde metodologias relativamente simples, que exigem uma quantidade determinada de dados e podem ser aplicadas com poucos recursos computacionais, como modelos de séries temporais, até modelos mais elaborados como redes neurais artificiais e inteligência artificial.

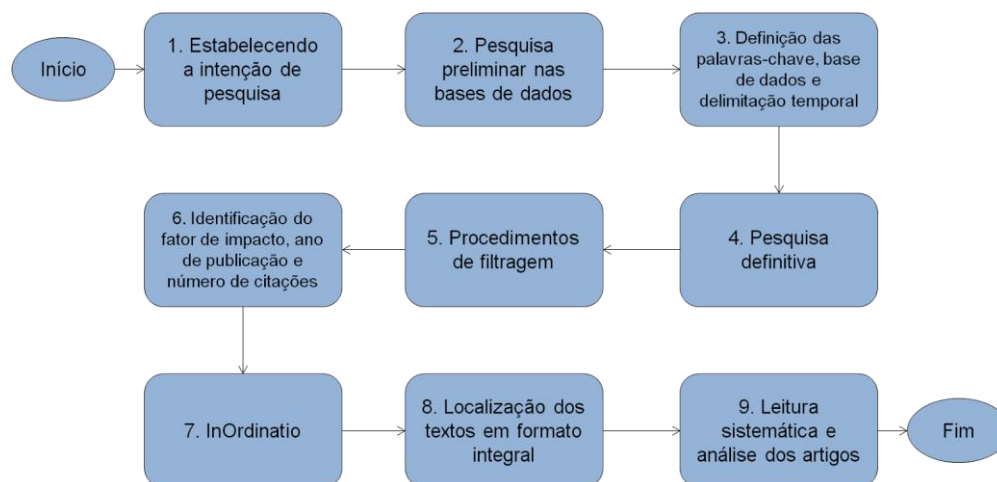
Assim, a escolha do modelo de previsão apropriado depende do propósito, da qualidade desejada e do volume dos dados que se possui (39). Além disso, outro fator que impacta a escolha do método é o uso de dados climáticos ou socioeconômicos, tais como: temperatura, precipitações, crescimento populacional e desenvolvimento econômico.

A próxima seção descreve a metodologia utilizada nesta pesquisa.

### 3. Metodologia

A revisão integrativa da literatura realizada neste trabalho baseia-se na Methodi Ordinatio (Pagani et al., 2015; 2017; 2022) A revisão integrativa da literatura visa fornecer uma conceituação holística e síntese da literatura (Torraco, 2005). A Figura 1 apresenta os passos da pesquisa.

**Figura 1** – Passos da Methodi Ordinatio.



Fonte: Pagani et al. (2017).

Primeiramente (etapa 1), foi definido o tema da pesquisa, que neste caso tem como foco a previsão de demanda de água, pois constatou-se a carência de pesquisas abrangentes sobre o assunto, além de sua relevância para o uso adequado desse recurso.

Posteriormente, foi realizada uma pesquisa preliminar (etapa 2) nas bases de dados. As bases de dados escolhidas foram Scopus, Science Direct e Web of Science. Não foi estabelecido limite temporal para analisar toda a literatura existente.

As combinações de palavras-chave foram definidas (etapa 3), conforme detalhado na Tabela 1. A busca final foi feita (etapa 4), usando o Mendeley para coletar os artigos. Os resultados brutos, assim como a sintaxe da busca, são apresentados na Tabela 1.

**Tabela 1** – Termos de busca e resultados.

<b>Palavras-chave</b>	<b>Scopus</b>	<b>Science Direct</b>	<b>Web of Science</b>	<b>Total</b>
“water demand forecast*” AND model*	257	64	4	325

Fonte: Autores (2023).

Para a remoção de duplicatas (etapa 5) dentre os artigos encontrados na busca, foi utilizado o Mendeley, totalizando 249 artigos. Pela leitura dos títulos e, em seguida, dos resumos, também foram eliminados os artigos que não estivessem relacionados ao tema. A Tabela 2 apresenta os procedimentos de filtragem e o número final de artigos.

**Tabela 2** - Pesquisa de documentos.

<b>“Water demand forecast*” AND model</b>	<b>Nº of documents</b>
Total found	325
After eliminating duplicates	249
After reading the titles	171
After reading the abstracts	74

Fonte: Autores (2023).

Então, para exportar os dados para uma planilha, foi utilizado outro gerenciador chamado JabRef, que facilita essa etapa. Além disso, foram identificados o fator de impacto, o ano de publicação e o número de citações de cada artigo, utilizando (passo 6) os sites Google Scholar, Clarivate Analytics e Scopus para realizar esta tarefa.

A aplicação da equação para encontrar o índice InOrdinatio (etapa 7) foi feita e os artigos foram classificados de acordo com sua relevância científica, com base no ano de publicação, número de citações e valores das métricas do periódico.

Após a localização desses artigos (etapa 8), a leitura sistemática (etapa 9) foi realizada de acordo com os parâmetros bibliométricos e de análise de conteúdo que investigaram a evolução temporal das publicações, países, autores e periódicos mais influentes sobre o tema.

A análise aprofundada buscou identificar padrões nos estudos e classificá-los em subgrupos de acordo com a área de aplicação, métodos e horizonte de previsão, além dos fatores que influenciam as previsões.

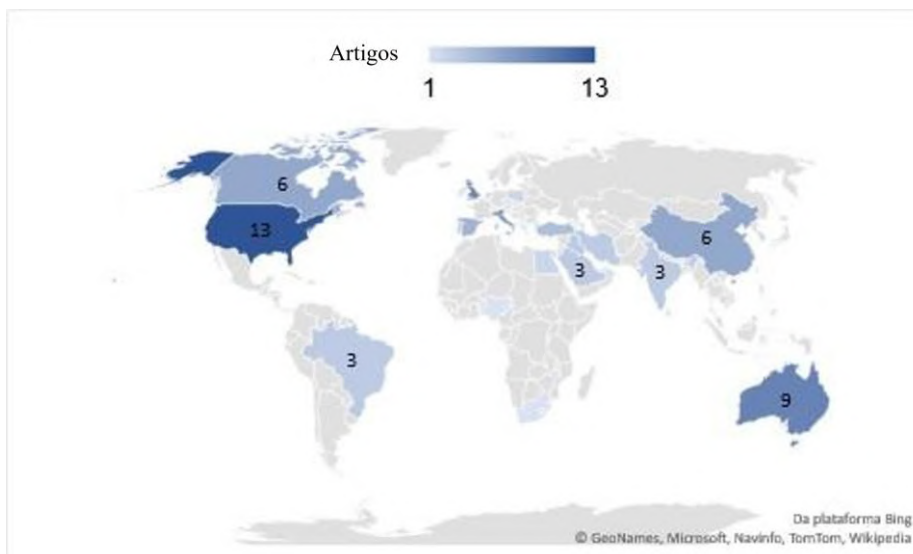
## **4. Resultados e Discussão**

Esta seção apresenta os resultados da bibliometria e análise de conteúdo dos artigos. Está estruturado nos seguintes tópicos: bibliometria e discussão das publicações selecionadas (área de aplicação, métodos utilizados, fatores que influenciam a previsão de demanda e previsão de demanda para análise de investimentos futuros).

