

Desenvolvimento de algoritmos e *software* para previsão de carga na área de concessão da Mux Energia - horizonte de curtíssimo prazo

Sérgio Bordignon, Daniel P. Bernardon, Mauricio Sperandio, Vinícius J. Garcia, Gladis Bordin

Resumo – Este trabalho apresenta uma nova metodologia para realizar a previsão de demanda de energia elétrica em um horizonte de curtíssimo prazo (horário), considerando a influência do índice de desconforto térmico, obtido a partir de variáveis climáticas (temperatura, umidade relativa do ar e velocidade do vento) no comportamento do consumo de um sistema de distribuição de energia elétrica. A metodologia proposta envolve a criação de um modelo probabilístico discreto (cadeia de Markov) a partir da classificação de dados históricos em um Mapa Auto-Organizável (SOM). Assim, é possível se estimar a probabilidade de um determinado nível de demanda ocorrer dada uma condição climática atual, bem como o número de intervalos de tempo (horas) até que isto ocorra. O resultado desta previsão auxilia, também, o despacho de uma Pequena Central Hidroelétrica (PCH) a fim de evitar a ultrapassagem da demanda contratada.

Palavras-chave – Previsão de demanda, Índice de Desconforto, Mapas Auto-Organizáveis, Cadeia de Markov, PCH.

I. INTRODUÇÃO

Este projeto de P&D, de mesmo título deste artigo e com código PD-0401-0001/2008, foi executado em 18 meses pela Universidade Federal do Pampa – UNIPAMPA, com suporte financeiro da Muxfeldt, Marin & Cia Ltda – Mux Energia.

A projeção de demanda de energia elétrica pode ser vista como uma das principais atividades estratégicas dentro da complexa estrutura envolvida no planejamento da operação e expansão dos sistemas elétricos.

A estimação do comportamento futuro das cargas presentes em um circuito alimentador, e de forma mais abrangente dentro da área de concessão de uma determinada empresa de distribuição de energia elétrica, está diretamente vinculada à tarefa de tomada de decisão voltadas à gestão tanto pelo lado

da demanda quanto da oferta de energia. Deste modo, uma projeção com escopo divergente do horizonte de estudo (curtíssimo, curto, médio ou longo prazos) pode trazer inúmeros prejuízos, já que uma subestimação pode resultar em não atendimento de consumidores e uma superestimação conduz a uma ociosidade do sistema envolvido.

Neste contexto, a utilização de metodologias que permitem prever o comportamento das cargas de um dado sistema mostra-se relevante. Na literatura encontram-se diversas metodologias para a projeção de carga elétrica nos distintos horizontes de planejamento. No entanto, a aplicação, em geral, das metodologias limitam-se a sistemas elétricos de médio e grande porte considerando o curto, médio e longo prazo e poucas são as propostas de projeção de demanda no horizonte de curtíssimo prazo [1][2], principalmente para pequenas concessionárias.

No caso das pequenas concessionárias, o desafio é a grande sensibilidade das cargas, por exemplo, a variação climática tem um impacto significativo na demanda [3]. Para contribuir com a solução deste problema foi desenvolvida uma metodologia que envolve a criação de um modelo probabilístico discreto (cadeia de Markov) a partir da classificação de dados históricos de variáveis climáticas em um Mapa Auto-Organizável (SOM) e o cálculo do índice de desconforto térmico. Desta forma, é possível se estimar a probabilidade de um determinado nível de demanda acontecer dada uma condição climática atual, bem como o número de intervalos de tempo (horas) até que isto ocorra.

A aplicação desta metodologia resulta em informações importantes para suporte à decisão do despacho de uma pequena central hidroelétrica (PCH), de 1 MW, a fio d'água, cujo regime de operação é limitado à pequena capacidade de armazenamento de água do reservatório (figura 1).



Figura 1. Barragem e reservatório da PCH.

Este trabalho foi desenvolvido no âmbito do Programa de Pesquisa e Desenvolvimento Tecnológico do Setor de Energia Elétrica regulado pela ANEEL e consta dos Anais do VI Congresso de Inovação Tecnológica em Energia Elétrica (VI CITENEL), realizado em Fortaleza/CE, no período de 17 a 19 de agosto de 2011.

Este trabalho foi apoiado parcialmente pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

S. Bordignon trabalha na Mux Energia (serginho@muxenergia.com.br)

D.P. Bernardon, M. Sperandio, V.J. Garcia trabalham na Universidade Federal do Pampa (danielbernardon@unipampa.edu.br).

G. Bordin trabalha na Universidade Federal do Rio Grande do Sul (gladis.bordin@ufrgs.br).

Usualmente, há restrição de geração no período de estiagem (verão-outono), visto que não há água suficiente para a usina gerar em regime contínuo, como mostra a figura 2. Por este motivo é necessário definir intervalos horários para a

geração. É de interesse da concessionária que a PCH entre em funcionamento nos períodos em que há previsão de que a energia demandada ultrapassará a contratada, para evitar o pagamento da tarifa de ultrapassagem. Assim, um método de previsão de carga, horizonte de curtíssimo prazo, é de grande valia para a empresa.




Figura 2. Evolução da geração da PCH entre set-2008 e ago-2009.

Para viabilizar a aplicação da ferramenta computacional desenvolvida foi necessário a implementação de um sistema SCADA (*Supervisory Control and Data Acquisition*) na Mux Energia, conforme previsto inicialmente no projeto. O sistema SCADA recebe em tempo real as medições de demanda a partir dos medidores de fronteira com a supridora (concessionária RGE) e variáveis climáticas de estação meteorológica instalada em subestação da supridora próxima do município de Tapejara-RS (figura 3). Com isso, é possível realizar a previsão de carga adaptativa, isto é, a previsão é atualizada em períodos horários conforme os valores verificados são adicionados ao sistema.

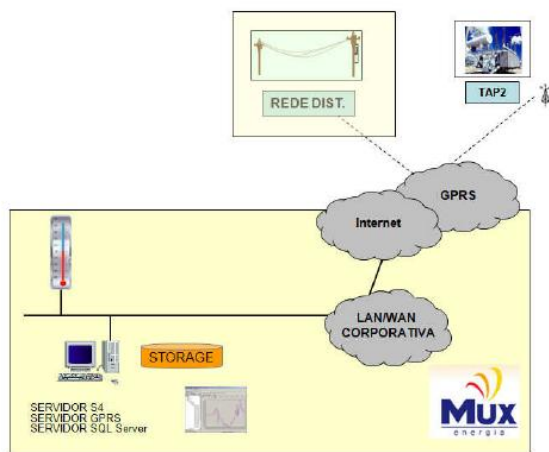


Figura 3. Estrutura do sistema SCADA para aquisição dos dados.

