

MODELO DE PREVISÃO DE CONSUMO DE ÁGUA: ESTUDO DE CASO DE CAMPO VERDE/MT

Thaiza M. P. de Mello^{1*}; *Welitom T. P. da Silva*²; *Aldecy de A. Santos*³; *Paulo E. G. de Oliveira*⁴; *Ricardo A. M. Zaque*⁵

Resumo – A previsão de consumo de água é essencial quando se pretende aperfeiçoar a operação do sistema de abastecimento de água (SAA), de forma a oferecer um serviço de melhor qualidade, mais confiável e a um menor custo. Assim, o trabalho teve como objetivo desenvolver um modelo de previsão de consumo de água para curtíssimo prazo, que servirá como ferramenta de suporte a decisões operacionais no sistema de abastecimento de água da cidade de Campo Verde/MT. O modelo de previsão foi baseado em dados históricos de consumo de água, relacionados ao dia da semana, feriados, temperatura máxima e mínima do dia, umidade relativa máxima e mínima, e o perfil tipo de consumo dos três dias anteriores ao dia que se deseja prever. Na avaliação, o índice Kappa ($k = 0,57$) e a matriz de confusão indicaram moderada precisão do modelo de previsão. Recomenda-se a expansão do banco de dados que favoreça a obtenção de um modelo mais confiável.

Palavras-Chave – apoio a decisão, planejamento operacional, sistema especialista.

WATER CONSUMPTION FORECAST MODEL: CASE STUDY OF CAMPO VERDE/MT

Abstract – Prediction of water consumption is essential when improving the operation of the water supply system (SAA), in order to offer a better quality service, more reliable and at a lower cost. Thus, the objective of this work was to develop a very short-term water consumption forecasting model, which will serve as a tool to support operational decisions in the water supply system of the city of Campo Verde / MT. The forecast model was based on historical water consumption data, related to the day of the week, holidays, maximum and minimum temperature of the day, maximum and minimum relative humidity, and the consumption profile of the three days prior to the desired day predict. In the evaluation, the Kappa index ($k = 0.57$) and the confusion matrix indicated moderate prediction model accuracy. It is recommended to expand the database that favors obtaining a more reliable model.

Keywords – Decision support, operational planning, expert system.

¹Faculdade de Arquitetura, Engenharia e Tecnologia (FAET), Programa de Pós-graduação em Recursos Hídricos (PPGRH), Universidade Federal de Mato Grosso (UFMT) – Avenida Fernando Corrêa da Costa, Nº. 2367 – Bairro Boa Esperança. Cuiabá/MT – 78060-900, e-mail: thaiza_mello@hotmail.com

²Departamento de Engenharia Sanitária e Ambiental (DESA), Pós-graduação em Recursos Hídricos (PGRH), Universidade Federal de Mato Grosso (UFMT) – Avenida Fernando Corrêa da Costa, Nº. 2367 – Bairro Boa Esperança. Cuiabá/MT – 78060-900, e-mail: welitom@ufmt.br

³Departamento de Engenharia Sanitária e Ambiental (DESA), Pós-graduação em Recursos Hídricos (PGRH), Universidade Federal de Mato Grosso (UFMT) – Avenida Fernando Corrêa da Costa, Nº. 2367 – Bairro Boa Esperança. Cuiabá/MT – 78060-900, e-mail: aldecy_allmeida@yahoo.com.br

⁴Faculdade de Arquitetura, Engenharia e Tecnologia (FAET), Programa de Pós-graduação em Recursos Hídricos (PPGRH), Universidade Federal de Mato Grosso (UFMT) – Avenida Fernando Corrêa da Costa, Nº. 2367 – Bairro Boa Esperança. Cuiabá/MT – 78060-900, e-mail: edupauloliveira@yahoo.com.br