### **4.1 Análise Bibliométrica**

Quanto aos países de maior destaque entre os 74 artigos selecionados, destacam-se os Estados Unidos, com 13 artigos; Austrália e Reino Unido, com 9 publicações cada, seguidos pela Itália, com 7 publicações. Um ranking dos países que possuem o maior número de publicações dentro do tema de previsão de demanda de água está representado na Figura 2.

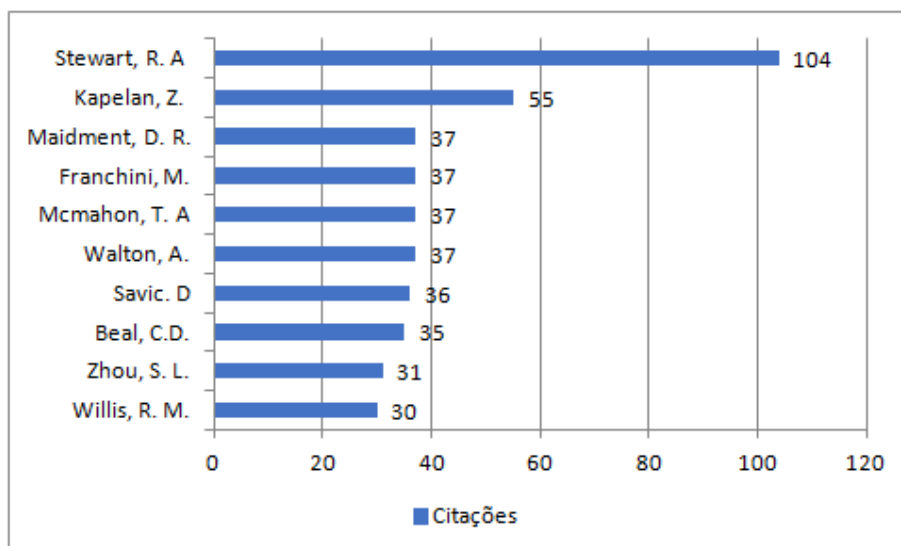
**Figura 2** – Países mais influentes para o tema.



Fonte: Autores (2023).

Outra análise realizada diz respeito aos autores mais influentes entre os artigos definidos. Para fazer essa análise, foi construído um gráfico (Figura 3) que mostra uma classificação destes de acordo com o número de citações de seus artigos, tanto como autor quanto como coautor.

**Figura 3** - Most cited authors.



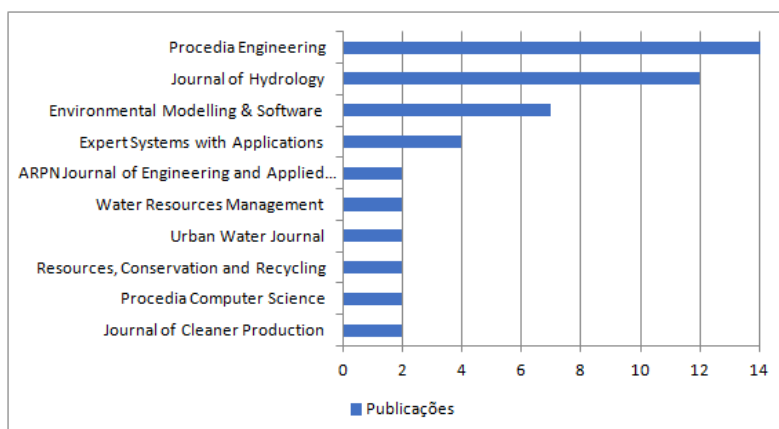
Fonte: Autores (2023).

Stewart, pesquisador ligado à universidade Griffith, na Austrália, está em primeiro lugar no ranking, com 104 citações. Seus estudos concentram-se nos temas de water supply, water management, water conservation e water demand management. O segundo autor com maior número de citações é Kapelan, que faz parte do Departamento de Gestão de Água, na Universidade de Tecnologia Delft, localizada nos Países Baixos. Além disso, trabalha com sistemas de distribuição de água, suprimento de água e gestão de água. E o terceiro autor com mais destaque é Maidment, afiliado à Universidade do Texas, nos EUA. Sua pesquisa aborda, principalmente, Sistemas de Informação Geográfica (GIS), hidrologia e recursos hídricos.

Ainda, elaborou-se um ranking (Figura 4) referente às revistas com maior relevância entre as publicações elegidas

neste trabalho.

**Figure 4 - Journals ranking.**



Fonte: Autores (2023).

The Journal of Hydrology publishes comprehensive articles in all fields of hydrology, including management and policy issues that impact the economy and society, within the theme of water.

Environmental Modeling & Software seeks to contribute to advances in the area of environmental modeling and software. Its objective is to improve the ability to represent, predict, and manage the behavior of natural environmental systems, including air, water, and terrestrial components, in all areas.

A *Procedia Engineering* é uma revista que publica artigos de diversos temas dentro da engenharia, mas que atualmente não está aceitando novos trabalhos, sendo, seu último volume, publicado em 2018. O *Journal of Hydrology* publica artigos abrangentes em todos os campos da hidrologia, incluindo gestão e questões políticas que impactam a economia e a sociedade, dentro do tema da água. Já o *Environmental Modeling & Software* busca contribuir sobre avanços na área de modelagem ambiental e software. Seu objetivo é melhorar a capacidade de representar, prever e gerenciar o comportamento dos sistemas ambientais naturais, incluindo ar, água e componentes terrestres, em todas as áreas.

## 4.2 Análise de conteúdo

Esta seção apresenta o conteúdo dos artigos pesquisados estruturados em cinco áreas: área de aplicação, métodos mais utilizados, horizonte de tempo nos modelos de previsão, fatores que influenciam a previsão de demanda e previsão de demanda para análise de investimentos futuros.

### 4.2.1 Área de aplicação

Os artigos encontrados realizaram seus estudos direcionados para o levantamento de água em três áreas de aplicação: municipal, irrigação e geração de energia. Não foram encontrados artigos que tratassem especificamente da previsão de demanda de água industrial ou comercial.

Há uma maior quantidade de estudos voltados à área municipal. Dos 33 artigos que apresentam um modelo de previsão de demanda a uma área específica de aplicação, 30 são voltados à demanda no contexto municipal.

A demanda urbana inclui residências, comércios, indústrias e instituições públicas. Porém, na maioria das cidades, os principais responsáveis pela demanda urbana são as residências (Qi & Chang, 2011; Liu et al., 2003; Darbandsari et al., 2017). Os artigos do portfólio apresentam métodos de previsão de demanda municipal e urbana voltados para fornecedores, gestores e formuladores de políticas de água, a fim de auxiliar na avaliação da demanda, otimização de recursos e planejamento de investimentos futuros (Sebri, 2016). Os estudos mais recentes também trazem uma abordagem voltada para o consumidor, com



a intenção de promover a conscientização e reduzir o uso de água (Gurung et al., 2016).

