

SISTEMA DE SUPORTE À DECISÃO PARA GERENCIAMENTO DA ENERGIA EM CONSUMIDORES DO GRUPO A

CLÁUDIO A. ROCHA², ARMANDO TUPIASSU³, CARLOS RENATO L. FRANCÊS¹, ÁDAMO L. DE SANTANA¹, ANTONIO PINHO³, ADEMILSA CORREA³, LIVIANE REGO¹, RAFAEL COSTA²

¹Departamento de Engenharia Elétrica e de Computação
Universidade Federal do Pará

Campus Universitário do Guamá, Rua Augusto Côrrea, 01 CEP 66075-110 - Belém - Pará

²Centro de Ciências Exatas e Tecnologia
Universidade da Amazônia

Av. Alcindo Cacela, 287 - 66060-902 - Belém – Pará

³Rede Celpa
Av. Governador Magalhães Barata, 209
CEP 66040-170 - Belém, PA

alex@cci.unama.br, armando.tupiassu@redecelpa.com.br, rfrances@ufpa.br, adamo@deec.ufpa.br, antonio.pinho@redecelpa.com.br, liviane@deec.ufpa.br, rcosta@cci.unama.br

Resumo

Este trabalho apresenta um sistema de suporte à decisão para o gerenciamento remoto do consumo de energia em consumidores finais do grupo A. O sistema é composto de um módulo para a medição digital de energia, instalado externamente na entrada da unidade consumidora; um módulo de comunicação para o envio periódico das leituras realizadas; um sistema de software para a implementação de protocolos de comunicação; um sistema de software para o armazenamento em banco de dados e a recuperação das informações sobre os consumos de energia para fins de faturamento. Este último módulo, enfatizado neste artigo, também permite a realização de análises dos perfis de demanda dos consumidores do grupo A, utilizando algoritmos de mineração de dados, para fins de acompanhamento dos contratos de energia, viabilizando também a tomada de ações de controle de demanda por parte dos consumidores e/ou da concessionária.

1. Introdução

O gerenciamento pelo lado da demanda (GLD) é algumas vezes retratado nas concessionárias de energia elétrica como um novo conceito de planejamento, cujo objetivo é influenciar o uso da eletricidade por parte do consumidor, tanto do ponto de vista da quantidade quanto do ponto de vista dos horários de utilização. Atualmente, o GLD no Brasil

passa por um processo de afirmação, procurando-se demonstrar, através de diversos projetos pilotos, que é uma alternativa válida, do ponto de vista econômico, à expansão do sistema elétrico.

Existem no setor elétrico brasileiro várias aplicações do GLD, principalmente a modulação de cargas, sendo na maioria associadas ao consumidor industrial, restando ainda vários aspectos a serem considerados nos casos dos consumidores comerciais e rurais do grupo A.

A tecnologia de monitoramento dos usos finais é bastante dispendiosa, demandando elevados investimentos por parte das concessionárias. Esta tecnologia tem evoluído por várias gerações de instrumentos, acompanhando os avanços nos sistemas de comunicação e sistemas computacionais para a mineração de dados e gestão de sistemas de informação.

Para ser eficiente, um sistema de suporte à decisão, que auxilie nas políticas de tratamento de consumidores do grupo A, deve ser uma solução integrada que contemple: (1) a aquisição eficaz dos dados; (2) um mecanismo de transmissão que garanta a integridade das informações com tempos de respostas condizentes; (3) uma forma adequada de armazenamento e recuperação de informações e de conhecimento; (4) uma boa interface usuário-computador para otimizar a utilização da ferramenta.

Para melhor compreensão do Sistema proposto neste trabalho, a organização é a que se segue. Na

seção 2, são listados os elementos que compõem este Sistema. Na seção 3, é abordada a forma de coleta de dados da memória de massa. Na seção 4, são sublinhados os métodos computacionais empregados para a análise dos dados. Na seção 5, são exploradas as funcionalidades do Sistema. Na seção 6, são apresentadas algumas considerações finais sobre a aplicação proposta.

2. Componentes do Sistema de Suporte à Decisão

O objetivo do Sistema de Suporte à Decisão proposto neste trabalho é o gerenciamento remoto do consumo de energia em consumidores finais do grupo A, na média tensão (13,8 kV), compondo uma solução para um sistema de Gerenciamento pelo Lado da Demanda (GLD), que será utilizado pela concessionária Centrais Elétricas do Pará (REDE - CELPA), empresa do Grupo Rede. O sistema é composto de um módulo para a medição digital de energia, a ser instalado externamente na entrada da unidade consumidora; um módulo de comunicação para o envio periódico e sob requisição do Centro de Operação da Distribuição (COD) das leituras realizadas; um sistema de software para a implementação de protocolos de comunicação; um sistema de software para o armazenamento em banco de dados e a recuperação das informações sobre os consumos de energia para fins de faturamento. Este último módulo também permite a realização de análises dos perfis de demanda dos consumidores do grupo A, utilizando mineração de dados, para fins de acompanhamento dos contratos de energia, viabilizando também a tomada de ações de controle de demanda por parte dos consumidores e/ou da concessionária.