⁵Faculdade de Arquitetura, Engenharia e Tecnologia (FAET), Programa de Pós-graduação em Recursos Hídricos (PPGRH), Universidade Federal de Mato Grosso (UFMT) – Avenida Fernando Corrêa da Costa, Nº. 2367 – Bairro Boa Esperança. Cuiabá/MT – 78060-900, e-mail: ricardo_zaque@hotmail.com

1 – INTRODUÇÃO

A elevada taxa de urbanização, traduzida no crescimento populacional, e o aumento do consumo de água têm sobrecarregado e exigido respostas imediatas dos sistemas de abastecimento de água (SAA), numa época em que a escassez seja por quantidade ou qualidade de água disponível, já é uma realidade. Assim, torna-se necessário o emprego de ferramentas tecnológicas e de gestão, de modo que os processos operacionais sejam realizados eficientemente, e atenda aos requisitos de quantidade e qualidade, ao mesmo tempo em que preservam os recursos hídricos, e reduzem os custos operacionais e as perdas de água (MENESES, 2011).

Previsões precisas da demanda de água são fundamentais para a otimização no sistema de abastecimento de água, e pode ser realizada para um horizonte de longo, curto ou curtíssimo prazo. A operação, manutenção e ampliação dos sistemas, bem como a concepção de novos projetos, estão totalmente relacionadas à demanda de água (TSUTIYA, 2006). A previsão de longo prazo é geralmente utilizada para avaliar investimentos destinados à ampliação da capacidade do sistema, considerando as prováveis zonas de expansão da rede de abastecimento, e a eficácia advinda da implantação de medidas de conservação e uso racional da água, voltadas à redução das vazões médias demandadas. Já a previsão de curto e curtíssimo prazo fornece informações imediatas sobre a ocorrência de picos prolongados e flutuações acentuadas de demanda, servindo como suporte para tomada de decisão sobre as manobras operacionais que serão adotadas nas próximas horas ou nos próximos dias, e avaliação das medidas de conservação voltadas à redução dos picos de consumo (ODAN, 2010). O uso de métodos de previsão acarreta a minimização da subjetividade na tomada de decisão na operação diária do sistema de abastecimento de água. A identificação da perda física de água no sistema, o ganho de qualidade da água armazenada adequadamente, o planejamento da operação das elevatórias e das Estações de Tratamento de Água (ETA) de modo a evitar os períodos de altos valores da tarifa e a estimativa das variáveis de ajuste de controle de pressão e vazão ótimas ao longo do dia são algumas das diversas vantagens de se obter um modelo de previsão de consumo (FALKENBERG, 2005). Entre as diversas técnicas de previsão existem as que são baseadas em modelos estatísticos e baseados em sistemas inteligentes. O desenvolvimeto dos métodos de inteligência artificial (IA) fornece aos pesquisadores formas de codificar o conhecimento humano em um programa computacional (sistema especialista) e determinar o comportamento de um sistema baseado apenas no seu histórico, sem depender de modelagem matemática complexa e conhecimento profundo do sistema (GUIRELLI, 2006). O Sistema Especialista (SE) é uma técnica de inteligência artificial, destinado a representar o conhecimento sobre um domínio específico, a partir do processamento da base de conhecimento para solucionar determinados problemas, sem necessitar de associações complexas.

Estes modelos utilizam dados históricos que são estudados a fim de identificar os seus comportamentos e padrões para que sejam traçadas projeções futuras com base nos mesmos. Assim, o objetivo deste trabalho é o desenvolvimento de modelo para previsão do consumo de água em curtíssimo prazo, utilizando sistema especialista, baseado em dados históricos do sistema de abastecimento de água da cidade de Campo Verde, Estado de Mato Grosso (MT).

2 – METODOLOGIA

A metodologia consistiu nas seguintes etapas: (1) construção do modelo de previsão; (2) avaliação do conhecimento do modelo de previsão; e (3) interface do modelo de previsão.