Um fator importante na gestão da demanda de água urbana é a sazonalidade. Zhou et al. (2000) propõem um modelo de série temporal para prever o consumo diário. O consumo total considerado no artigo é composto pelo consumo de base (consumo em litros por pessoa diariamente definido com base em fatores socioeconômicos) e o consumo sazonal (considera questões climáticas, como temperatura, evaporação e precipitação).

Zhou et al. (2002) aprimorou o estudo desenvolvendo um modelo para projeção fragmentado por hora da demanda das próximas 24 horas. A pesquisa foi calibrada com dados horários e diários de um período de 6 anos. As duas pesquisas foram realizadas na zona urbana de Melbourne na Austrália.

Outro fator significativo para a gestão econômica e sustentável da demanda de água é prever os pontos de pico. Adamowski (2008) apresentou modelos para previsão do pico diário da demanda de água com diferentes métodos. O autor comparou o desempenho dos modelos e concluiu que o método RNA se mostrou o mais eficiente. A análise foi realizada utilizando dados do pico diário de 10 anos e variáveis meteorológicas (temperatura máxima diária e precipitação diária).

A análise da demanda de pico e questões de sazonalidade são relevantes para aplicação em estudos em cidades turísticas que tenham eventos ou temporadas de maior demanda. Ajbar e Ali (2015) desenvolveram um modelo para prever a demanda mensal e anual de água para Meca, que apresenta picos em duas ocasiões religiosas que ocorrem em datas específicas. O modelo utiliza rede neural RNA.

A demanda municipal contempla residências, comércios, indústrias, instituições públicas, porém na maioria das cidades o principal responsável pela demanda urbana são as residências (Qi & Chang, 2011; Liu et al., 2003; Darbandsari et al., 2017).

Uma forma de prever a demanda são modelos de baixo para cima. Dois artigos apresentam este tipo de estudo. O primeiro foi elaborado por Bennett et al. (2013), que identifica os determinantes da demanda de água em uma residência utilizando RNA. Os autores concluem que os principais determinantes são a renda familiar, o número de adultos, crianças e adolescentes na residência e a eficiência em relação aos usos finais (banheiro, chuveiro e lavadora de roupas etc.). O segundo foi Rathnayaka et al. (2017) que apresenta previsão em múltiplas escalas temporais para um grupo de usuários no nível de uso final. Capturam também a variabilidade dentro de cada grupo, levando em conta questões comportamentais.

Por ser um dos elementos de maior impacto na demanda residencial. Makki et al. (2015) realizaram um estudo para encontrar os determinantes de consumo do chuveiro por meio de métodos estatísticos e regressão multivariada, usando conjuntos de dados sociodemográficos e dados de hidrômetros inteligentes.

Outros estudos utilizaram também hidrômetros inteligentes, que registram continuamente os dados de água e transferem instantaneamente informações de forma remota, que permite avaliações mais ampliadas das simulações da rede de abastecimento de água (Gurung et al., 2016; Makki et al., 2013; Walker et al., 2015).

O uso de água pela agricultura irrigada é um dos principais fatores de redução dos níveis de água doce disponível, o que torna importante desenvolver metodologias para auxiliar os gestores. No entanto, um problema no desenvolvimento dos modelos é a quantidade e a qualidade dos dados na agricultura irrigada (González et al., 2019).

Pulido et al. (2007) analisam o desempenho de modelos de previsão de demanda para irrigação com regressões múltiplas e redes neurais computacionais. Devido à falta de dados, foi instalado sistema de telemetria comercial em 28 fazendas, para registrar os volumes de água em tempo real. González et al. (2019) desenvolveram um modelo para previsão de curto prazo de demanda de água de irrigação quando o número de dados disponíveis é limitado.

Foi encontrado um artigo para previsão de demanda de água para termelétrica. Thopil e Pouris (2016) afirmam que há poucos estudos para previsão de demanda para a geração de energia elétrica. Os autores propõem e aplicam método para estimativa da demanda de água para a refrigeração em usinas de geração de energia elétrica a carvão utilizando dados



históricos em modelo matemático.

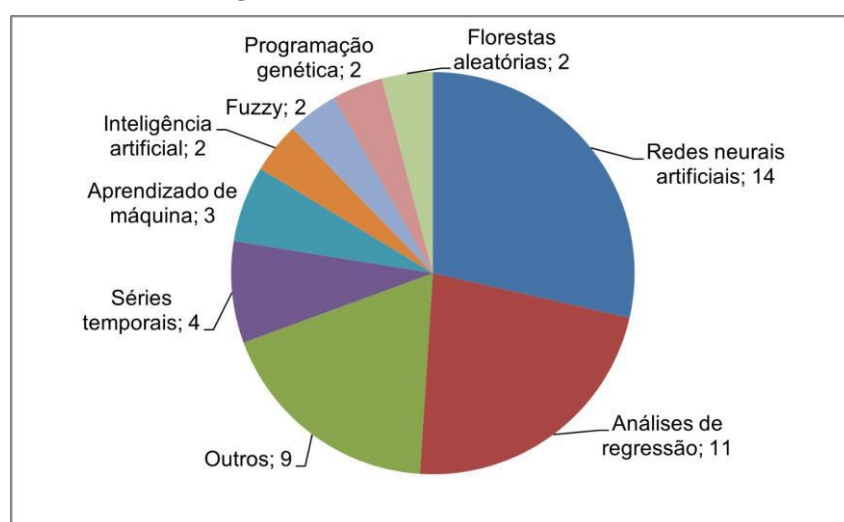
#### 4.2.2 Métodos mais mencionados no portfólio

Esta seção apresenta os principais métodos encontrados nos artigos, separando em quantitativo e qualitativo. Também aborda o horizonte de tempo das previsões (curto, médio e longo prazo), a previsão de demanda futura e os fatores que afetam a demanda

Foi encontrado apenas um trabalho que utilizou abordagem qualitativa. Matos e Martinelli (1998) apresentam um modelo qualitativo iterativo para auxiliar na previsão com o aprendizado de máquina, baseado em dados históricos, precisando da visão de especialistas para auxiliar na seleção de dados e avaliar os resultados.

Os métodos de previsão de demanda de água, encontrados nos artigos da revisão integrativa, são bem variados, mas nota-se um predomínio da abordagem de redes neurais artificiais e análise de regressão. Na Figura 5 pode ser observado que os dois métodos estão presentes em 51% dos artigos que apresentam aplicação ou proposição de modelo. A Figura 5 apresenta um comparativo dos dois métodos predominantes ao longo do tempo, além de mostrar uma sazonalidade no uso dos métodos.

**Figura 5 – Métodos usados nos modelos.**



Fonte: Autores (2023).

A análise de regressão multivariada pode ser usada para avaliar a presença de autocorrelação entre fatores (Ashoori et al., 2017). Makki et al. (2013) utilizam análise de regressão para revelar os determinantes de consumo do chuveiro, como por exemplo, composição da família, eficiência do chuveiro elétrico, renda, educação, entre outros. Mamade et al. (2014) aplicam MLR para reduzir o número de variáveis de cada categoria sociodemográfica. Ashoori et al. (2017) propõem um modelo para projetar a demanda de água considerando cenários futuros alternativos de população, clima, preços e conservação.

