

Arquitetura baseada em Computação em Névoa para Sistemas de Gerenciamento Inteligente de Água

Leonan Oliveira¹, Manollo Martinez¹, Bruno Kuehne²,
Bruno Batista², Dionisio Leite³, Maycon Peixoto¹

¹ Universidade Federal da Bahia (UFBA)
Salvador – BA – Brasil

² Universidade Federal de Itajubá (UNIFEI)
Itajubá – MG – Brasil

³ Universidade Federal do Mato Grosso do Sul (UFMS)
Ponta Porã – MS – Brasil

leonan.teixeira@gmail.com, maycon.leone@ufba.br

Abstract. *The necessity for new technologies to Water Management Systems has been increasingly relevance due to population growth and constant climate change. Water scarcity is often a problem in many regions across the world. Smart Water Management Systems have been proposed for various sectors of society. These systems seek through information and communication technology to improve the management of such resources. In this way, this article presents a Fog network architecture to monitor dams by wireless sensors and proposes a demand response control mechanism based on the statistical model SARIMA, whose aims to reduce the use of reservoirs in periods of scarcity balancing its use and avoiding that the reservoir reaches its minimum volume.*

Resumo. *A necessidade de novas tecnologias para o gerenciamento dos recursos hídricos tem tido cada vez mais relevância devido ao crescimento populacional e as constantes mudanças climáticas. A escassez de água é frequentemente um problema em diversas regiões do mundo. Sistemas de Gerenciamento Inteligente de Água tem sido propostos para diversos setores da sociedade, estes sistemas buscam através de tecnologia de informação e comunicação aprimorar o gerenciamento de tais recursos. Desta forma, este artigo apresenta uma arquitetura de rede em névoa para monitoramento de represas por meio de sensores sem fio e propõe um mecanismo de controle de atendimento a demandas baseada no modelo estatístico SARIMA, que tem por finalidade reduzir a utilização do reservatórios em períodos buscando balancear a sua utilização evitando que o reservatório atinja seu volume mínimo.*

1. Introdução

A água representa um elemento essencial para a vida de todos os que habitam o nosso planeta, mas a natureza aleatória deste recurso, que se manifesta pela alternância de períodos úmidos e períodos secos, a torna ainda mais preciosa [Pedro-Monzonís et al. 2015]. O impacto da escassez desse recurso pode acarretar profundos problemas sociais, econômicos e ambientais. Não há consenso na definição de seca, contudo é possível dividir-las em dois tipos principais:

conceituais e operacionais. Por um lado, as definições conceituais são formuladas em termos gerais para descrever o conceito de seca. De acordo com este tipo de definição, como observado por [Estrela and Vargas 2012], a seca é um perigo natural que resulta de uma deficiência de precipitação do esperado ou normal, o que pode, por sua vez, traduzir em quantidades insuficientes de água para atender às necessidades dos ecossistemas e / ou atividades humanas. As definições operacionais são usadas para identificar o começo, o fim e a gravidade das secas. Nesse sentido, não existe uma definição operacional única de seca que possa ser usada em todos os contextos. Contudo em cada contexto esse é o conceito mais importante para o planejamento de ações preventivas para a redução de períodos de escassez. [Quiring 2009].

O uso da água em todo o mundo aumentou mais de seis vezes no último século, muito acima da taxa de crescimento populacional. Estima-se que cerca de 35% da população mundial sofre de estresse hídrico, situações de falta d'água grave, e cerca de 65% dos fluxos de rios globais e ecossistemas aquáticos estão sob grau de degradação moderado a alto [Kahil et al. 2016]. É previsto que até 2025, as retiradas de água aumentarão em 50% nos países em desenvolvimento e 18% nos países desenvolvidos devido ao crescimento industrial e da população. Em razão ao número crescente de regiões de escassez de água, mais de 2,8 bilhões de pessoas em 48 países enfrentarão estresse hídrico ou condições de escassez até 2025 [Hammetman 2013].

O gerenciamento da água é definido como a atividade de planejamento, desenvolvimento, distribuição e gerenciamento dos recursos hídricos [Robles et al. 2015]. Devido à complexidade das questões relacionadas à água, os sistemas de gerenciamento tradicionais têm demonstrado limitações e incapacidade de resolver os diversos problemas do setor. Portanto, há uma demanda por novas tecnologias capazes resolver tais problemas e melhorar a eficiência do gerenciamento da água. [Choi et al. 2016].

Desse modo, este trabalho propõe uma Arquitetura baseada em Névoa para Sistemas de Gestão Inteligente de Água (Fog-SWM) direcionado para a gestão de represas. Além disso, é proposto um algoritmo para atuar no controle da entrega da demanda da água com objetivo de minimizar períodos de volume mínimo da represa. O algoritmo utiliza uma base histórica de vazão da água do rio para construir um modelo utilizando o SARIMA (Auto-Regressivo Integrado de Médias Móveis Sazonal). O SARIMA tem sido considerada o melhor modelo estatístico para previsão de fluxos de rios e tem sido muito usado em diversos estudos sobre fluxos [Moeeni et al. 2017].

O ambiente foi implementado com a proposta de fornecer dados realistas para o experimento. Implementamos cenários completos para (i) entrada e saída do fluxo de água na represa, e (ii) volumes máximos e mínimos da represa. Os resultados do experimento apresentaram uma eficiência do algoritmo proposto em relação a uma heurística gulosa de gestão, reduzindo significativamente o número de dias em que a represa esteve em seu limite inferior, interferindo o mínimo na demanda total atendida, e conseguinte aumentando satisfação do usuário final.