Construção do modelo de previsão

O modelo de previsão de consumo de água foi construído a partir dos dezesseis perfis tipo de consumo diário de água obtidos no estudo realizado por Mello (2016) na cidade de Campo Verde/MT. O perfil tipo de consumo foi relacionado com as seguintes variáveis: o dia da semana, a existência ou não de feriados, a temperatura, a umidade relativa do ar e o perfil tipo de consumo de água dos três dias anteriores ao dia que se deseja prever. As informações de temperatura e umidade relativa do ar foram obtidas do banco de dados da Estação Meteorológica de Observação de Superfície Automática de Campo Verde, disponibilizado pelo Instituto Nacional de Meteorologia (INMET). Neste trabalho, foi utilizado a temperatura e umidade relativa máximas e mínimas de cada dia.

O banco de dados organizados contendo a variáveis influentes no modelo foi submetido ao processo de classificação. Para se encontrar a regras que descrevem as relações das classes de dados e seja capaz de prever a classe de um objeto ainda desconhecido utilizou-se o método de árvore de decisão com o classificador J48, disponível no ambiente Weka (*Waikato Environment for Knowledge Analysis*), versão 3.8.0.

Avaliação do conhecimento do modelo de previsão

A avaliação do conhecimento do modelo foi realizada pelo índice Kappa, indicador de exatidão e a confiança do classificador, categorizado empregando a Tabela 1 (TAVARES *et al.*, 2007) e também pela matriz de confusão que permite analisar o desempenho do classificador.

Tabela 1 – Interpretação de valores do índice Kappa

Índice Kappa (κ)	Nível de Exatidão do Classificador
< 0,20	Fraco
0,20 - 0,40	Regular
0,41 - 0,60	Moderado
0,61 - 0,80	Bom
> 0,81	Excelente

Fonte: Tavares *et al.* (2007)

Interface do modelo de previsão

A interface do modelo de previsão foi construída no MS Excel 2013 utilizando o *UserForms* do *Visual Basic Applications* (VBA). As regras de produção geradas pelo algoritmo J48 no processo de classificação foram traduzidas para linguagem VBA e codificadas no formulário do modelo.

3 – RESULTADOS E DISCUSSÃO

Para elaboração das regras de produção que descrevem o modelo de previsão proposto, cada dia contido no banco de dados estudado foi classificado conforme o perfil tipo (PT) de consumo determinado na etapa de agrupamento do estudo de Mello (2016) e relacionado às seguintes variáveis:

dia da semana (DS), existência ou não de feriados (FE), temperatura máxima (TPMA) e temperatura mínima (TPMI), umidade relativa máxima (URMA) e umidade relativa mínima (URMI), perfil tipo do dia anterior ao que se deseja prever (PT(-1)), perfil tipo de dois dias anteriores ao que se deseja prever (PT(-2)), e perfil tipo de três dias anteriores ao que se deseja prever (PT(-3)). Os valores de temperatura estão em graus Celsius (°C) e a umidade relativa em porcentagem (%).

A Tabela 2 apresenta a configuração do banco de dados contendo todas as variáveis mencionadas anteriormente, e representa uma parcela da base de conhecimento utilizada para geração das regras de produção que descrevem o modelo de previsão.

Tabela 2 – Representação do banco de dados do modelo de previsão

DS	FE	TPMA	TPMI	URMA	URMI	PT(-1)	PT(-2)	PT(-3)	PT
Segunda-feira	NÃO	33,7	22,2	54	17	PT16	PT15	PT8	PT1
Terça-feira	NÃO	32	20,9	55	31	PT1	PT16	PT15	PT8
Quarta-feira	NÃO	32,1	22,1	75	40	PT8	PT1	PT16	PT16
Quinta-feira	NÃO	30,8	19,1	73	34	PT16	PT8	PT1	PT3
Sexta-feira	NÃO	34	20,4	61	26	PT3	PT16	PT8	PT10
Sábado	NÃO	34,5	22,2	62	26	PT10	PT3	PT16	PT3
Domingo	NÃO	33,8	20,9	80	30	PT3	PT10	PT3	PT15