Devido à complexidade da análise da demanda de água fez necessário o uso de ferramentas mais sofisticadas e robustas como redes neurais artificiais (Oyebode et al., 2019). Liu et al. (2003) apresentam modelo simples de RNA, com uma camada, sendo que os autores concluem que o método se mostrou eficaz para a previsão de demanda de água na cidade de Weinan, na China. Firat et al. (2010) comparam o desempenho dos modelos de RNA com o consumo de água observado em Izmir, na Turquia. O estudo mostra que as técnicas de RNA apresentaram resultado satisfatório para previsão de consumo e de demanda futura. Bennett et al. (2013) apresentam modelo para previsão da demanda de água residencial focado no uso final usando RNA e cria uma ferramenta iterativa.

Ajbar e Ali (2015) afirmam que o modelo com RNA se mostrou eficiente para capturar os efeitos dinâmicos do consumo de água tanto no curto como no longo prazo. Ashoori et al. (2017) aplicam modelo para prever a possível demanda futura até 2050 sob cenários alternativos para as variáveis explicativas: população, preço, conservação voluntária, esforços e resultados de temperatura e precipitação. O modelo de regressão múltipla se ajusta a 44 anos de dados de demanda mensal (1970-2014) para Los Angeles, na Califórnia.

Outro método robusto é o sistema de inferência *Fuzzy*. Firat et al. (2010) comparam dois modelos utilizando a abordagem *Fuzzy*. O sistema de Inferência *Neuro-Fuzzy* Adaptativo (ANFIS) se mostrou superior quando comparado com o Sistemas de Inferência *Fuzzy* Mamdani. Yurdusev e Firat (2009) encontram resultados satisfatórios para aplicação de modelo com ANFIS em estudo em Izmir, na Turquia. O Quadro 1 apresenta artigos com diferentes metodologias.

**Quadro 1 - Métodos usados em modelos de previsão.**

Método	Referência	Estudo
Rede Neural Artificial (RNA)	Liu et al. (2003)	Modelagem com RNA simples para prever a demanda de água em área urbana na cidade de Weinan na China
	Firat et al. (2010)	Comparação de diferentes tipos de técnicas de RNA: Rede neurais para regressão, Rede neural de correlação em cascata e Redes Neurais de Feedforward
		Modelo de previsão em tempo real para auxiliar na tomada de decisão
	Zeng et al. (2012)	Modelo com três tipos de RNA. Estudo desenvolve ferramenta iterativa para previsão de demanda
	Bennett et al. (2013)	Modelo com RNA para prever a demanda mensal e anual de água para Meca, levando em conta os picos de demanda, o modelo foi calibrado com dados históricos.
	Ajbar e Ali (2015)	Modelo com RNA a partir de um medidor inteligente
Walker et al. (2015)	Comparação de diferentes tipos de técnicas de RNA: Rede neurais para regressão, Rede neural de correlação em cascata e Redes Neurais de Feedforward	
Análise de Regressão	Makki et al. (2013)	Regressão Linear Multipla para encontrar os determinantes de consumo do chuveiro. Foi utilizado dados sociodemográficos e coletados de residências com hidrômetros inteligentes
	Mamade et al. (2014)	Regressão Linear Multipla para análise de correlação de variáveis sociodemográficas
	Ashoori et al. (2017)	Modelo com Regressão Linear Multipla em conjunto com simulações de Monte Carlo para prever a possível demanda futura até 2050 com base em dados de demanda mensal (1970-2014) para Los Angeles, Califórnia
	Sanchez et al. (2020)	Analisar o impacto conjunto em cenários futuros das densidades populacionais e do aquecimento climático sobre a demanda de água em dois estados americanos de rápido crescimento
Inteligencia Artificial	Nguyen et al. (2018)	Sistema inteligente de gestão de água urbana com uso do software voltado para concessionárias e clientes, com base em dados coletados é capaz de realizar previsão de demanda de curto prazo
	Gharabaghi et al. (2019)	Modelos com métodos estocásticos avançados não lineares e de inteligência artificial para a previsão de demanda diária de água.
Séries temporais	Zhou et al. (2002)	Modelo para prever o consumo de água por dia e por hora diário em Melbourne usando uma abordagem de time series
	Gato et al. (2007)	Modelo de demanda diária incorporando valores de uso de base calculados usando limites de temperatura e precipitação dados de precipitação e temperatura correspondentes de 1990 a 2000
	Arandia et al. (2014)	Modelo utiliza uma abordagem séries temporais, considerando o consumo como a soma do consumo base e sazonal.
<i>Fuzzy</i>	Firat et al. (2009)	Compara dois sistemas de inferência <i>Fuzzy</i> para previsão de demanda em área urbana
	Yurdusev e Firat (2009)	Modelo com sistema de inferência <i>neuro-fuzzy</i> adaptativo (ANFIS) para prever consumo de água mensal, considera fatores socioeconômicos e climáticos
Outros	Qi e Chang (2011)	Modelos de Sistemas Dinâmico
	Yin e Fang (2014)	Análise de Harmonia
	Fontanazza et al. (2014)	Análise estatística multivariada
	Candelieri e Archetti (2014)	Máquina de vetores de suporte
	Chen et al. (2015)	Redes Lógicas Adaptativas
	Brentan et al. (2017)	Regressão vetorial e aprendizado de máquina
	Yousefi et al. (2017)	Programação de expressão genética usando decomposição de wavelet
	Darbandsari et al. (2017)	Modelagem baseada em agente

Fonte: Autores (2023).

Os estudos mencionados no portfólio de artigos foram realizados para comparar o desempenho de modelos desenvolvidos com diferentes metodologias. Alguns estudos combinam métodos na construção dos modelos. Herrera et al. (2014) propõe método com aprendizagem on-line em cidade inteligente utilizando regressão múltipla de kernel combinado com simple support vector regression (SVR). González et al. (2019) combinam RNA com Genetic Algorithms para previsão de demanda de água em tempo real, com objetivo de juntamente com outras informações auxiliar na tomada de decisão na gestão dos recursos hídricos urbanos.

Candelieri et al. (2015) desenvolve previsão da demanda de água de curto prazo, adota um esquema de aprendizagem de duas fases com base em clustering de dados de série temporal (primeiro estágio) e Support Vector Machine para regressão (segundo estágio).

Adamowski (2008) desenvolve e compara 39 modelos por regressão linear múltipla, 9 modelos de séries temporais e 39 modelos de RNA para previsão de picos de demanda de água. Neste estudo a abordagem por rede neural artificial se mostrou mais eficiente.

Herrera et al. (2010) descrevem e comparam modelos de previsão da demanda de água, utilizando métodos de aprendizagem de máquina. Foi realizado comparação experimental utilizando RNA, perseguição de projeção, splines de regressão adaptativa multivariada, florestas aleatórias e regressão vetorial de suporte. Os resultados apontaram como método mais preciso os modelos de regressão com vetores suporte (SVR). Modelos com RNA apresentaram o pior desempenho do grupo comparado.