A implementação da metodologia proposta na plataforma definida para aplicação do produto foi desenvolvida em linguagem de programação C. O produto está integrado ao sistema SCADA, de modo que permite a visualização e acompanhamento dos resultados.

II. DESENVOLVIMENTO DA PESQUISA

A solução do problema de previsão de carga, que é de suma importância para as concessionárias, exige grande complexidade para sua realização. Já seu sucesso possibilita vários benefícios, tanto para as concessionárias quanto para os consumidores. Desse modo, este trabalho propõe uma

ferramenta computacional desenvolvida a partir de pesquisas que resultaram em uma metodologia inovadora para previsão de carga, com destaque para: análise da influência das variáveis climáticas no processo de previsão de carga usando os conceitos de Índice de Desconforto e Sensação Térmica; aplicação de Mapas Auto-Organizáveis – SOM (*Self-Organizing Map*) para agrupamento da demanda e variáveis climáticas em neurônios; criação de modelo probabilístico discreto (cadeia de Markov) a partir da classificação de dados históricos do SOM para realização das previsões de carga. Outro diferencial da metodologia proposta é a informação da probabilidade de violação da demanda contratada a partir das previsões de carga, permitindo a concessionária definir o período de despacho da PCH principalmente quando há estiagem. Um fluxograma da metodologia é apresentado na figura 4, sendo alguns dos processos detalhados nas subseções a seguir.

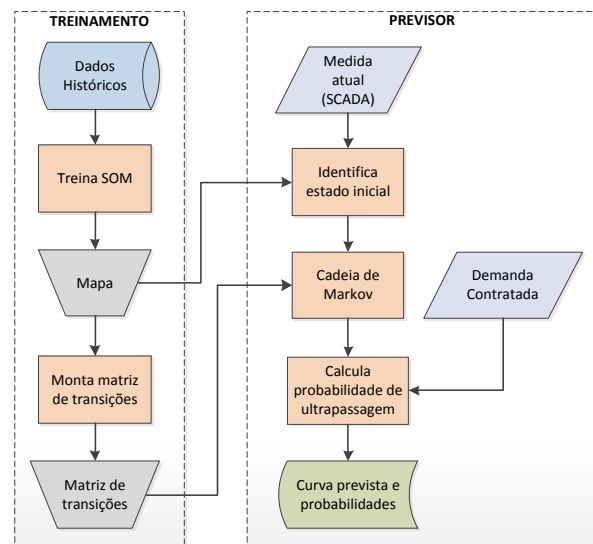


Figura 4. Fluxograma da metodologia de previsão de demanda.

Com vista a atingir o objetivo principal, os seguintes objetivos parciais foram propostos:

- obtenção das curvas de demanda de energia elétrica na área de concessão da Mux Energia. As curvas são avaliadas para os diferentes dias da semana (dias úteis, sábados, domingos) e períodos do ano (estações do ano);
- levantamento dos dados relacionados às principais variáveis climáticas que serão utilizadas nas pesquisas de projeção de demanda, como: valor da temperatura ambiente, valor da umidade relativa do ar e valor da velocidade média do vento;
- modelagem das relações “causa-efeito” entre as variáveis climáticas mensuradas e a demanda de energia elétrica;
- criação dos Mapas Auto-Organizáveis para agrupamento da demanda e variáveis climáticas em neurônios;
- criação de modelo probabilístico discreto (cadeia de Markov) a partir da classificação de dados históricos do SOM para realização das previsões de carga;
- desenvolvimento de ferramenta computacional para realização das previsões de carga a curtíssimo prazo com base na metodologia proposta;
- avaliação dos resultados obtidos através da comparação da demanda projetada com a demanda real medida.

A. Influência das Variáveis Climáticas

As variáveis climáticas apresentam grande relevância em termos de seus efeitos sobre a evolução da demanda de energia elétrica no curtíssimo prazo, uma vez que atuam diretamente sobre a sensação de conforto térmico dos indivíduos e, conseqüentemente, interferem na evolução da demanda.

Definir o conforto térmico não é tarefa simples, pois além dos fatores físicos, envolve uma gama de fatores pessoais que tornam sua definição subjetiva. O conforto térmico pode ser visto e analisado sob dois pontos de vista: o pessoal e o ambiental. No primeiro caso, este pode ser definido como sendo uma condição mental que expressa satisfação com o ambiente térmico.

O corpo humano é uma máquina térmica que constantemente troca energia com o meio ambiente e qualquer fator que interfira na taxa de perda de calor do corpo afeta sua sensação de temperatura. A demanda elétrica é afetada quando um indivíduo em estado de desconforto térmico procura adequar o ambiente em que se encontra a uma temperatura mais confortável utilizando condicionadores de ar ou ventiladores. Além da temperatura do ar, outros fatores significativos que controlam o conforto térmico do corpo humano são: umidade relativa, vento e radiação solar.

Dentre as variáveis climáticas a Temperatura Ambiente (TA) é a mais significativa em relação a sua influência sobre a carga elétrica no contexto dos consumidores residenciais e comerciais. Um pequeno desvio da TA em relação a seu valor normal (considerado como 23°C no Brasil) gera uma variação significativa no consumo de eletricidade. Para demonstrar isto, a figura 5 apresenta a dispersão da carga elétrica com a variação de temperatura média. Nesta figura, os pontos representam os valores reais obtidos da base de dados considerada no presente estudo e a linha contínua representa a tendência da variação de uma variável em relação à outra.




Figura 5. Regressão entre a temperatura média e a demanda de energia.

Além da temperatura, a Umidade Relativa do ar (UR) é outra variável meteorológica que afeta o nível de demanda elétrica. A figura 6 ilustra o seu efeito sobre a demanda com o gráfico de regressão entre a carga máxima e a UR média em um dado período.

Em ambas as figuras, pode-se observar que existe uma correlação positiva entre a carga elétrica demandada e as duas variáveis avaliadas, isto é, a demanda de energia elétrica aumenta com o aumento da temperatura e/ou o aumento da umidade relativa do ar, esta última também rela-

cionada com dias muito nublados ou chuvosos, que exigem maior iluminação artificial.




Figura 6. Regressão entre a umidade média e a demanda de energia.

É de conhecimento tácito que o vento diminui a sensação térmica. Na figura 7, pode-se observar o gráfico de dispersão e a correlação negativa entre velocidade do vento e demanda elétrica.




Figura 7. Regressão entre a velocidade do vento e a demanda elétrica.