A técnica de mineração de dados foi aplicada ao banco de dados completo, buscando extrair regras de produção para se prever o consumo diário de água. Foi empregado o algoritmo J48 disponibilizado pelo Weka, que fornece a árvore de decisão mostrada na Figura 1.

```

PT(-1) = PT1: PT8 (4.0/1.0)
PT(-1) = PT2: PT2 (8.0/4.0)
PT(-1) = PT3
| TPMA <= 32.5: PT9 (2.0)
| TPMA > 32.5: PT10 (3.0/2.0)
PT(-1) = PT4: PT9 (0.0)
PT(-1) = PT5: PT8 (3.0/1.0)
PT(-1) = PT6: PT1 (3.0/2.0)
PT(-1) = PT7: PT7 (3.0/1.0)
PT(-1) = PT8
| DS = segunda-feira: PT12 (0.0)
(Continua)

```

Figura 1- Árvore de decisão gerada pelo algoritmo J48

Observando a árvore de decisão, nota-se que das variáveis inseridas no modelo, as mais relevantes para expressar as relações do banco de dados foram a temperatura máxima, umidade relativa máxima, dia da semana e o perfil tipo do dia anterior ao que se deseja prever. Verifica-se também com as regras, a possibilidade de se obter respostas iguais para diferentes entradas.

As Regras de Produção são obtidas facilmente pela conversão da árvore de decisão. As Equações 1 e 2 apresentam dois exemplos de regras que foram convertidas da árvore de decisão resultante da aplicação do algoritmo J48.

$$\begin{aligned} \text{Se } PT(-1) = PT3 & & (1) \\ \text{Então } PT = PT8 & \end{aligned}$$

$$\begin{aligned} \text{Se } PT(-1) = PT8 \text{ e} & & (2) \\ \text{DS} = \text{segunda - feira} & \text{ ou} \\ \text{DS} = \text{terça - feira} & \text{ ou} \\ \text{DS} = \text{quinta - feira} & \text{ ou} \\ \text{DS} = \text{sábado} & \text{ ou} \\ \text{DS} = \text{domingo} & \\ \text{Então } PT = PT12 & \end{aligned}$$

A interpretação da regra apresentada da Equação (1), menciona que: se o perfil do dia anterior ao que se deseja prever for o PT3, então o perfil de consumo do próximo dia será o PT8. Da mesma forma, para a Equação (2) temos que: se o perfil do dia anterior ao que se deseja prever for o PT8 e o dia da semana for segunda, terça, quinta-feira, sábado ou domingo, o perfil do próximo dia será o PT12. A avaliação do conhecimento do modelo de previsão foi realizada com o indicador de precisão a Estatística Kappa e com a Matriz de Confusão. O índice Kappa, k , descreve e testa o grau de concordância (confiabilidade e precisão) na classificação, e seus valores variam de 0 a 1. O valores próximos a 0 indicam baixa concordância entre o valor da entrada e o esperado, enquanto os valores próximos a 1 indica uma concordância quase perfeita.

O modelo proposto obteve índice Kappa igual a 0,57, estando portanto, na faixa entre 0,41 a 0,60 classificado como moderado segundo Tavares *et al.* (2007). A matriz de confusão também permitiu analisar o desempenho do algoritmo usado para gerar as regras de produção do modelo de previsão. A matriz contém informações muito importantes para o entendimento do resultado do algoritmo, dentre elas: a quantidade de instâncias classificadas corretamente, a quantidade de instâncias classificadas erroneamente e a quantidade de instâncias que o algoritmo acreditava ser de um tipo e na verdade foram classificadas como outro tipo. A Figura 2 apresenta a Matriz de Confusão do modelo de previsão de consumo, baseado no sistema especialista.