Pesantez et al. (2020) comparam modelos utilizando métodos de aprendizado de máquina, incluindo FA, RNA, SVR para prever a demanda de água utilizando dados de hidrômetros inteligentes. Modelos com RFs e RNA apresentaram melhores desempenho.

#### **4.2.3 Horizonte de tempo em modelos de previsão e fatores que influenciam a previsão de demanda**

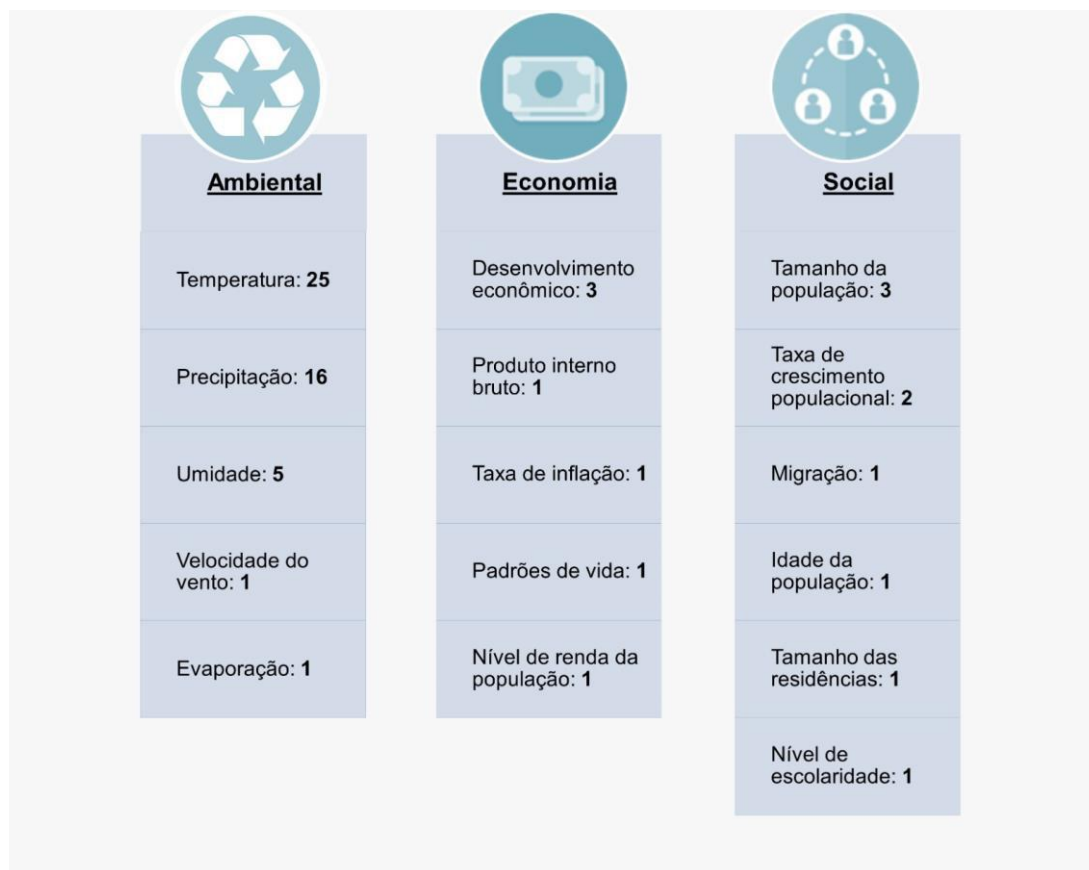
Os modelos podem ser propostos levando em conta o horizonte de tempo da previsão de demanda, podendo ser curto, médio e de longo prazo. A previsão de curto prazo varia de horas a dias e oferece informações para a operação e gestão dos sistemas de abastecimento de água existentes. Na previsão de médio prazo, sua resolução é igual ou maior que um mês e menor que um ano, com aplicação no gerenciamento de médio prazo. A previsão de longo prazo se refere a um tempo superior a um ano e fornece informações úteis para planejamento, design e gerenciamento de ativos (Nasseri et al, 2011; Qi et al, 2011).

Fatores socioeconômicos, comportamento do consumidor e mudanças climáticas afetam a demanda nas áreas urbanas (Qi & Chang, 2011). Os elementos climáticos presentes nos artigos foram a temperatura (Nasseri et al, 2011; Adamowski, 2008; Ajbar e Ali, 2015; Arandia et al, 2014; Ashoori et al., 2017; Bakker et al, 2013; Brentan et al., 2017; Breyer e Chang, 2014; Darbandsari et al., 2017; Firat et al., 2009; Firat et al., 2010; GATO et al., 2002; Gharabaghi et al., 2019; Herrera et al., 2014; Jain e Ormsbee, 2002; Jain et al, 2001; Kozłowski et al, 2018; Pulido-Calvo et al., 2007; Wang e Davies, 2018; Vijai e Bagavathi, 2018; Shabani et al., 2017; Sanchez et al., 2020), as precipitações (Nasseri et al, 2011; Adamowski, 2008; Arandia et al., 2014; Ashoori et al., 2017; Bakker et al, 2013; Darbandsari et al., 2017; Firat et al., 2009; Firat et al., 2010; Gato et al., 2002; Gharabaghi et al., 2019; Hutton & Kapelan, 2015; Jain & Ormsbee, 2002; Jain et al, 2001; Pulido-Calvo et al., 2007; Wang & Davies, 2018; Shabani et al., 2017), a umidade (Brentan et al., 2017; Firat et al., 2009; Firat et al., 2010), a velocidade do vento (Brentan et al., 2017), e a evaporação (Nasseri et al, 2011).

Os fatores socioeconômicos considerados foram o crescimento populacional (Nasseri et al, 2011; Ajbar e Ali, 2015), a migração (Nasseri et al, 2011), o desenvolvimento econômico (Nasseri et al, 2011; Ajbar e Ali, 2015; Guo et al., 2020), a população (Yurdusev & Firat, 2009; Guo et al., 2020; Firat et al., 2009), a idade da população (Chen et al., 2015), o produto

nacional bruto (Yurdusev & Firat, 2009), a taxa de inflação (Yurdusev & Firat, 2009), o tamanho dos domicílios (Chen et al., 2015), o nível de renda e educação da população (Chen et al., 2015), e o padrão de vida (Guo et al., 2020). A Figura 6 apresenta os fatores que influenciam a demanda de água presente nos artigos.

**Figura 6** - Número de autores citando fatores que influenciam na previsão da demanda de água.



Fonte: Autores (2023).

Outros fatores apontados como influenciadores da demanda são o nível de educação e conscientização dos consumidores (Darbandsari et al., 2017), as políticas de preço da água (Darbandsari et al., 2017; Wang & Davies, 2018), e regulamentações (Wang & Davies, 2018). No entanto não há consenso na correlação entre fatores climáticos e a demanda de água. Jain et al. (2001) Adamowski (2008) concluem ter relação entre a ocorrência de precipitações e a demanda de água sem importar o volume de chuva. Adamowski (2008) atribui ao comportamento do consumidor. Por outro lado, Gato et al. (2007) não encontraram correlação entre a demanda de água e as precipitações e temperatura.