O restante deste artigo está organizado da seguinte forma: a Seção 2 descreve trabalhos relacionados; A seção 3 apresenta conceitos relacionados à gestão inteligente de água; A Seção 4 apresenta uma proposta para uma arquitetura para um Sistema de Gerenciamento Inteligente de Água e um algoritmo para auxiliar na gestão de barragens; A Seção 5 descreve o ambiente e a metodologia do algoritmo proposto e a discussão dos resultados obtidos; A seção 6 apresenta as conclusões de nosso estudo.

2. Trabalhos Relacionados

[Wadekar et al. 2016] apresentam um sistema baseado em IoT para auxiliar no gerenciamento e no planejamento do uso da água em residências. A proposta é que uma bomba de água e um sensor de nível devam ser instalados na caixa de água da residência, os dados do sensor são enviados para um serviço na nuvem por meio de uma conexão com a internet, quando o serviço detecta um determinado nível de água a bomba é acionada, quando a caixa encher, a bomba é desligada. O sistema proposto também conta com um aplicativo de acompanhamento dos níveis de água da caixa. Os autores não utilizam nenhuma abordagem que permita identificar padrões de uso, nem efetuam algum tipo de pré-processamento dos dados antes de enviar os dados para a nuvem.

SWMI (Smart Water Management Initiative) é discutido em [Choi et al. 2016] este trabalho foi proposto pela K-water, uma empresa do governo Coreano que cuida do gerenciamento das águas no país. O SWMI é um paradigma de gerenciamento de água desenvolvido com base nas experiências da K-water na gestão da água, o modelo proposto utiliza tecnologias de informação e de comunicação para gerir todo o ciclo da água, assegurando a estabilidade, segurança e eficiência do uso da água. Os autores sugerem três etapas para a implementação do SWMI, a primeira consiste no desenvolvimento de tecnologias necessárias para o SWMI baseando nas tecnologias atuais, a segunda etapa é a padronização das tecnologias com o propósito de facilitar a conectividade e melhorar a eficiência da aplicação das tecnologias, a última etapa é a padronização de um framework com o objetivo de aplicar as tecnologias desenvolvidas, a definição do framework deve contar com partes customizáveis e modularizáveis que resolvem diferentes tipos de problemas.

[Robles et al. 2015] apresenta um modelo de arquitetura para um sistema de gerenciamento inteligente de água baseado em IoT voltado para a indústria, utilizam como base o padrão arquitetural OPC UA (*object linking and embedding for process control unified architecture*), padrão utilizado em processos industriais com a finalidade de padronizar a comunicação entre serviços. Com base nesse padrão os autores propõem um modelo de gerenciamento inteligente de água que combina IoT com sistemas de coordenação de processos de negócios e de apoio a decisão.

De acordo com [Vijai and Sivakumar 2016] um sistema IoT típico consiste em um conjunto de sensores que monitoram o meio ambiente. Os dados produzidos por esses sensores são transmitidos para um sistema através de algum tipo de conectividade, os dados recebidos pelo sistema são armazenados e processados com o propósito de identificar padrões e produzir conhecimento que poderá ser utilizado para ativar sistemas de alerta ou mesmo facilitar a exibição dos dados para o usuário final. O artigo também apresenta técnicas de aprendizado de máquina utilizadas em Sistemas Inteligentes de Água atacando três de suas subáreas: (i) previsão de demanda de água, (ii) monitoramento da qualidade da água e (iii) detecção de anomalias. Para o primeiro caso (i) o autor trabalha com análise de séries temporais. Para o monitoramento da qualidade da água (ii), os autores identificaram que as técnicas mais utilizadas são as Redes Neurais Artificiais e sistemas *fuzzy*, para a identificação de anomalias (iii) técnicas estatísticas de identificação de *outliers* são as mais frequentes, contudo em algumas situações podem ser facilmente solucionadas com algoritmos de agrupamento.

Em [Moeeni et al. 2017] os autores propõem um método híbrido para previsão de vazão de rios baseado na junção do modelo estatístico SARIMA e no algoritmo evolucionário *gene expression programming (GEP)* chamado pelos autores de SARIMA-GEP e fazem um comparativo com os métodos isolados SARIMA, GEP bem como com os modelos baseados em

redes neurais artificiais (RNN) e o modelo híbrido SARIMA-RNN. O SARIMA-GEP apresentou melhores resultados para previsões mais longas comparados com os demais métodos utilizados para comparativo.

Ao contrário dos trabalhos encontrados na literatura, utilizamos o paradigma *Fog Computing* como uma extensão da *Cloud Computing* para executar serviços diretamente na extremidade da rede, oferecendo baixa latência e computação em tempo real. A *Fog* deve continuar a armazenar e processar os dados para a tomada de decisões, mesmo de forma autônoma, independentemente do estado da infraestrutura. No entanto, para que este modelo de infraestrutura funcione corretamente, é necessário oferecer alta disponibilidade e redundância. Desta forma, os serviços essenciais não são afetados se um dispositivo tiver problemas para se conectar à *Cloud*, pois a *Fog* irá garantir a integridade dos dados e a continuidade dos serviços nessas situações.