B. Índice de Desconforto e Sensação Térmica

A combinação da Temperatura Ambiente (TA) e da Umidade Relativa do ar (UR) determina a sensação de conforto do corpo humano. Estas variáveis são normalmente as variáveis climáticas mais utilizadas quando se busca definir níveis de desconforto. O Índice de Desconforto (ID) é uma expressão proposta em [4], que combina em um único valor numérico os efeitos da temperatura e umidade sobre a sensação de calor ou frio sentida pelo corpo humano. Assim, o ID é expresso pela seguinte equação:

$$ID = T_A - 0,55 \cdot \left(1 - \frac{UR}{100} \right) \cdot (T_A - 14) \quad (1)$$

onde ID é o índice de desconforto térmico [°C], TA é a temperatura ambiente [°C] e UR é a umidade relativa do ar [%].

A figura 8 apresenta a variação do ID e da TA no decorrer de um dia útil completo. Pode-se observar que a variação do ID é similar à variação da temperatura ao longo do dia, fato que permite estudar a variação de carga elétrica diretamente em relação à variação do ID, dado que este parâmetro considera, além do valor da temperatura, a variação da umidade relativa do ar.

Visando considerar mais variáveis climáticas que expliquem a evolução da demanda, estudou-se outra expressão que relaciona a temperatura ambiente e a Velocidade do Vento (VV). Esta expressão, conhecida como Sensação Térmica (ST) foi elaborada a partir da expressão a-

presentada em [5], determina a temperatura sentida pelo corpo humano em função da perda de calor por convecção. A ST pode ser calculada através de:

$$ST = 33 + \frac{10 \cdot \sqrt{V_V} + 10,45 - V_V \cdot T_A - 33}{22} \quad (2)$$

onde, ST é a sensação térmica [°C], TA é a temperatura ambiente [°C] e VV é a velocidade do vento [m/s].

A figura 9 apresenta a variação da ST, da TA e da VV no decorrer de um dia útil completo. Pode-se observar que a variação da ST é proporcional à variação da temperatura, contudo, esta variável não acompanha de forma diretamente proporcional a variação da velocidade do vento, sendo mais influenciada quando este fica acima de 8 m/s.




Figura 8. Variação do ID, temperatura e umidade ao longo de 100 horas.




Figura 9. Variação da ST, da temperatura ambiente e da velocidade do vento ao longo de 100 horas.

No entanto, é interessante avaliar o ST em função do ID, ao invés de TA, sendo que estes dois índices estão relacionados diretamente com a sensação de desconforto térmico de um indivíduo, que por sua vez tem correlação positiva com a necessidade de condicionamento do ambiente, refletindo diretamente na demanda de energia elétrica. Além disso, com o estudo do efeito do ID e da ST sobre a evolução da demanda é possível relacionar-se em dois únicos valores os efeitos individuais das variáveis climáticas consideradas.

A figura 10 mostra que o ST com ID varia acima e abaixo da temperatura ambiente, dependendo da umidade relativa e velocidade do vento. Alta umidade e baixo ven-

to aumentam a sensação de calor, enquanto baixa umidade e alto vento diminuem a temperatura percebida. Para umidade média ($40 < UR < 50$) e baixo vento ($VV < 8$) a ST é praticamente igual a TA.




Figura 10. Variação da ST em função do ID e diferença para a temperatura ambiente ao longo de 100 horas.

A partir dos resultados deste projeto, identificou-se que o ID e a ST são indicadores adequados para projeção de carga elétrica a curtíssimo prazo, dado que consideram satisfatoriamente os efeitos das principais variáveis climáticas sobre a evolução da demanda de energia elétrica.

C. Aplicação dos Mapas Auto-Organizáveis

O Mapa Auto-Organizável ou SOM (*Self-Organizing Map*) é um tipo de rede neural desenvolvido para reconhecimento de padrões. O algoritmo SOM é definido como uma transformação Φ não-linear, que mapeia um espaço de entrada E contínuo, cuja topologia é definida pela relação métrica dos vetores de dados $D \in E$, para um espaço de saída S discreto, cuja topologia é definida por um conjunto de modelos M dispostos em uma grade bidimensional, como mostra a figura 11 [6]. Normalmente, essa rede de neurônios é interligada por conexões sinápticas (pesos) hexagonais.




Figura 11. Uma transformação $\Phi: E \rightarrow S$ em um mapa 4x4 com conexões hexagonais.

O algoritmo realiza um processo de ordenação que acontece em três etapas e consiste em encontrar o modelo que melhor represente um dado de entrada na rede (vencedor). As ligações servem para ajustar modelos de neurônios próximos ao vencedor (vizinhos) ao padrão de entrada. Assim, ao final de várias iterações o mapa apresenta os dados associados aos seus neurônios, de forma que padrões similares encontram-se em neurônios contíguos, tendo uma organização topológica [7]. Deste modo é possível se extrair relações abstratas entre as variáveis do vetor de dados através da sua posição nos mapas componentes, que por meio de uma escala de cores mostram a quantidade de uma variável específica em cada neurônio do mapa.

Cada mapa componente é uma representação do mapa treinado com referência a apenas uma das variáveis envolvidas, sendo assim, a posição dos neurônios é a mesma em todos os mapas componentes, o que permite a identificação de correlações entre variáveis. Mapas componentes similares indicam variáveis com correlação forte [8].

No referido projeto, o SOM foi aplicado para agrupamento das variáveis de entrada (demanda e climáticas) em neurônios. A figura 12 apresenta os mapas componentes para a classificação de 3.290 medidas horárias de demanda, temperatura, umidade do ar e velocidade do vento em uma rede com 36 neurônios (6x6). A cor vermelha indica os valores maiores, enquanto a azul os menores. A escala ao lado do mapa indica o valor médio das variáveis, demanda em MW, temperatura em °C, umidade em % e velocidade do vento em m/s.

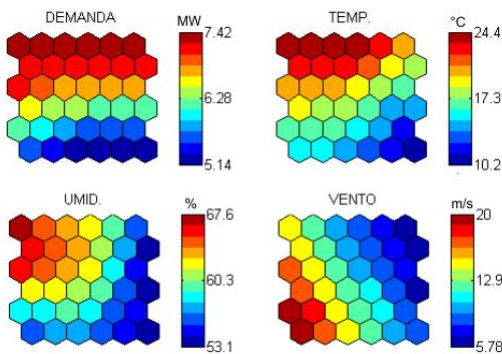


Figura 12. Mapas componentes 6x6 para as quatro variáveis estudadas.