Um estudo em Portland (Oregon) buscou ver a relação entre a demanda de água e as variações no clima. Para isso analisou as flutuações climáticas ao longo de 29 anos (1981-2009) (Breyer & Chang, 2014).

Qi e Chang (2011) propuseram um modelo que considera a relação entre a demanda de água e o ambiente macroeconômico. Ajibar e Ali (2013) utilizaram variáveis de renda familiar, população e previsão de visitantes na cidade.

#### 4.2.4 Previsão de demanda para análise de investimentos futuros

As decisões sobre investimentos, pelos gestores públicos e pelas empresas de abastecimento de água, são fortemente dependentes de previsão de demanda de água, sendo esta estratégica principalmente para regiões com abastecimento de água limitada (Bennett et al., 2013; Ajbar & Ali, 2015).

Estudos de demanda futura para prever a necessidade de criar ou ampliar plantas de dessalinização foram realizados nos Emirados Árabes Unidos (Mohamed & Al-Mualla, 2010) e para a cidade de Meca, na Arábia Saudita (Ajbar & Ali, 2015).

## 5. Conclusão

O artigo apresentou uma revisão integrativa da literatura em relação à previsão de demanda de água. As pesquisas foram realizadas nas bases Web of Science, Scopus e Science Direct e classificadas utilizando a Methodi Ordinatio. Assim, 74 artigos foram considerados para análise bibliométrica e para análise de conteúdo.

Na bibliometria, notou-se que, ao longo do tempo, o número de publicações sobre o tema apresentou um aumento até o ano 2014 e após isto houve uma queda. Ainda, percebeu-se que, dentre os trabalhos selecionados, os EUA possuem destaque em pesquisas na área. Na análise de conteúdo, foi possível perceber um predomínio de estudos por redes neurais e um desempenho superior deste método quando comparados com outros. Outra abordagem muito utilizada nos estudos é a análise de regressão.

Os artigos são voltados em fornecer dados de previsão de demanda para gestores de empresas de distribuição de água e para gestores públicos. No entanto, pesquisas mais recentes estão voltadas para aplicações para fornecer informação também para os consumidores. A maior parte dos estudos abordam a previsão na área urbana. Alguns destes estudos abordaram especificamente a demanda residencial, pois tem grande impacto na demanda urbana. Modelos inovadores são apresentados para previsão de demanda de cima para baixo. Não foram encontrados artigos aplicados à previsão em todos os setores da economia. Neste sentido, uma lacuna identificada é a falta de estudos que levante os principais determinantes de consumo de água em segmentos específicos, teste a correlação destes determinantes e proponha modelos para previsão de demanda de curto e longo prazo.

Esta pesquisa contribui com uma visão geral sobre a previsão de demanda de água, que permitiu também apontar lacunas nas pesquisas. A principal limitação desta pesquisa é o fato de que a busca foi realizada em apenas três bases de dados. Assim, para pesquisas futuras, sugere-se que a pesquisa amplie suas buscas para outras bases, além de identificar os fatores que influenciam na quantidade de publicações feitas ao longo dos anos.

Como o portfólio não apresentou nenhum estudo referente à previsão de demanda de água industrial ou comercial, sugere-se que trabalhos futuros possam explorar melhor esses estudos. Quanto aos fatores que interferem na demanda hídrica, o fator cultural não foi citado, devendo ser melhor investigado também em pesquisas futuras.

## Agradecimentos

O presente trabalho foi desenvolvido com o apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código Financeiro 001, e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

## Referências

- Adamowski, J. F. (2008). Peak daily water demand forecast modeling using artificial neural networks. *Journal of Water Resources Planning and Management*, 134 (2), 119-128. 10.1061/(ASCE)0733-9496(2008)134
- Amelin, M. (2013). Monte Carlo Simulation in Engineering. KTH Royal Institute of Technology, Stockholm. <https://www.kth.se/social/files/55e017b4f276545643070e39/Monte%20Carlo%20Simulation%20in%20Engineering.pdf>. Access in: May 11, 2022.
- Ajbar, A., & Ali, E.M. (2015). Prediction of municipal water production in touristic Mecca City in Saudi Arabia using neural networks. *Journal of King Saud University - Engineering Sciences*, 27(1), 89-91. 10.1016/j.jksues.2013.01.001
- Arandia, E., Eck, B., & Mckenna, S. (2014). The effect of temporal resolution on the accuracy of forecasting models for total system demand. *Procedia Engineering*, 89, 916-925. 10.1016/j.proeng.2014.11.525