3. Gerenciamento Inteligente de Água

Os Sistemas de Gerenciamento Inteligente de Água (SWM) concentram-se em resolver problemas do gerenciamento de água por meios de tecnologias de informação e comunicação. Muitas tecnologias têm sido aplicadas para resolver problemas e aumentar a eficiência do gerenciamento da água. SWM utiliza a combinação de dispositivos de monitoramento, tecnologias de comunicação e a ciência dos dados para monitorar recursos, identificar problemas, melhorar eficiência e coordenar o gerenciamento. Com isso é possível contribuir também no processo de tomada de decisões que afetam diretamente aspectos sociais e econômicos. [Choi et al. 2016]

Várias aplicações automatizadas de monitoramento, gerenciamento e controle foram desenvolvidas nos últimos anos usando o conceito de Internet de Coisas (IoT). Sensores e atuadores tornaram-se cada vez mais poderosos, baratos e pequenos tornando o seu uso pervasivo. Os dados capturados através de sensores são transformados em informações inteligentes que, por sua vez, são usadas para decidir sobre como os atuadores devem agir, contribuindo desse modo para tornar o ambiente inteligente. A IoT é fundamental para a construção do SWM. Na verdade, há uma variedade de sensores para monitorar a água em aplicações industriais e domésticas, tais como: sensores de fluxo, temperatura, nível, sensores de qualidade (Ph, Turbidity), entre outros. Além disso, os atuadores podem funcionar ativando equipamentos como: bombas, válvulas, chaves [Prasad et al. 2015, Cherukutota and Jadhav 2016].

Ambientes IoT podem produzir uma grande quantidade de dados que podem ser utilizados para diversos propósitos, em geral, os dados precisam ser analisados para a extração de informações inteligentes, muitas vezes o armazenamento e os sistemas de análise requerem um poder computacional que não estão presentes nos dispositivos. A *Cloud Computing* pode ajudar provendo toda a infraestrutura necessária e de forma escalável. Entretanto o massivo tráfego de dados na rede gerados pela transmissão de dados dos sensores para plataformas em *Cloud* e a necessidade de respostas rápidas para sistemas críticos levaram ao surgimento de um novo paradigma: A *Fog Computing*. [Dastjerdi and Buyya 2016]

Utilizamos a *Fog* como uma extensão da *Cloud* com o propósito de executar serviços na borda da rede, oferecer serviços com baixa latência e computação em tempo real. Em nosso trabalho, a *Fog* armazena e processa os dados para a tomada de decisão, de forma autônoma, independentemente do estado do infraestrutura em *Cloud*. Desta forma, os serviços essenciais não são afetados se um dispositivo tiver problemas para se conectar à *Cloud*, isso porque, a *Fog* garantirá a integridade dos dados e a continuidade dos serviços

nessas situações. Além disso, a *Fog* tem o papel de reduzir o tráfego de dados na rede. Visto que uma rede de sensores podem produzir uma carga de dados elevada capaz de inundar uma rede e comprometer seu funcionamento, a *Fog* pode realizar a coleta, armazenamento e análise de dados, reduzindo assim a quantidade de dados que são enviados aos servidores na *Cloud* [Bonomi et al. 2012, Adhatarao et al. 2017, Al-Fuqaha et al. 2015].

4. Fog-SWM

Em função da situação atual e do histórico dos níveis da represa e do fluxo do rio, o Fog-SWM atua no controle do fluxo de saída de água da represa, a fim de prevenir que a represa atinja seu volume mínimo também conhecido como volume morto. Nós utilizamos o modelo estatístico SARIMA para identificar prováveis períodos de escassez e a partir dos dados obtidos atuamos no controle do fluxo de saída. Este trabalho não abrange a melhor forma de distribuição da água, o Fog-SWM atua somente no controle da barragem.

4.1. Arquitetura Fog-SWM

A estrutura geral do Fog-SWM é apresentada na Figura 1 e foi definida a partir dos conceitos de Fog, ela está dividida em três camadas.




Figura 1. Modelo do Fog-SWM

- **Camada 1:** é composta por sensores que estão monitorando o nível de água da represa, vazão do rio, vazão de saída para o sistema de tratamento e atuadores para controlar a vazão de saída. Esta deve continuamente fornecer dados para a camada superior.

- **Camada 2:** é composta por dispositivos de armazenamento e de computação, aqui os dados dos sensores serão recebidos, armazenados temporariamente e analisados, posteriormente serão enviados de forma resumida para a camada superior, reduzindo dessa forma a quantidade de dados que serão enviados para a camada 3.
- **Camada 3:** onde estão os *datacenters* da *Cloud*, aqui os dados resumidos da camada 2 serão recebidos por um sistema que manterá um histórico dos dados e executará as análises necessárias para atuar nos atuadores da camada 1.

A Figura 2 apresenta com mais detalhes o papel de cada camada da arquitetura no Fog-SWM.