Na figura 12 é possível se identificar algumas relações entre as variáveis, como, por exemplo, no canto superior esquerdo, tem-se alta demanda, alta temperatura, alta umidade e vento intermediário. Já, no canto inferior esquerdo, onde predominam as velocidades de vento maiores, verifica-se uma baixa demanda. No caso de mapas maiores, com uma maior relação de neurônios por dado de entrada, se obtém uma maior dispersão topológica capaz de revelar relações entre variáveis que não aparecem em dimensões menores. Veja o exemplo da figura 13, com um mapa 20x20 treinado com a mesma base de dados da figura 12.

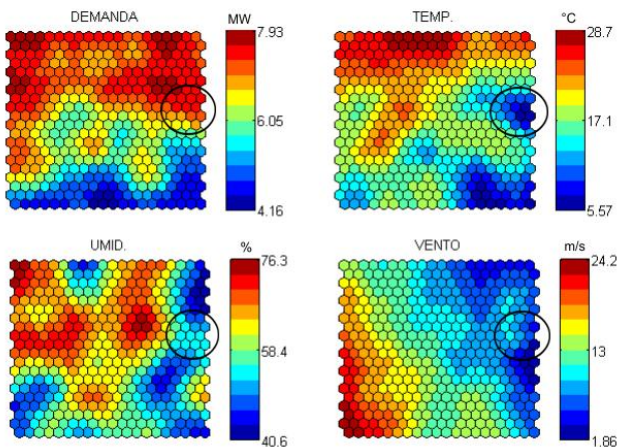


Figura 13. Mapas componentes 20x20 para as quatro variáveis estudadas.

Na figura 13 é possível se observar novas relações que não eram evidentes nos mapas da figura 12, como, por exemplo, na região mais à direita e no centro do mapa (circulada), onde a demanda é alta, a temperatura é baixa e a umi-

dade e o vento são baixos, o que caracteriza dias de inverno no Rio Grande do Sul em que a população deve ter recorrido a aquecedores elétricos. Isso mostra uma tendência inversa entre temperatura e demanda também, o que torna um modelo de previsão linear falho sob estas condições.

Uma alternativa é usar o Índice de Desconforto e Sensação Térmica em substituição das variáveis climáticas. Assim, é possível relacionar-se em dois únicos valores os efeitos das variáveis climáticas consideradas. A figura 14 apresenta os mapas componentes com 20x20 neurônios treinados a partir da base de dados de demanda e variáveis climáticas convertidas para o valor de sensação térmica, com o índice de desconforto. É interessante observar que os neurônios com maior demanda não são coincidentes com os de maior sensação térmica.




Figura 14. Mapas componentes 20x20 para demanda e sensação térmica.

D. Modelo de Markov para Previsão de Carga

Um modelo de Markov representa um processo estocástico, geralmente com estados discretos e contínuo no tempo, em que o sistema é modelado a partir de parâmetros observáveis. A proposta então é que este modelo possa ser usado para realizar análises da evolução dos estados ao longo do tempo. Parte-se do princípio de que os estados anteriores são irrelevantes para a predição dos estados seguintes, desde que o estado atual seja conhecido.

Uma cadeia de Markov [9] é uma sequência $X_1, X_2, X_3, \dots, X_n$ de variáveis aleatórias. O escopo destas variáveis, isto é, o conjunto de valores que elas podem assumir, é chamado de espaço de estados, onde X_n denota o estado do processo no tempo n . Se a distribuição de probabilidade condicional de X_{n+1} nos estados passados é uma função apenas de X_n , então:

$$\Pr(X_{n+1} = x | X_0, X_1, X_2, \dots, X_n) = \Pr(X_{n+1} = x | X_n) \quad (3)$$

Se o modelo está em um estado y no tempo n , então a probabilidade de que se mova para o estado x no tempo $n+1$ não depende de n , e somente depende do estado atual y em que se está. Assim em qualquer tempo n , uma cadeia de Markov finita pode ser caracterizada por uma matriz de probabilidades cujo elemento (x, y) é dado pela expressão (4) e é independente do tempo n .

$$\Pr(X_{n+1} = x | X_n = y) \quad (4)$$

Um espaço de estados é representável por uma matriz de transição, com o (i, j) -ésimo elemento igual à expressão:

$$P_{ij} = \Pr(X_{n+1} = j | X_n = i) \quad (5)$$

Para um espaço de estados discretos, as integrações na probabilidade de transição de k passos são somatórios, e podem ser calculados como a k -ésima potência da matriz de transição. Isto é, se \mathbf{P} é a matriz de transição para um passo, então \mathbf{P}^k é a matriz de transição para a transição de k passos.

Na medida em que o tempo avança, os valores de probabilidade de se encontrar cada um dos estados tendem a um valor limite constante. Portanto, esses valores de probabilidade limite são independentes do tempo, e a soma resulta em 1.

Em um exemplo simplificado, se observado que a demanda é baixa em uma determinada hora, a probabilidade de que ela será alta na próxima hora é 0,5. Se a demanda é alta, de outra forma, a probabilidade dela ser baixa na hora seguinte é igual a 0,25. As transições entre demandas alta e baixa podem ser modeladas como uma cadeia homogênea de Markov, e a matriz de transição de probabilidade é dada pela tabela I.

Tabela I: Exemplo de uma matriz de transição (\mathbf{P}) para dois estados de demanda.

Carga	Baixa	Alta
Baixa	0,50	0,50
Alta	0,25	0,75

Quando o número de estados é pequeno, é conveniente representar um diagrama de transições como o da figura 15:




Figura 15. Diagrama de estados de uma cadeia de Markov com a matriz de transição da tabela I.

Definido o modelo e a matriz de transições \mathbf{P} , pode-se então calcular a probabilidade do sistema estar em um estado após um determinado número de intervalos de tempo com a seguinte equação:

$$\mathbf{p}(k) = \mathbf{p}(0) \cdot \mathbf{P}^k \quad (6)$$

onde:

- $\mathbf{p}(k)$ = vetor com as probabilidades de cada estado;
- $\mathbf{p}(0)$ = vetor com as probabilidades do estado inicial;
- \mathbf{P} = matriz de transição;
- k = num. de intervalos de tempo após o estado inicial.

Assim, por exemplo, conhecendo-se o estado atual como de demanda baixa, as probabilidades do sistema estar em cada estado após quatro intervalos de tempo são definidas da seguinte forma:

$$\mathbf{P}(4) = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} 0,5 & 0,5 \\ 0,25 & 0,75 \end{bmatrix}^4 = \begin{bmatrix} 0,334 & 0,666 \end{bmatrix} \quad (7)$$

Desta forma, dado que o sistema estava com demanda baixa, após quatro intervalos de tempo (horas), a probabilidade da demanda ser baixa é de 33,4% e de ser alta é de 66,6%.