- Ashoori, N., Dzombak, D. A., & Small, M. J. (2017). Identifying water price and population criteria for meeting future urban water demand targets. *Journal of Hydrology*, 555, 547-556. 10.1016/j.jhydrol.2017.10.047
- Bakker, M., Vreeburg, J. H. G., Van Schagen, K. M., & Rietveld, L. C. (2013). A fully adaptive forecasting model for short-term drinking water demand. *Environmental Modelling and Software*, 48, 141-151. 10.1016/j.proeng.2014.02.012
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3-31. 10.1016/j.envsoft.2013.06.012
- Batty, M., Axhausen, K. W., Giannotti, F., Pozdnoukhov, A., Bazzani, A., Wachowicz, M., Ouzounis, G., & Portugali, Y. Smart cities of the future (2012). *The European Physical Journal Special Topics*, 214(1), 481-518, 2012. 10.1140/epjst/e2012-01703-3
- Bennett, C., Stewart, R.A., & Beal, C.D. (2013). ANN-based residential water end-use demand forecasting model. *Expert Systems with Applications*, 40(4), 1014-1023. 10.1016/j.eswa.2012.08.012
- Brentan, B. M., Luvizotto Jr., E., Herrera, M., Izquierdo, J., & Pérez-García, R. (2017). Hybrid regression model for near real-time urban water demand forecasting. *Journal of Computational and Applied Mathematics*, 309, 532-541. 10.1016/j.cam.2016.02.009.
- Breyer, B., & Chang, H. (2014). Urban water consumption and weather variation in the Portland, Oregon metropolitan area. *Urban Climate*, 9, 1-18. 10.1016/j.uclim.2014.05.001.
- Burek, P., Satoh, Y., Fischer, G., Kahil, M.T., Scherzer, A., Tramberend, S., Nava, L.F., Wada, Y., Eisner, S., Flörke, M., Hanasaki, N., Magnuszewski, P., Cosgrove, B., & Wilberg, D. (2016). Water Futures and Solution. *International Institute for Applied Systems Analysis*, 1-113. <http://pure.iiasa.ac.at/13008>
- Candelieri, A., & Archetti, F. (2014). Identifying typical urban water demand patterns for a reliable short-term forecasting - The icewater project approach. *Procedia Engineering*, 89, 1004-1012. 10.1016/j.proeng.2015.08.948.
- Chen, X., Yang, S.-H., Yang, L., & Chen, X. (2015). A benchmarking model for household water consumption based on adaptive logic networks. *Procedia Engineering*, 119(1), 1391-1398. 10.1016/j.proeng.2015.08.998.
- Darbandsari, P., Kerachian, R., & Malakpour-Estalaki, S. (2017). An Agent-based behavioral simulation model for residential water demand management: The case-study of Tehran, Iran. *Simulation Modelling Practice and Theory*, 78, 51-72. 10.1016/j.simpat.2017.08.006.
- Firat, M., Turan, M. E., & Yurdusev, M. A. (2009). Comparative analysis of fuzzy inference systems for water consumption time. series prediction. *Journal of Hydrology*, 374(3-4), 235-241. 10.1016/j.jhydrol.2009.06.013.
- Firat, M., Turan, M. E., & Yurdusev, M. A. (2010). Comparative analysis of neural network techniques for predicting water consumption time series. *Journal of Hydrology*, 384 (1-2), 46-51. 10.1016/j.jhydrol.2010.01.005.
- Fontanazza, C. M., Notaro, V., Puleo, V., & Freni, G. (2014). Multivariate statistical analysis for water demand modeling. *Procedia Engineering*, 89, 901-908. 10.1016/j.proeng.2014.11.523
- Gato, S., Jayasuriya, N., & Roberts, P. (2007). Temperature and rainfall thresholds for base use urban water demand modelling. *Journal of Hydrology*, 337 (3-4), 364-376. 10.1016/j.jhydrol.2007.02.014.
- Gharabaghi, S., Stahl, E., & Bonakdari, H. (2019). Integrated nonlinear daily water demand forecast model (case study: City of Guelph, Canada). *Journal of Hydrology*, 579, art. no. 124182. 10.1016/j.jhydrol.2019.124182
- González Perea, R., Camacho Poyato, E., Montesinos, P., & Rodríguez Díaz, J.A. (2019). Optimisation of water demand forecasting by artificial intelligence with short data sets. *Biosystems Engineering*, 177, 59-66. 10.1016/j.biosystemseng.2018.03.011.
- Guo, W., Liu, T., Dai, F., & Xu, P. (2020). An improved whale optimization algorithm for forecasting water resources demand. *Applied Soft Computing Journal*, 86, art. no. 105925. 10.1016/j.asoc.2019.10592.
- Gurung, T. R., Stewart, R. A., Beal, C. D., & Sharma, A. K. (2016). Smart meter enabled informatics for economically efficient diversified water supply infrastructure planning. *Journal of Cleaner Production*, 135, 1023-1033. 10.1016/j.jclepro.2016.07.017.
- Herrera, M., Izquierdo, J., Pérez-García, R., & Ayala-Cabrera, D. (2014). On-line learning of predictive kernel models for urban water demand in a smart city. *Procedia Engineering*, 70, 791-799. 10.1016/j.proeng.2014.02.086.
- Herrera, M., Torgo, L., Izquierdo, J., & Pérez-García, R. (2010). Predictive models for forecasting hourly urban water demand. *Journal of Hydrology*, 387 (1-2), 141-150. 10.1016/j.jhydrol.2010.04.005.
- Hutton, C. J., & Kapelan, Z. A. (2015). Probabilistic methodology for quantifying, diagnosing and reducing model structural and predictive errors in short term water demand forecasting. *Environmental Modelling and Software*, 66, 87-97. 10.1016/j.envsoft.2014.12.021
- Hyndman, R., Koehler, A. B., Ord, J. K., & Snyder, R. D. (2008). *Forecasting with Exponential Smoothing: The State Space Approach*. Springer, Berlin. [http://online.kottakkalfarookcollege.edu.in:8001/jspui/bitstream/123456789/3945/1/\\_ForecastingWithExponentialSmoo.pdf](http://online.kottakkalfarookcollege.edu.in:8001/jspui/bitstream/123456789/3945/1/_ForecastingWithExponentialSmoo.pdf). Access in: July 11, 2022.
- Hyndman, R. J., & Athanasopoulos, G. (2013). *Forecasting: principles and practice*. Second ed. O Texts, Australia. <https://otexts.com/fpp2/>
- Jain, A., Varshney, A. K., & Joshi, U. C. (2001). Short-term water demand forecast modelling at IIT Kanpur using artificial neural networks. *Water Resources Management*, 15 (5), 299-321. 10.1023/A