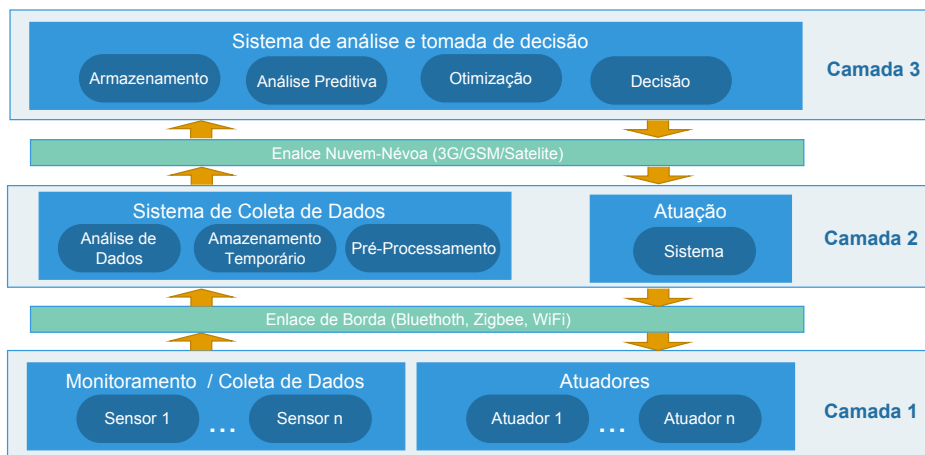


Figura 2. Arquitetura do Fog-SWM

Todos os dados coletados a partir dos sensores são analisados previamente nos *Gateway's* da *Fog*. Os componentes presentes na camada 2 da Figura 2 tem a função de reunir as médias diárias das medições. Depois disso, enviar-las para serem consumidas na camada 3. Na camada 3, os dados serão armazenados permanentemente. A partir dos dados históricos armazenados, e do estado atual da represa, o componente de análise da terceira camada realizará uma análise preditiva. Com base no resultado desta previsão e da observação atual, o Fog-SWM tentará otimizar a saída para reduzir os períodos em que o volume da barragem permanecerá no volume volume morto, momento em que a água torna-se imprópria para consumo.

4.2. Predição dos dados com série temporal

A análise de séries temporais tem um papel importante no gerenciamento inteligente de água. Em nosso contexto, a modelagem de series temporais é a tarefa mais complexa. Series temporais são utilizadas para prever o futuro baseando-se no passado. A modelagem estatística é o mais antigo método de previsão de séries temporais. SARIMA é considerada o melhor tipo de modelo linear estatístico na previsão de escoamento de rios, e tem sido amplamente empregada em estudos sobre fluxos [Moeeni et al. 2017]. Por isso, com objetivo de melhorar a precisão da estimativa, utilizamos o modelo SARIMA.

4.3. Sistema de Tomada de Decisão

Depois de definido o método de previsão, o sistema deve utilizar os dados provenientes das previsões de vazão em conjunto com a média de demandas e o volume atual do reservatório

para obter o fator que definirá o atendimento a demanda no presente. O algoritmo proposto tem como parâmetro principal a quantidade de meses a frente em que tentará prever momentos de escassez para que possa no momento presente tomar decisões que evitem que o reservatório atinja o volume morto no período observado.

O volume útil do reservatório (VU) é dado pela diferença entre seu volume atual (VA) e o seu volume mínimo (VM) (Equação 1).

$$VU = (VA - VM) \quad (1)$$

O fator com base na previsão (FBP) é definida pela relação entre volume útil somado ao volume esperado pela demanda total esperada para o período (Equação 2). J é número de meses a frente que será observado, a função $prev(i)$ deve retornar a previsão do volume esperado para o mês "i" a partir do mês atual e a função DE deve retornar o volume da demanda esperado para J meses a frente.

$$FBP = \frac{VU + \sum_{i=1}^J prev(i)}{DE(J)}; \quad (2)$$

Quando a represa está com seu volume insuficiente para atender a demanda total para o mês atual, o fator que determina a vazão é dividido pela metade, isso deve ocorrer devido a possibilidade do fluxo esperado só chegar ao fim do mês, levando o reservatório a um estado crítico, então por medida protetiva esse caso é acionado quando existe um risco iminente do sistema entrar em colapso. O Algoritmo 1 deve retornar o fator que determinará o percentual de atendimento a demanda para aquele momento.

Algorithm 1: CalcularFator (i, J)

Result: Fator de atendimento
fator = FBP(i,J)
if *VU less than DE(1)* **then**
| fator = fator*0.5
if *fator more than 1* **then**
| **return** 1
else
| **return** fator
end

5. Avaliação de Desempenho

O desempenho é um critério fundamental na concepção, aquisição e utilização de sistemas informatizados. Neste artigo, a avaliação de desempenho é usada para selecionar o algoritmo de controle apropriado. A avaliação de desempenho é uma técnica importante para o setor acadêmico e industrial, pois produz resultados bastante confiáveis, economizando dinheiro e tempo. Além disso, serve para avaliar qualquer sistema. A avaliação de desempenho torna possível encontrar métricas que indiquem quantidade ou qualidade, verificando também a precisão, validade e significado da magnitude produzida durante a avaliação. Ela é usada para obter a maior precisão estatística possível, fornecendo a informação máxima com um número mínimo de experimentos. Além disso, mostra os efeitos de vários fatores no resultado observado além da interação entre eles.

Para a execução dos experimentos, foi implementado um ambiente de simulação com a linguagem Python, utilizando a biblioteca Simpy¹. Além disso, para fins comparativos, uma heurística gulosa foi definida em que, sempre que houver água suficiente para atender a demanda, ela será atendida. No final da simulação de cada cenário, apresenta-se o número de dias em que a barragem esteve em volume morto e o total da demanda atendida para todo o período. Esse trabalho limitou-se a utilizar apenas as variáveis apresentadas acima, não levando em consideração outras variáveis como precipitação, infiltração e evaporação.