E. Atribuição de Estados a Partir do SOM

Para criar um modelo de Markov a partir de medidas de

demanda e variáveis climáticas é necessário se estabelecer estados discretos. Uma forma de definir estes estados é utilizar um método de agrupamento, e como apresentado na seção anterior, o Mapa Auto-Organizável (SOM) é uma ferramenta adequada para esta definição [10]. Neste caso, cada neurônio do SOM representa um estado do modelo de Markov, permitindo obter a probabilidade de transição dos estados (neurônios) a cada período de tempo.

Assim, a proposta é treinar um Mapa Auto-Organizável com um histórico de medidas das variáveis desejadas e, então, definir cada neurônio como um estado para um modelo de Markov. A matriz de transição \mathbf{P} é construída verificando-se a troca de neurônios a cada passo de tempo (intervalos horários) das amostras medidas, ou seja, o caminho percorrido pelo mapa, como exemplificado pelos dados da tabela II distribuídos no mapa da figura 16.

Tabela II. Exemplo de medidas horárias para as quatro variáveis observadas.

Hora	Demanda	Temp.	Umid.	Vento
:	:	:	:	:
6	5,00	8,78	57,00	22,34
7	5,92	9,10	59,50	20,80
8	6,84	9,96	61,11	22,53
9	7,38	11,14	62,44	21,13
10	7,62	13,10	64,42	19,40
11	7,64	15,34	65,71	18,36
12	6,54	17,53	65,46	16,72
13	6,64	18,53	65,00	14,35
14	7,48	18,40	65,00	11,68
15	7,29	18,34	65,00	11,78
16	7,62	17,91	65,00	8,00
17	8,31	13,22	61,98	5,04
18	8,78	14,36	66,56	2,16
19	7,93	14,18	71,14	7,20
20	7,46	14,00	76,00	10,35
:	:	:	:	:




Figura 16. Mapa 4x4 com os dados da tabela II.

Com o mapa treinado, e considerando cada neurônio como um estado para o modelo de Markov, o passo seguinte é verificar a distribuição da sequência de amostras pelos neurônios, computando as transições de um neurônio para outro, a fim de formar a matriz de transições \mathbf{P} . Dessa forma, observa-se a sequência horária das amostras, como, por exemplo, no mapa da figura 16, a amostra da hora 6 está alocada no neurônio de número 1, já a amostra seguinte (7 h), transitou para o neurônio 2, e a amostra 8 foi parar no neurônio 6.

A taxa de transição de um estado i para outro j será igual ao número de saídas para o estado j dividido pelo número total de visitas ao estado i . A figura 17 exemplifica as transições entre neurônios.




Figura 17. Transições entre neurônios conforme sequência de dados amostrados.

O esquema da figura 17, representando as transições dos dados entre neurônios, pode ser redesenhado como um diagrama de estados de um modelo de Markov, conforme mostra a figura 18.




Figura 18. Modelo de Markov criado a partir do mapa da figura 16.

O modelo da figura 18 é somente uma exemplificação, para que um modelo de previsão de demanda construído desta forma tenha uma boa assertividade é necessário treinar o SOM com um histórico de medidas de pelo menos um ano, de forma que seja possível construir um espaço de estados representativo. Como o modelo é construído a partir de estados já visitados pelo sistema, seu comportamento tende a reproduzir o histórico. Porém, pode-se incrementar o modelo aumentando o tamanho do mapa a ser treinado, e considerando-se os neurônios não ativados (vazios) com uma probabilidade de transição pequena.

Assim, por exemplo, tendo-se como ponto de partida as mesmas medidas da hora 6, o modelo realiza a previsão de carga respeitando as transições de estados (neurônios) da figura 18, ou seja, replica a ordem de estados da tabela II nos respectivos horários. No entanto, considerando um histórico maior de medidas, não necessariamente seria respeitada esta ordem, visto que cada neurônio teria uma probabilidade de transição para outros vários neurônios em função do histórico, ou seja, o neurônio “1”, que contém as medidas da hora 6, poderia ter um histórico de transitar para os estados “E”, “F” e “G”.

III. SIMULAÇÕES E RESULTADOS

A metodologia proposta para previsões de carga no horizonte de curtíssimo prazo foi analisada em um sistema protótipo, a fim de avaliar o seu desempenho e a sua eficácia. Foram realizados vários testes a partir da base histórica fornecida pela concessionária. Analisou-se o desempenho da metodologia proposta para vários cenários operacionais, incluindo dias úteis, sábados, domingos e feriados, e diferentes períodos do ano. Além disso, as não conformidades identificadas durante a realização dos testes foram tratadas.

A. Desenvolvimento da Ferramenta Computacional

Um dos objetivos da análise é verificar as probabilidades da demanda atingir um determinado nível dentro de um período estipulado. Em um exemplo, usou-se uma amostra inicial de valores das variáveis (4,475 MW, 12,29 °C, 69,00 % e 18,84 m/s), que representa uma medida realizada às 0 h e não foi usada para o treinamento do Mapa Auto-Organizável (SOM). Tal amostra foi alocada no neurônio de número “208”, que já continha os dados da tabela III.

Tabela III. Medidas classificadas no neurônio “208”.

Demanda (MW)	Temp. (°C)	Umidade (%)	Vel. Vento (m/s)
4,972	14,76	67,50	20,07
4,808	17,76	69,67	17,88
4,579	17,36	68,33	17,23
5,317	12,44	64,75	17,87

A partir do estado $p(0) = “208”$, o sistema pode ir na hora seguinte para os estados de número “178”, “208”, “238” e “267”, com as probabilidades $p(1) = [0,1667; 0,5000; 0,1667; 0,1667]$, isto é, tem 50 % de chance de a demanda permanecer no mesmo neurônio. Neste caso, a demanda passaria de 4,475 MW para 4,919 MW (demanda média do neurônio “208”). Os outros patamares médios seriam de 5,31 MW, 4,86 MW e 5,18 MW, para os estados “178”, “238” e “267”, respectivamente. Após quatro horas, o sistema pode sofrer uma grande variação, podendo parar em 44 estados diferentes, com destaque para o estado “900”, com uma probabilidade de 14,02 %.

Com o objetivo de determinar a probabilidade de se ultrapassar a demanda contratada, verificou-se os valores para o período de ponta. A chance disto ocorrer às 18 h foi de 12,71 %, de 22,86 % para às 19 h e de 17,58 % para às 20 h. A partir das 21 h a probabilidade de ultrapassar a demanda contratada é nula. Dessa forma, o sistema sinaliza ao operador da usina a probabilidade da demanda contratada ser ultrapassada, auxiliando na tomada de decisão de se usar ou não a PCH, já que geralmente não há água suficiente para sustentar a geração por muito tempo nos períodos críticos.