=== Confusion Matrix ===

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	← classified as
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a = PT1
0	6	0	0	0	0	0	0	1	1	0	0	0	0	0	0	b = PT2
0	1	1	0	0	0	0	0	0	2	0	0	0	0	0	0	c = PT3
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	d = PT4
1	0	0	0	1	0	0	0	0	0	0	1	0	0	0	0	e = PT5
1	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	f = PT6
0	0	0	0	0	0	2	0	0	0	0	1	0	0	0	0	g = PT7
0	0	0	0	0	0	0	7	0	0	0	1	0	0	0	0	h = PT8
0	2	0	0	0	0	0	0	17	5	0	0	0	0	0	0	i = PT9
1	2	0	0	0	0	0	0	1	12	0	0	0	0	0	0	j = PT10
0	0	1	0	0	0	1	0	0	1	0	0	0	0	0	0	k = PT11
1	0	0	0	1	0	0	0	0	0	0	5	0	0	0	0	l = PT12
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	m = PT13
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	m = PT14
0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	m = PT15
0	0	0	0	1	0	0	0	1	0	0	1	0	0	0	1	m = PT16

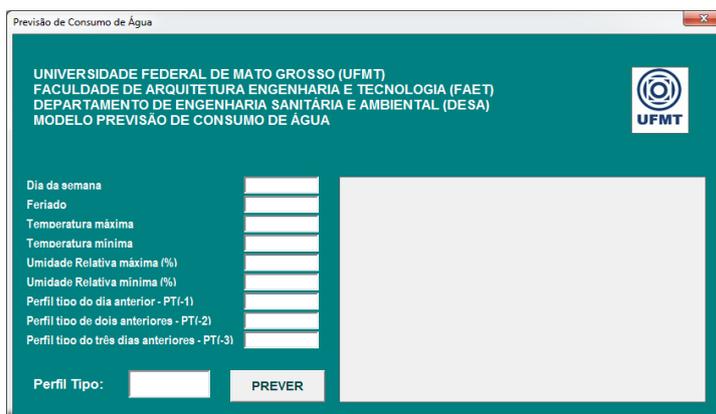
Figura 2 – Matriz de Confusão do modelo de previsão

A interpretação da Matriz expõe que para a classe do PT1, por exemplo, todas as instâncias foram classificadas corretamente. Para o PT11, não houve acerto na classificação, e foram classificados como PT3, PT7 e PT10. O banco de dados que foi submetido a classificação do

algoritmo J48 para extração das regras de produção é composto por informações de 88 dias, sendo assim, 88 instâncias, destas 63,6% foram classificadas corretamente, que corresponde aos números da diagonal principal da matriz.

A atividade de codificação, em ambiente VBA, do conhecimento resultante do processo de classificação, resultou em um protótipo de um Sistema Especialista capaz de relacionar o banco de dados, a máquina de inferência e a interface do usuário. A Figura 3 apresenta a interface do modelo SE de previsão de consumo para curtíssimo prazo para cidade de Campo Verde/MT.

A utilização do modelo SE consiste basicamente na inserção dos dados relativos ao dia que se deseja prever. O campo de dia da semana deve ser preenchido com: segunda, terça, quarta, quinta, sexta, sábado ou domingo; o feriado com sim ou não; temperatura máxima e mínima, umidade relativa máxima e mínima do dia que se deseja prever (dados fornecidos por modelos de previsão do tempo) e os perfis tipo dos três dias anteriores ao dia que se deseja prever, podendo ser eles: PT1, PT2, PT3, PT4, PT5, PT6, PT7, PT8, PT9, PT10, PT11, PT12, PT13, PT14, PT15 ou PT16. Após a inserção das informações, ativa-se a opção “PREVER” e o modelo indicará o perfil tipo de consumo para o próximo dia. Considerando que se deseja prever o perfil de consumo de uma segunda-feira sem feriado cuja temperatura máxima esperada é de 33°C, temperatura mínima igual a 18°C, umidade máxima de 95% e a umidade mínima de 50%, e os perfis dos dias anteriores, domingo (PT(-1)), sábado (PT(-2)) e sexta-feira (PT(-3)), são PT3, PT5 e PT7, respectivamente, o modelo de previsão indica que o perfil de consumo é o PT10, conforme a Figura 4.