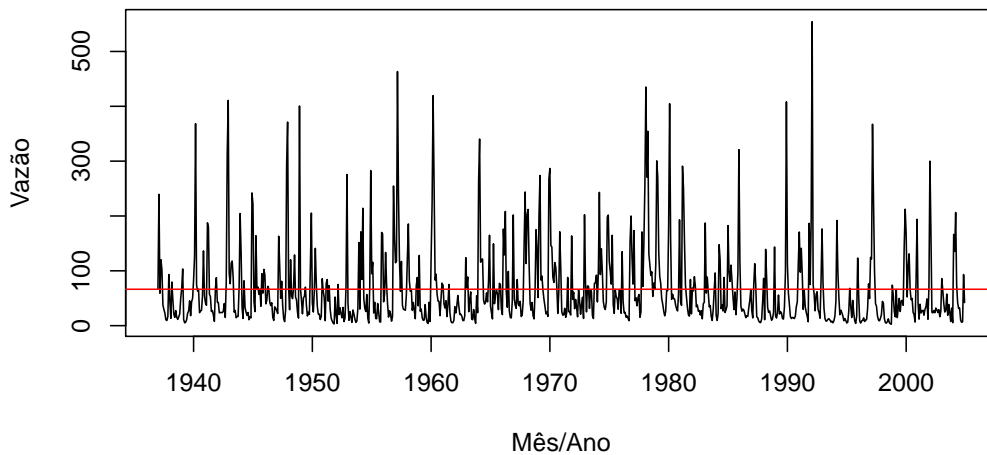


Figura 3. Série temporal da vazão do Rio Paraguaçu entre 1937 e 2004

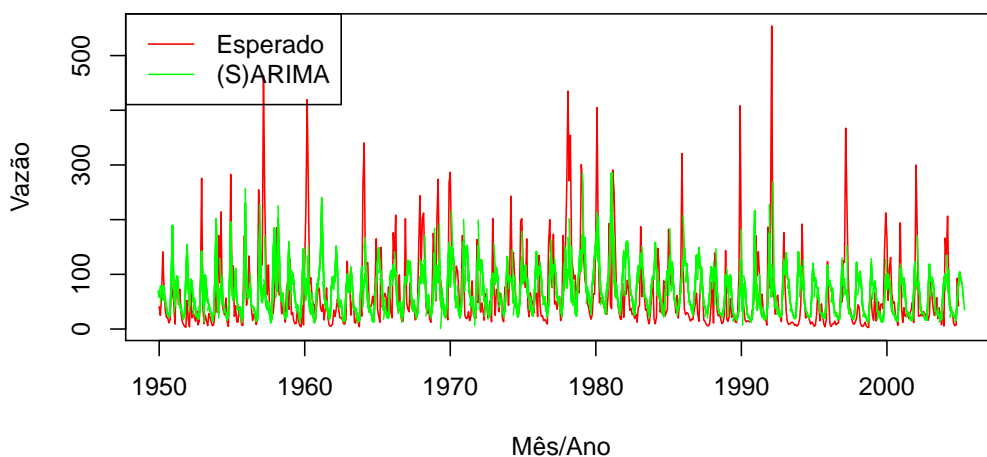


Figura 4. Predição de vazão da vazão do Rio Paraguaçu entre 1950 e 2004

As médias históricas mensais utilizadas foram retiradas da sistema HidroWeb da [Agência Nacional de Águas 2017] (ANA) observadas no Rio Paraguaçu nas imediações

¹Disponível em <<https://simpy.readthedocs.io/en/latest/>> Acessado em: 20/12/2017.

do município de Itaeté entre janeiro de 1937 e dezembro de 2014². A Figura 3 apresenta a série temporal de vazão do rio e é dada em m³/s, a linha traçada em vermelho é a média das vazões para todo o período. Os dados compreendidos entre janeiro de 1937 e dezembro de 1949 foram utilizados exclusivamente para o treinamento inicial do modelo SARIMA, portanto os resultados da simulação estão situados entre janeiro de 1950 e dezembro de 2004. Para o nosso modelo, o conjunto de parâmetros que mais se adequou ao conjunto de dados foi o $ARIMA(0,0,1)(1,1,1)_{12}$, sendo $(0,0,1)$ a parte não sazonal do modelo, $(1,1,1)$ a parte sazonal do modelo, e 12 a quantidade de períodos (Figura 4).

Os experimentos foram planejados utilizando o modelo de experimentos fatorial 2^k , apresentando por [Jain 1991]. Para o projeto de experimento deste trabalho foram considerados os seguintes fatores que influenciam no resultado final do sistema: Fator A – Algoritmo [Abordagem Guloso, Fog-SWM], Fator B – Capacidade do Reservatório [500 Hm³, 700 Hm³], Fator C – Demanda [45m³s, 50m³s], Fator D – Janela de Observação [4 meses, 6 meses]. Os níveis dos fatores B e C foram definidos de acordo uma estimativa da vazão regularizada do Rio observado, os níveis do Fator D foram definidos durante a observação da execução do experimentos, os valores escolhidos foram os que de forma geral apresentaram um melhor resultado. A Tabela 1 apresentam os 16 cenários obtidos a partir do planejamento fatorial 2^k aplicando os devidos fatores e níveis.