Outros resultados foram obtidos comparando as projeções com medições reais de demanda de energia elétrica para um horizonte até às 23 horas. A figura 19 apresenta um perfil de demanda de energia elétrica correspondente a um dia útil no período de verão, que não foi usado no treinamento do predictor, acompanhado de duas previsões a partir das 8 h da manhã. A primeira usa o indicador de sensação térmica (ST) e a segunda as três variáveis climáticas separadas (temp. ambiente – TA, umidade relativa – UR e vel. do vento – VV). Ambas as projeções são próximas, sendo que a que usou o ST obteve um desvio de 4,38 %, enquanto a com três variáveis desviou 5,36 %. Esses resultados são para 16 h à frente, e o predictor é atualizado de hora em hora. Pode-se observar no gráfico que as projeções das três primeiras horas acompanham o realizado com pequeno desvio.

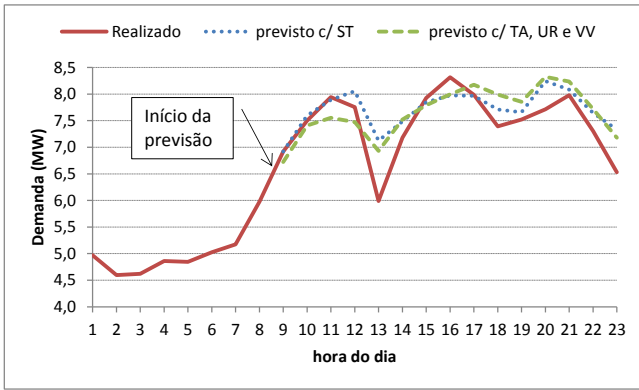


Figura 19. Projeção de demanda para um dia útil típico (verão).

Para avaliar a probabilidade de ultrapassagem da demanda contratada, a cadeia de Markov é simulada uma centena de vezes, então é contabilizado o número de cenários que ultrapassou o valor limite para cada hora do horizonte de estudos. A figura 21 ilustra esse processo, onde na parte superior aparece a probabilidade da demanda ultrapassar o limite indicado a cada hora, quando for maior que zero.

A figura 20 mostra a projeção de demanda de energia elétrica para um dia do mês de setembro, que apresenta um perfil diferente da figura 19, a partir da 8 h. Nesse caso, ambas as projeções foram muito próximas, com desvios de 3,79 e 3,78 % para as projeções com ST e com as três variáveis, respectivamente. A figura 22 apresenta a projeção de cenários para o cálculo da probabilidade de ultrapassagem da demanda contratada, que ficou em torno de 6 % entre as 14 e 16 h, e chegou a 23 % para às 18 – 19 h.




Figura 20. Projeção de demanda para um dia de setembro.

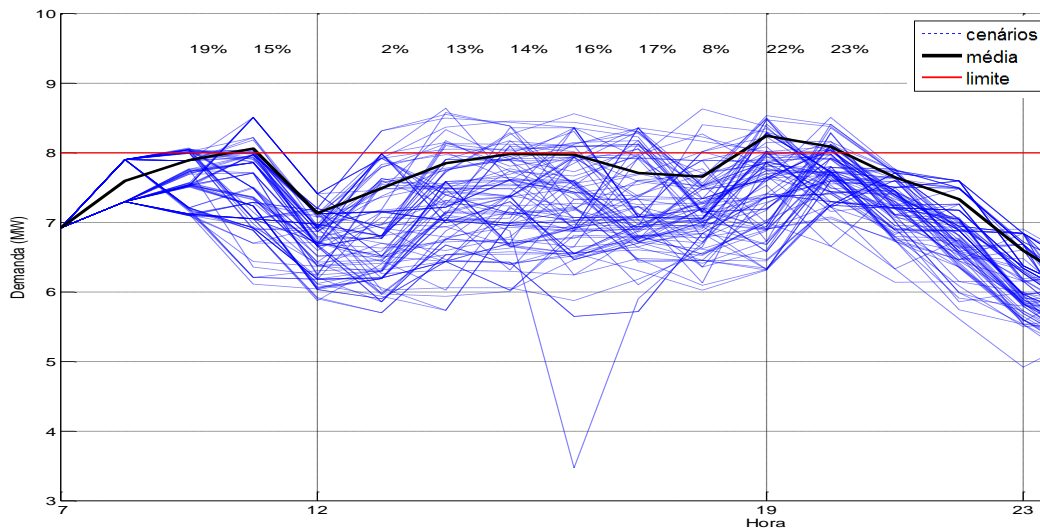


Figura 21. Cálculo das probabilidades de ultrapassagem da demanda contratada.

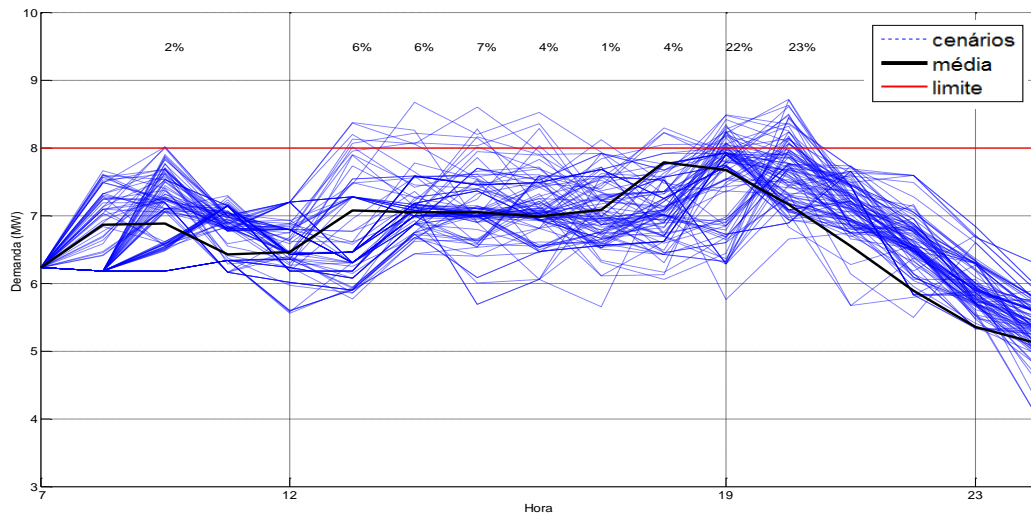


Figura 22. Projeção de cenários para cálculo de probabilidade de um dia de setembro.




Figura 23. Despacho da PCH durante o período de seca.