Previsão de Consumo de Água

UNIVERSIDADE FEDERAL DE MATO GROSSO (UFMT)
FACULDADE DE ARQUITETURA ENGENHARIA E TECNOLOGIA (FAET)
DEPARTAMENTO DE ENGENHARIA SANITÁRIA E AMBIENTAL (DESA)
MODELO PREVISÃO DE CONSUMO DE ÁGUA

UFMT

Dia da semana:

Feriado:

Temperatura máxima:

Temperatura mínima:

Umidade Relativa máxima (%):

Umidade Relativa mínima (%):

Perfil tipo do dia anterior - PT(-1):

Perfil tipo de dois anteriores - PT(-2):

Perfil tipo de três dias anteriores - PT(-3):

Perfil Tipo:

Figura 3 – Interface do Sistema Especialista para previsão de consumo de água

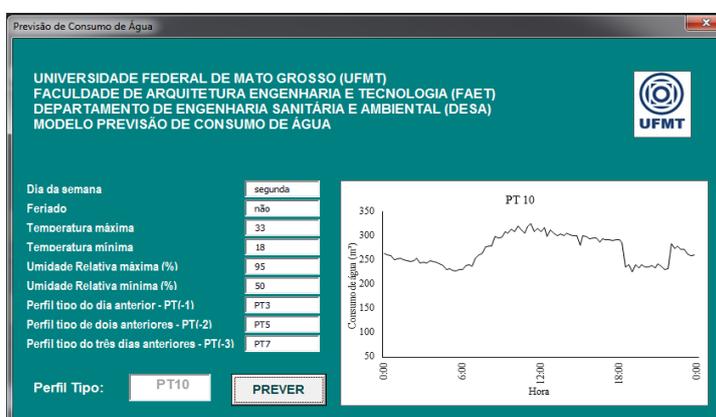


Figura 4 – Simulação do modelo de previsão

4 – CONCLUSÃO

Um modelo de previsão, baseado nos dados históricos, relacionados a dia da semana, feriados, temperatura máxima e mínima do dia, umidade relativa máxima e mínima, perfil tipo de consumo de dias anteriores, foi desenvolvido.

As regras de produção extraídas dos dados históricos de consumo sugeriram relação de dependência do consumo de água com a temperatura máxima, umidade relativa máxima, dia da semana e o perfil tipo do dia anterior ao que se deseja prever. O índice Kappa ($\kappa = 0,57$) e a avaliação da matriz de confusão indicou que o modelo pode ser considerado de moderada precisão, e necessita dentre outros fatores da expansão do banco de dados.

AGRADECIMENTOS

Os autores agradecem à Nascentes do Xingu/Águas de Campo Verde Ltda., pelo fornecimento de dados e pela colaboração com o desenvolvimento da pesquisa.

REFERÊNCIAS

- FALKENBERG, A. V. (2005). Previsão de consumo urbano de água em curto prazo. UFPR. Curitiba. 89 p.
- GUIRELLI, C. R. (2006). Previsão de carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial. EPUSP. São Paulo. 127 p.
- MELLO, T. M. P. (2016). Modelo de previsão de consumo de água para curtíssimo prazo: estudo de caso em Campo Verde/M. UFMT. Cuiabá.
- MENESES, R. A. (2011). Diagnóstico operacional de sistemas de abastecimento de água: o caso de Campina Grande. UFCG. Campina Grande. 161 p.
- ODAN, F. K. (2010). Previsão de demanda para sistema de abastecimento de água. USP. São Carlos. 77 p.
- TAVARES, C.; BOZZA, D; KONO, F. (2007). Descoberta de Conhecimento Aplicado a Dados Eleitorais. *Gestão & Conhecimento*, 5(1), pp. 54-94.
- TSUTIYA, M. T. (2006). *Abastecimento de água*. São Paulo: Escola Politécnica da Universidade de São Paulo, 643 p.