Tabela 1. Experimentos

Nº	A: Algoritmo	B: Capacidade	C: Demanda	D: Janela
1	<i>Guloso</i>	500 Hm ³	45m ³ s	4
2	<i>Guloso</i>	500 Hm ³	45m ³ s	6
3	<i>Guloso</i>	500 Hm ³	50m ³ s	4
4	<i>Guloso</i>	500 Hm ³	50m ³ s	6
5	<i>Guloso</i>	700 Hm ³	45m ³ s	4
6	<i>Guloso</i>	700 Hm ³	45m ³ s	6
7	<i>Guloso</i>	700 Hm ³	50m ³ s	4
8	<i>Guloso</i>	700 Hm ³	50m ³ s	6
9	<i>Fog-SWM</i>	500 Hm ³	45m ³ s	4
10	<i>Fog-SWM</i>	500 Hm ³	45m ³ s	6
11	<i>Fog-SWM</i>	500 Hm ³	50m ³ s	4
12	<i>Fog-SWM</i>	500 Hm ³	50m ³ s	6
13	<i>Fog-SWM</i>	700 Hm ³	45m ³ s	4
14	<i>Fog-SWM</i>	700 Hm ³	45m ³ s	6
15	<i>Fog-SWM</i>	700 Hm ³	50m ³ s	4
16	<i>Fog-SWM</i>	700 Hm ³	50m ³ s	6

5.1. Discussão e Análise dos Resultados

Inicialmente executamos 10 replicações para cada experimento. Em todos os experimento obtivemos pouca variação nos resultados, tornando assim dispensável a execução de mais replicações. Todos os experimentos foram avaliados a partir do intervalo de confiança de 95% obtidos através da tabela t-student.

²Disponível em <<http://www.snirh.gov.br/hidroweb/Estacao.asp?Codigo=51240000>> Acessado em: 20/12/2017.

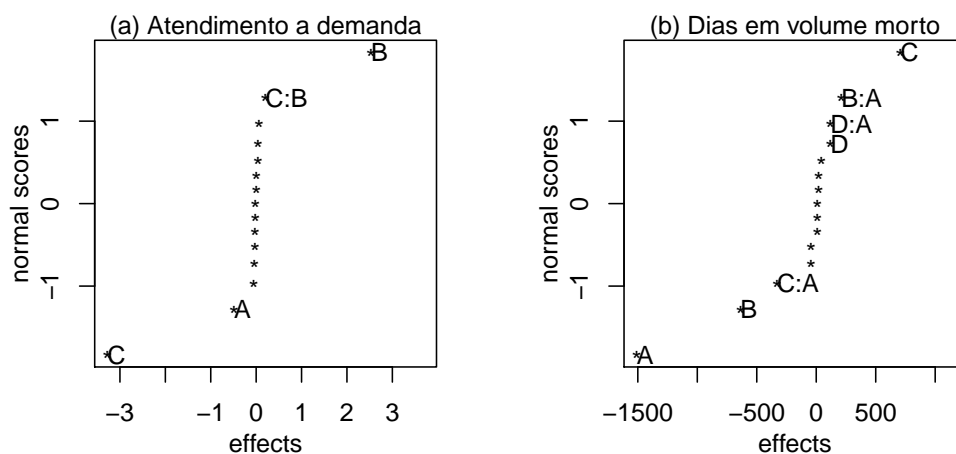


Figura 5. Gráfico normal dos efeitos




Figura 6. Influência dos fatores

Para identificar os fatores de maior significância no resultado do experimento a Figura 5 apresenta os gráficos normais dos efeitos dos fatores sobre as variáveis de resposta. Na Figura 5(a) é possível observar que a demanda e a capacidade são os fatores que tem maior significância sobre o atendimento a demanda e o algoritmo tem uma leve significância, também é possível observar que quando o algoritmo é alterado de "Guloso" para "Fog-SWM" ou a demanda é elevado de $45\text{m}^3\text{s}$ para $50\text{m}^3\text{s}$ há uma redução no atendimento a demanda.

Contudo o efeito provocado pelo algoritmo é menor comprado ao efeito produzido pela elevação da demanda, por outro lado, ao elevar a capacidade de 500Hm^3 para 700Hm^3 há um aumento no atendimento a demanda. Esse comportamento também pode ser confirmado observado a Figura 7 que apresenta os principais efeito dos fatores em relação ao atendimento a demanda.

Na Figura 5(b) é possível observar que o algoritmo e a demanda seguidos pela capacidade têm os maiores níveis de significância em relação a quantidade de dias em que

o reservatório atinge o seu volume mínimo, de acordo o gráfico ao altear o algoritmo de "Guloso" para o "Fog-SWM" há uma redução da variável resposta, o mesmo ocorre ao elevar capacidade do reservatório de 500 Hm³ para 700 Hm³, por outro lado, a elevação da demanda causa um aumento a variável resposta. Esse comportamento pode ser observado no gráfico da Figura 8 que apresenta os principais efeito dos fatores em relação a quantidade de dias em volume morto.