- Jain, A., & Ormsbee, L. E. (2002). Short-term water demand forecast modeling techniques - Conventional methods versus AI. *Journal American Water Works Association*, 94 (7), 64-7. 10.1002/j.1551-8833.2002.tb09507.x
- Karamaziotis, P. I., Raptis, A., Nikolopoulos, K., Litsiou, K., & Assimakopoulos, V. (2020). An empirical investigation of water consumption forecasting methods. *International Journal of Forecasting*, 36(2), 588-606. 10.1016/j.ijforecast.2019.07.009.
- Kozłowski, E., Kowalska, B., Kowalski, D., & Mazurkiewicz, D. (2018). Water demand forecasting by trend and harmonic analysis. *Archives of Civil and Mechanical Engineering*, 18 (1), 140-148. 10.1016/j.acme.2017.05.006.
- Liu, J., Savenije, H. H. G., & Xu, J. (2003). Forecast of water demand in Weinan City in China using WDF-ANN model. *Physics and Chemistry of the Earth*, 28 (4-5), 219-224. 10.1016/S0022-1694(00)00287-0
- Lorente-Leyva, L. L. et al. (2019). Artificial Neural Networks for Urban Water Demand Forecasting: A Case Study. *Journal of Physics: Conference Series*, 1284(1), 0-8. 10.1088/1742-6596/1284/1/012004.
- Makki, A. A., Stewart, R. A., Panuwatwanich, K., & Beal, C. (2013). Revealing the determinants of shower water end use consumption: Enabling better targeted urban water conservation strategies. *Journal of Cleaner Production*, 60, 129-146. 10.1016/j.jclepro.2011.08.007
- Makki, A. A., Stewart, R. A., Beal, C. D., & Panuwatwanich, K. (2015). Novel bottom-up urban water demand forecasting model: Revealing the determinants, drivers and predictors of residential indoor end-use consumption. *Resources, Conservation and Recycling*, 95, 15-37. *Resources, Conservation and Recycling*, 10.1016/j.resconrec.2014.11.009.
- Makridakis, S., Wheelwright, S., & Hyndman, R., (1998). Forecasting: methods and applications. Third ed., *John Wiley & Sons*, New York.
- Matos, L. M. C., & Martinelli, F. J. (1998). Application of machine learning in water distribution networks. *Intelligent Data Analysis*, 2(4), 311-332. 10.3233/IDA-1998-2405
- Mohamed, M. M., & Al-Mualla, A. A. (2010). Water demand forecasting in Umm Al-Quwain using the constant rate model. *Desalination*, 259 (1-3), 161-168. 10.1016/j.desal.2010.04.014.
- Montgomery, D. C., Peck, E. A., & Vining, G. (2012). Introduction to linear regression analysis. Fifth ed. *John Wiley & Sons*, New Jersey.
- Mori, K., & Christodoulou, A. (2012). Review of sustainability indices and indicators: Towards a new City Sustainability Index (CSI). *Environmental impact assessment review*, 32 (1), 94-106. 10.1016/j.eiar.2011.06.001
- Nasseri, M., Moeini, A., & Tabesh, M. (2011). Forecasting monthly urban water demand using Extended Kalman Filter and genetic programming. *Expert Systems with Applications*, 38(6), 7387-7395. 10.1016/j.eswa.2010.12.087.
- Nguyen, K. A., Stewart, R. A., Zhang, H., Sahin, O., & Siriwardene, N. (2018). Re-engineering traditional urban water management practices with smart metering and informatics. *Environmental Modelling and Software*, 101, 256-267. 10.1016/j.envsoft.2017.12.015
- Oyebode, O., Babatunde, D. E., Monyei, C. G., & Babatunde, O. M. (2019). Water demand modelling using evolutionary computation techniques: integrating water equity and justice for realization of the sustainable development goals. *Heliyon*, 5(11), e02796. 10.1016/j.heliyon.2019.e02796
- Pagani, R. N., Kovaleski, J. L., & Resende, L. M. M. (2015). Methodi Ordinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication. *Scientometrics*, 105(3), 2109-2135, 10.1007/s11192-015-1744-x.
- Pagani, R. N., Kovaleski, J. L., & Resende, L. M. M. (2017). Avanços na composição da Methodi Ordinatio para revisão sistemática de literatura. *Ciência da Informação*, 46(2). 10.18225/ci.inf.v47i1.1886.
- Pagani, R. N., Pedroso, B., dos Santos, C. B., Picinin, C. T., & Kovaleski, J. L. (2022). Methodi Ordinatio 2.0: revisited under statistical estimation, and presenting FIndex and RankIn. *Quality & Quantity*, 1-40.
- Palit, A. K., & Popovic, D. (2005) Computational Intelligence in Time Series Forecasting: Theory and Engineering Applications. *Springer*, London.
- Pesantez, J. E., Berglund, E. Z., & Kaza, N. (2020). Smart meters data for modeling and forecasting water demand at the user-level. (2020). *Environmental Modelling and Software*, 125, art. no. 104633. 10.1016/j.envsoft.2020.104633.
- Pulido-Calvo, I., Montesinos, P., Roldán, J., & Ruiz-Navarro, F. (2007). Linear regressions and neural approaches to water demand forecasting in irrigation districts with telemetry systems. *Biosystems Engineering*, 97(2), 283-293. 10.1016/j.biosystemseng.2007.03.003.
- Qi, C., & Chang, N. (2011). System dynamics modeling for municipal water demand estimation in an urban region under uncertain economic impacts. *Journal Of Environmental Management*, 92(6), 1628-1641. 10.1016/j.jenvman.2011.01.020.
- Rathnayaka, K., Malano, H., Arora, M., George, B., Maheepala, S., & Nawarathna, B. (2017). Prediction of urban residential end-use water demands by integrating known and unknown water demand drivers at multiple scale: Model development. *Resources, Conservation and Recycling*, 117, 85-92. 10.1016/j.resconrec.2016.11.014.
- Russell, R. S., & Taylor, B. W. (2011). Operations management: creating value along the supply chain. Seventh ed. *Wiley*, New York.
- Sanchez, G. M., Terando, A., Smith, J. W., García, A. M., Wagner, C. R., & Meentemeyer, R. K. (2020). Forecasting water demand across a rapidly urbanizing region. *The Science of the total environment*, 730, 139050. 10.1016/j.scitotenv.2020.139050.
- Sebri, M. (2016). Forecasting urban water demand: A meta-regression analysis. *Journal of Environmental Management*, 183, 777-785. 10.1016/j.jenvman.2016.09.032



- Shabani, S., Yousefi, P., & Naser, G. (2017). Support Vector Machines in Urban Water Demand Forecasting Using Phase Space Reconstruction. *Procedia Engineering*, 186, 537-543. 10.1016/j.proeng.2017.03.267.
- Thopil, G. A., & Pouris, A. (2016). A 20 year forecast of water usage in electricity generation for South Africa amidst water scarce conditions. *Renewable and Sustainable Energy Reviews*, 62, 1106-1121. <https://doi.org/10.1016/j.rser.2016.05.003>.
- Torraco, R. J. (2005). Writing integrative literature reviews: Guidelines and examples. *Human resource development review*, 4(3), 356-367. 10.1177/1534484305278283
- UN - United Nations (2019). Department of Economic and Social Affairs, Population Division. World Urbanization Prospects: The 2018 Revision (ST/ESA/SER.A/420). United Nations. <https://population.un.org/wup/Publications/Files/WUP2018-Report.pdf>
- UNESCO (2019). World Water Assessment Programme (WWAP). The United Nations World Water Development Report 2019: Leaving no one behind. UNESCO, Paris. <https://reliefweb.int/sites/reliefweb.int/files/resources/367306eng.pdf>
- Vijai, P., & Bagavathi S. P. (2016). Design of IoT Systems and Analytics in the Context of Smart City Initiatives in India. *Procedia Computer Science*, 92, 583-588. 10.1016/j.procs.2016.07.386.
- Vijai, P., & Bagavathi, S. P. (2018). Performance comparison of techniques for water demand forecasting. *Procedia Computer Science*, 143, 258-266. 10.1016/j.procs.2018.10.394.
- Walker, D., Creaco, E., Vamvakieridou-Lyroudia, L., Farmani, R., Kapelan, Z., & Savić, D. (2015). Forecasting domestic water consumption from smart meter readings using statistical methods and artificial neural networks. *Procedia Engineering*, 119(1), 1419-1428. 10.1016/j.proeng.2015.08.1002.
- Wang, K., & Davies, E. G. R. (2018). Municipal water planning and management with an end-use based simulation model. *Environmental Modelling and Software*, 101, 204-217. 10.1016/j.envsoft.2017.12.024.
- Yin, Q.-Q., & Fang, G.-H. (2014). Harmoniousness analysis of total amount control of water use. *Water Science and Engineering*, 7(1), 49-59. 10.3882/j.issn.1674-2370.2014.01.006.
- Yousefi, P., Shabani, S., Mohammadi, H., & Naser, G. (2017). Gene Expression Programming in Long Term Water Demand Forecasts Using Wavelet Decomposition. *Procedia Engineering*, 186, 544-550. 10.1016/j.proeng.2017.03.268.
- Yurdusev, M. A., & Firat, M. (2009). Adaptive neuro fuzzy inference system approach for municipal water consumption modeling: An application to Izmir, Turkey. *Journal of Hydrology*, 365 (3-4), 225-234. 10.1016/j.jhydrol.2008.11.036.
- Zeng, Y., Cai, Y., Jia, P., & Jee, H. (2012). Development of a web-based decision support system for supporting integrated water resources management in Daegu city, South Korea. *Expert Systems with Applications*, 39 (11), 10091-10102. 10.1016/j.eswa.2012.02.065.
- Zhou, S. L., McMahon, T. A., Walton, A., & Lewis, J. (2000). Forecasting daily urban water demand: A case study of Melbourne. *Journal of Hydrology*, 236 (3-4), 153-164. 10.1016/S0022-1694(00)00287-0.
- Zhou, S. L., McMahon, T. A., Walton, A., & Lewis, J. (2002). Forecasting operational demand for an urban water supply zone *Journal of Hydrology*, 259 (1-4), 189-202. 10.1016/S0022-1694(01)00582-0.