É interessante ressaltar que a data não é uma variável de entrada, apenas a hora do dia, demanda e variáveis climáticas, e mesmo assim o predictor é capaz de se adaptar aos diferentes perfis sazonais.

Uma simulação foi realizada com uma amostra dos dados históricos da demanda durante o período de seca em que a geração da PCH foi drasticamente prejudicada, como mostra a figura 23. Com a falta de água, o despacho tentou atender a demanda de ponta às 19 horas.

Devido a seca, a operação da usina ficou limitada a um curto período, e foi despachada preferencialmente durante o típico horário de ponta da demanda, mas como se pode verificar na área destacada da figura 24, o comportamento da carga não foi como o esperado, ultrapassando o valor de 8 MW várias vezes ao longo do dia nas três últimas semanas representadas na figura. Considerando este patamar como o limite da demanda contratada já com a tolerância de ultrapassagem, a PCH não foi suficiente para impedir o pagamento da tarifa de ultrapassagem, onerando a empresa.




Figura 24. Evolução da demanda durante o período de seca.

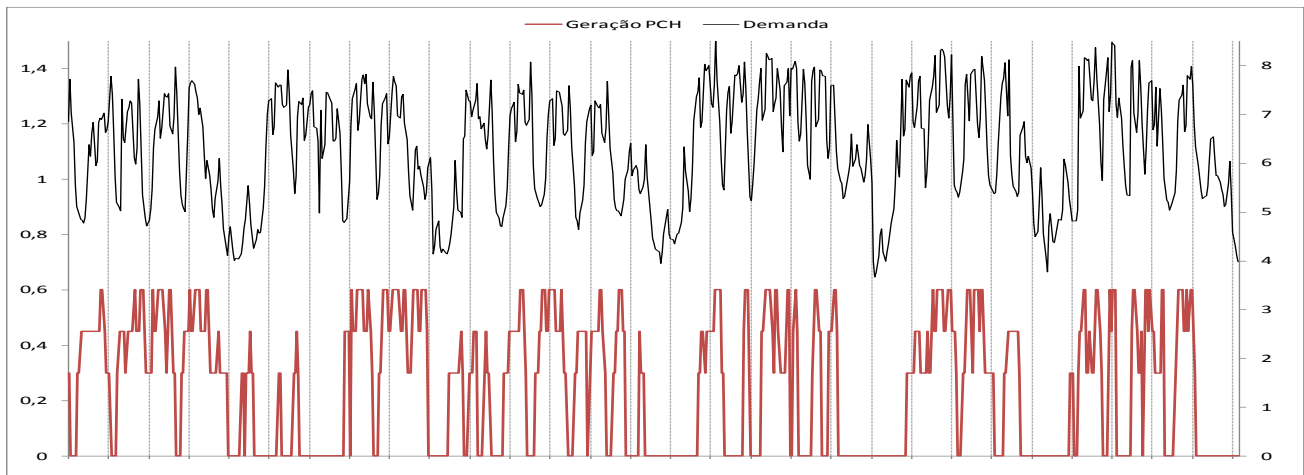


Figura 25. Evolução da demanda e despacho programado pelo modelo de previsão.

Um teste foi realizado simulando o despacho da PCH em três patamares: 0,3, 0,45 e 0,6 MW, controlados com base nas probabilidades obtidas do modelo de Markov, construindo a partir do histórico das variáveis de demanda e clima agrupados pelo mapa auto-organizável. Foi considerada a probabilidade da demanda ultrapassar o limite de 8 MW nas próximas três horas, sendo despachados os patamares se a probabilidade for maior do que 45, 60 e 75 %, respectivamente. O resultado pode ser observado na figura 25, onde são apresentados os níveis de demanda, com leitura do valor no eixo direito, e o valor da geração, com leitura no eixo esquerdo, ambos em MW.

Neste estudo de caso, o despacho da PCH a partir da probabilidade de ultrapassagem da demanda contratada limitado aos três patamares reduziu o pagamento da tarifa adicional em 91,66 %, usando menos energia do que o caso base. No entanto, cabe ressaltar que o reservatório não foi devidamente modelado, o que poderia comprometer a operação da usina na prática. O objetivo principal deste trabalho não é o controle direto do despacho, mas sim sinalizar a probabilidade de ultrapassagem de um determinado valor de demanda com base nas medidas de demanda atual e variáveis climáticas.

B. Integração ao Sistema Corporativo

Nesta etapa iniciou-se a implementação da metodologia proposta na plataforma definida para aplicação do produto, que foi integrado ao sistema SCADA da Mux Energia, de modo que os dados de entrada para execução do programa são obtidos automaticamente, bem como a visualização e acompanhamento dos resultados. Este recurso evita o uso de dois programas simultâneos pelo operador da empresa, tornando o processo de previsão de carga ágil, confiável e de fácil aplicação.

Nas figuras 26 e 27 são apresentadas as telas do sistema com a rede de distribuição e a subestação, nas quais é possível acompanhar as variáveis elétricas e climáticas em tempo real.

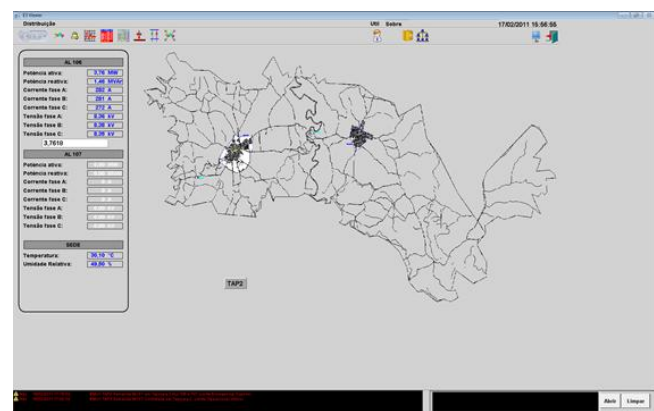


Figura 26. Tela do sistema SCADA com a rede de distribuição e monitoração em tempo real dos valores de demanda e variáveis climáticas.

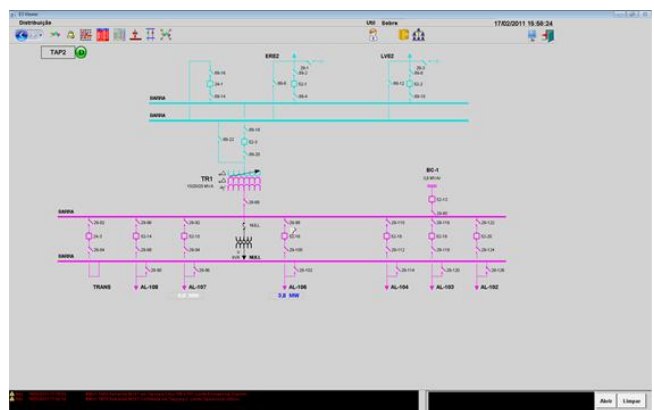


Figura 27. Tela do sistema SCADA com a monitoração em tempo real dos barramentos da subestação.