Figura 7. Principais Efeitos: Atendimento à demanda




Figura 8. Principais Efeitos: Dias em volume morto

Na Figura 6 são apresentadas as influências dos fatores nas variáveis de resposta. O algoritmo teve uma influência de 1,30% no atendimento a demanda, enquanto a capacidade e a demanda tiveram uma influência de 35,56% e 59,60% respectivamente. A baixa influência do algoritmo no atendimento a demanda reflete um comportamento esperado, visto que o algoritmo deve interferir o mínimo possível na quantidade total de água entregue a população, contudo é esperado que o algoritmo interfira diretamente na quantidade de dias em que o reservatório permanece em volume morto, fato que é constatado na Figura 6(b) que mostra o fator algoritmo com influência de 66,14% na variável resposta. A demanda foi o fator mais influente no atendimento da demanda, visto que a variação da quantidade de água exigida para suprir a necessidade está diretamente ligada com a taxa de entrada de água no reservatório, ao aumentar a demanda sem que se altere a taxa de entrada haverá um desequilíbrio no sistema, isso também é refletido na quantidade de dias em volume morto, já que o aumento da demanda provoca um esvaziamento mais rápido do reservatório.

A correlação apresentada entre os fatores é pequena, apresentando pouca significância. As maiores influências no atendimento a demanda entre fatores correlacionados são entre os fatores demanda e janela (3,14%) Figura 6(a) e entre os fatores algoritmo e demanda (3,15%) Figura 6(b) na quantidade de dias em volume morto. A Figura 9 apresenta um conjunto de gráficos que descreve a interação entre os fatores. Para ambas as variáveis resposta a única interação observada foi entre o fator Algoritmo e Janela, a combinação do Fog-SWM com uma janela de observação de 4 meses apresentou o melhor resultado. Os demais resultados apresentam retas paralelas que indicam interação não significativa.

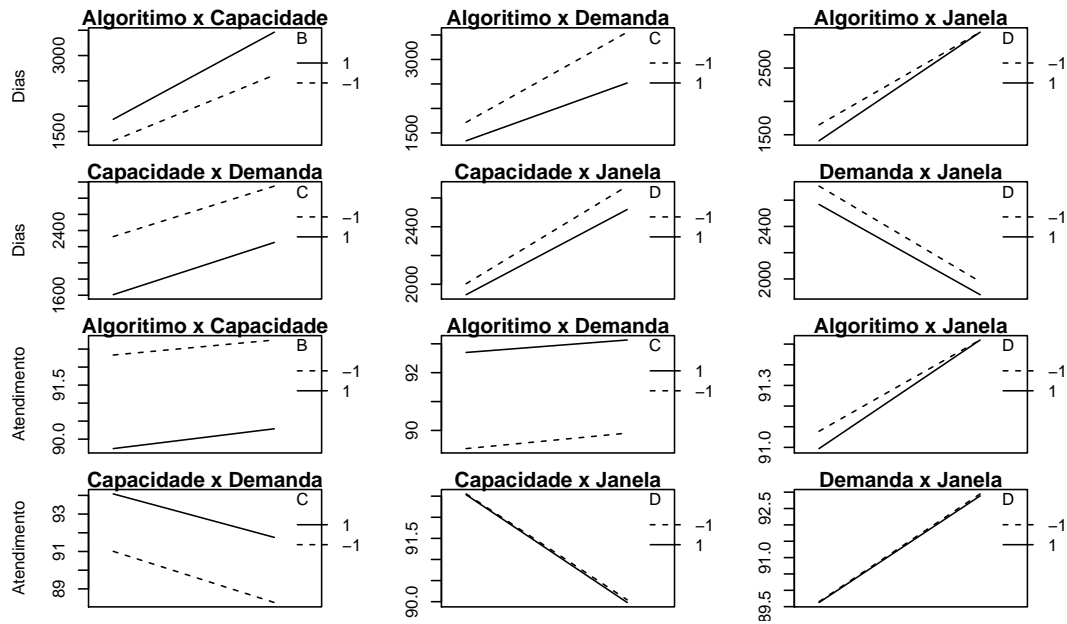


Figura 9. Interação entre os fatores




Figura 10. Frequência do volume do reservatório

A Figura 10 apresenta o histograma do volume da represa em cada dia da simulação observando os experimentos 1 e 9, que correspondem ao uso do algoritmo Guloso e o Fog-SWM respectivamente em conjunto a seguinte configuração de fatores: capacidade de 500 Hm^3 , demanda de 45 m^3/s e janela de observação igual a 4. Nota-se que o uso do algoritmo provocou uma queda de quase metade dos dias em que a represa esteve em seu volume mínimo.




Figura 11. Médias do total das demandas entregues dos experimentos

Na Figura 11 é apresentando o gráfico com as médias das demandas entregues para

cada experimento, as colunas estão agrupadas para facilitar a visualização da diferença entre os algoritmos, observa-se uma variação mínima entre os algoritmos, a média da diferença entre os algoritmos é de 0,48%, o que mostra uma baixa interferência do Fog-SWM sobre o total da demanda entregue.

6. Conclusão

Neste artigo nós propomos a Fog-SWM (*Fog Computing Architecture to Improvement the Smart Water Management*). A Fog-SWM é uma arquitetura com o objetivo de melhorar o Gerenciamento Inteligente de Água. A Fog-SWM executa o controle do fluxo de saída da água a fim de minimizar períodos em que a barragem atinge seu volume mínimo, maximizando a satisfação do usuário ao longo do ano. O Fog-SWM usa o modelo estatístico SARIMA.

Por meio da avaliação de desempenho aplicada ao ambiente experimentado foi possível verificar uma redução significativa do número de dias em que a barragem permanece em volume morto e uma melhor distribuição do recurso durante dias de escassez utilizando a Fog-SWM. Foi observado uma redução de 49,9% dos dias em que o volume do reservatório esteve em volume morto, de 32% dos dias em que o reservatório esteve abaixo dos 20% e de 13% para os dias em que o reservatório esteve abaixo dos 30%. Mesmo alterando a capacidade do reservatório ou a demanda, o fator Algoritmo foi o que possuiu maior relevância. A diminuição do número de dias da barragem no volume mínimo e a manutenção da demanda mostram que a Fog-SWM, por meio do seu algoritmo, foi capaz de manter o atendimento da demanda e reduzir o número de dias em que o serviço foi interrompido completamente, distribuindo melhor a água em momentos de escassez.

Em geral, as principais contribuições deste artigo são: uma Arquitetura de *Fog Computing* como uma extensão da *Cloud Computing* para o Gerenciamento Inteligente de Água que pode ajudar no processo de tomada de decisão no gerenciamento de água em barragens. A arquitetura proposta do *Fog-SWM* pode fornecer baixa latência e tolerância a falhas. No caso de tolerância a falhas, a Fog-SWM possui resiliência para operar em ambientes inóspitos (normalmente onde as barragens estão localizadas), mesmo de forma autônoma, independentemente do estado da infraestrutura *Cloud*. Desta forma, nossos serviços essenciais não são afetados se um dispositivo tiver problemas para se conectar à *Cloud*, pois o Fog-SWM irá garantir a integridade dos dados e a continuidade dos serviços nessas situações.

7. Agradecimentos

Os autores agradecem à FAPESB, FAPEMIG, CAPES, CNPq e à parceria MCTIC-UFBA - (Ministério da Ciência, Tecnologia, Inovação e Comunicação do Brasil) pelo apoio financeiro através do PROPCI/PROPG/PROPESQ/UFBA-004/2016.

Referências

- Adhatarao, S. S., Arumathurai, M., and Fu, X. (2017). FOGG: A Fog Computing Based Gateway to Integrate Sensor Networks to Internet. *2017 29th International Teletraffic Congress (ITC 29)*, pages 42–47.
- Agência Nacional de Águas (2017). Hidroweb.
- Al-Fuqaha, A., Guizani, M., Mohammadi, M., Aledhari, M., and Ayyash, M. (2015). Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications. *IEEE Communications Surveys and Tutorials*, 17(4):2347–2376.

- Bonomi, F., Milito, R., Zhu, J., and Addepalli, S. (2012). Fog computing and its role in the internet of things. In *Proceedings of the first edition of the MCC workshop on Mobile cloud computing - MCC '12*, page 13, New York, New York, USA. ACM Press.
- Cherukutota, N. and Jadhav, S. (2016). Architectural framework of smart water meter reading system in IoT environment. *2016 International Conference on Communication and Signal Processing (ICCSP)*, 400019:0791–0794.
- Choi, G. W., Chong, K. Y., Kim, S. J., and Ryu, T. S. (2016). SWMI: new paradigm of water resources management for SDGs. *Smart Water*, 1(1):3.
- Dastjerdi, A. V. and Buyya, R. (2016). Fog Computing: Helping the Internet of Things Realize Its Potential. *Computer*, 49(8):112–116.
- Estrela, T. and Vargas, E. (2012). Drought Management Plans in the European Union. The Case of Spain. *Water Resources Management*, 26(6):1537–1553.
- Hameeteman, E. (2013). Future water (In)security: facts, figures, and predictions. page 16.
- Jain, R. (1991). *The Art of Computer Systems Performance Analysis: Techniques for Experimental Design, Measurement, Simulation, and Modeling*. Winner of “1991 Best Advanced How-To Book, Systems” award from the Computer Press Association.
- Kahil, M. T., Dinar, A., and Albiac, J. (2016). Cooperative water management and ecosystem protection under scarcity and drought in arid and semiarid regions. *Water Resources and Economics*, 13:60–74.
- Moeeni, H., Bonakdari, H., and Ebtehaj, I. (2017). Monthly reservoir inflow forecasting using a new hybrid SARIMA genetic programming approach. *Journal of Earth System Science*, 126(2).
- Pedro-Monzonís, M., Solera, A., Ferrer, J., Estrela, T., and Paredes-Arquiola, J. (2015). A review of water scarcity and drought indexes in water resources planning and management. *Journal of Hydrology*, 527:482–493.
- Prasad, A. N., Mamun, K. A., Islam, F. R., and Haqva, H. (2015). Smart water quality monitoring system. *2nd Asia-Pacific World Congress on Computer Science and Engineering, APWC on CSE 2015*, pages 1–6.
- Quiring, S. M. (2009). Developing objective operational definitions for monitoring drought. *Journal of Applied Meteorology and Climatology*, 48(6):1217–1229.
- Robles, T., Alcarria, R., Martín, D., Navarro, M., Calero, R., Iglesias, S., and López, M. (2015). An IoT based reference architecture for smart water management processes. *Journal of Wireless Mobile Networks, Ubiquitous Computing, and Dependable Applications (JoWUA)*, 6(1):4–23.
- Vijai, P. and Sivakumar, P. B. (2016). Design of IoT Systems and Analytics in the Context of Smart City Initiatives in India. *Procedia - Procedia Computer Science*, 92:583–588.
- Wadekar, S., Vakare, V., Prajapati, R., Yadav, S., and Yadav, V. (2016). Smart Water Management Using IOT. *2016 5th International Conference on Wireless Networks and Embedded Systems (WECON)*, pages 1–4.