O banco de dados permite acesso ao histórico de medidas, em que se pode verificar a evolução de cada uma das variáveis acompanhadas.

A figura 28 apresenta a tela de acompanhamento da demanda em tempo real versus a projeção realizada pela metodologia. Sendo que esta é horária, por isso o perfil em patamares. Nesta tela também é apresentada a probabilidade de ultrapassagem do montante de uso do sistema de transmissão (MUST) contratado.

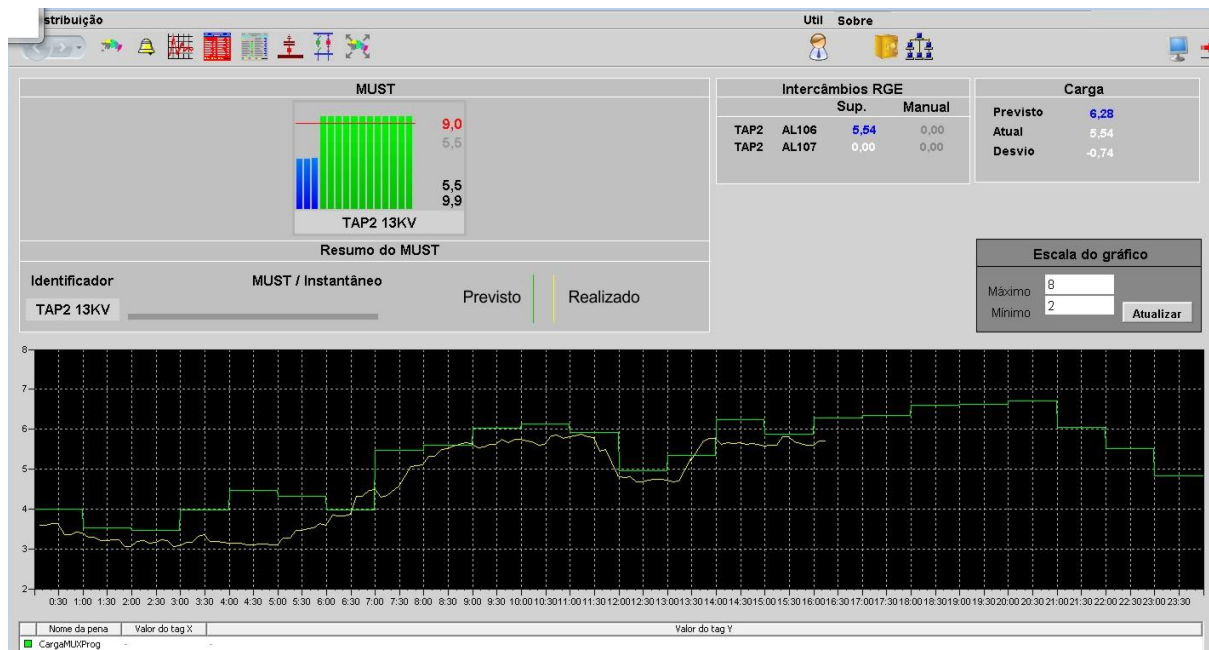


Figura 28. Acompanhamento da projeção de demanda para um dia útil típico no sistema supervisorio.

IV. CONCLUSÕES

Analisando os resultados obtidos, com a metodologia proposta, verifica-se uma diferença percentual média entre os valores previstos e medidos de demanda inferior a 5,0%, valor aceitável se tratando de horizonte de curtíssimo prazo em uma pequena distribuidora de energia elétrica. A partir da aplicação do produto também não se verificou ultrapassagens da demanda contratada, fora-ponta e ponta, com a empresa supridora (RGE) por meio de um melhor gerenciamento do despacho da PCH.

Projetando estes resultados para um ano de aplicação do produto, a empresa terá evitado um custo econômico na ordem de R\$ 127 mil, em função dos valores históricos de pagamento de ultrapassagem de demanda, apresentando um retorno financeiro superior aos investimentos realizados em curto prazo. Como ganhos intangíveis, cita-se o uso racional da energia e da água, bem como as demais aplicações a partir dos dados disponibilizados no sistema.

A ferramenta computacional ficou disponível no Centro de Operação da concessionária, sendo acompanhados seus resultados para análise de desempenho e eventuais adequações.

Novas pesquisas estão sendo planejadas para utilizar a metodologia de previsão de demanda integrada com uma previsão de afluência a fim de controlar automaticamente o despacho da PCH.

V. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] W. Charytoniuk e M. S. Chen, "Very Short-Term Load Forecasting Using Artificial Neural Network," *IEEE Transaction on Power System*, vol. 15, no. 1, pp. 263-268, 2000.
- [2] H. Daneshi e A. Daneshi, "Real Time Load Forecast in Power System," in *Proc. 3th Int. Conf. of Deregulation and Restructuring and Power Technology*. Nanjing, China, 2008.
- [3] S. Parkpoom, G. P. Harrison e J. W. Bialek, "Climate change impact on electricity demand," in *Proc. 39th University Power Engineering Conference - UPEC2004*, vol. 2, pp. 1342-1346, Bristol, UK, 2004.
- [4] S. D'Archivio, "Interazione animale-ambientale e criteri di progettazione degli edifici per l'allevamento ai fini della riduzione dello stress da caldo," Tese de doutorado, Universidade de Bologna, Itália, 2007.
- [5] B. Kermanshahi, R. Yokoyama e K. Takahashi, "Intelligent Forecasting of distribution System Loads," in *Proc. of Electrotechnical Conference MELECOM*, vol. 2, pp. 784-787, 1996.
- [6] S. S. Haykin, *Neural networks: a comprehensive foundation*, Upper Saddle River, N.J., Prentice Hall, 1999.
- [7] T. Kohonen, *Self-Organizing Maps*, 3 ed., Springer, 2000.
- [8] J. Vesanto, "SOM Based Data Visualization Methods," *Elsevier Science Intelligent Data Analysis*, vol. 3, no. 2, pp. 111-126, 1999.
- [9] P. Brémaud, *Markov Chains*, Springer, 1998.
- [10] M. Sperandio e J. Coelho, "Constructing Markov Models for Reliability Assessment with Self-Organizing Maps," *Int. Conf. on Probabilistic Methods Applied to Power Systems*. Stoccolmo, Suécia, 2006.