Para implementação da funcionalidade de Descoberta de padrões nos dados (mineração de dados), são utilizados algoritmos que implementam redes neurais e redes Bayesianas. As redes neurais são utilizadas para efetuar a predição do consumo de energia no tempo futuro. Este método confere uma maior eficiência e confiabilidade ao sistema de faturamento da concessionária para esse grupo de consumidores, como também permite que os contratos horosazonais sejam acompanhados com maior precisão pela empresa e pelos consumidores. Já as redes Bayesianas provêm um modo eficiente para codificar a relação de dependências entre as variáveis de interesse do domínio de aplicação, o que possibilita a visualização gráfica das correlações

entre os parâmetros de consumo da base de dados fornecida e a quantificação dessas dependências em termos de probabilidades. A partir do diagrama de dependências, será possível observar a propagação dos efeitos da manipulação de atributos na rede bayesiana. Dessa forma, o analista é capaz de tomar decisões baseadas na previsão de eventos diante de situações pré-definidas, tais como: estabelecimento de perfis de usuários por setor de consumo, geração de gráfico de inferências de consumo (tendências de consumo), entre outros.

3. Estratégia de Aquisição de Dados

Como forma de coleta de dados da memória de massa, foi o medidor ELO 2113, com a seguinte configuração:

- 2 Unidades de Comunicação Remota (UCRs) ELO.2136
- 1 Modem DLINK (DFM-560EL/Acesso Discado)
- 1 Modem Celular/CDMA Anydata (Modelo: EM-800II)
- 1 Software ELO.2998 (para comunicação e criptografia das informações)

A partir da instalação e configuração dos referidos medidores em clientes específicos, foi realizada a comunicação e obtida a “massa” de dados que alimenta o sistema de suporte à decisão. Na Figura 1, é possível ver o esquema de aquisição via Acess Point (Modem DLINK).



Figura 1 – Transferência dos Dados

A partir do instante em que o servidor de banco de dados é alimentado com as informações do medidor, estes dados são submetidos aos métodos de Inteligência Computacional, a fim de que possa ser realizado o processo de análise dos dados (mineração de dados). Vale ressaltar que, antes do processo de mineração, é realizado o pré-processamento dos dados com a finalidade de adequar o formato destes dados coletados com os formato dos arquivos de entradas dos algoritmos de inteligência computacional utilizados.

4. Métodos de Mineração de Dados utilizados no Sistema de Suporte à Decisão

Nesta seção, são apresentados os métodos de Inteligência Computacional, mas especificamente de Mineração de Dados, utilizados para análise dos dados.

Conforme apresentado na seção 2, foram utilizados dois métodos para realizar a descoberta de padrões de consumo – Redes Neurais e Redes Bayesianas, que serão brevemente abordadas a seguir.

4.1. Redes Neurais

As Redes Neurais são baseadas no mecanismo de funcionamento do cérebro. Os modelos neurais buscam simular através da máquina (algoritmos), o funcionamento e as reações sinápticas. Esses algoritmos implementam um processador maciçamente paralelo, constituído de unidade de processamento simples (neurônios), os quais armazenam o conhecimento por intermédio das conexões entre esses neurônios (sinapses) [1]. Este conhecimento é obtido por intermédio de um algoritmo de aprendizado, cuja função é modificar os pesos das conexões sinápticas de tal sorte que a rede atinja o objetivo do projeto desejado, por exemplo, para reconhecer padrões de imagens ou classificar clientes em determinadas categorias.

O modelo de rede neural utilizado neste projeto foi o Multi-Layer Perceptron (MLP). Nessas redes, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema [2].

O algoritmo para treinamento da rede utilizado foi o backpropagation. Neste algoritmo, a rede opera em uma seqüência de dois passos. Primeiro, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Se esta não estiver correta, o erro é calculado. O erro é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão

sendo modificados conforme o erro é retropropagado [1].

O modelo MLP foi empregado de modo a verificar a tendência dos dados, examinando o comportamento passado a fim de inferir sobre o seu conhecimento futuro, produzindo uma previsão do mesmo.

Os dados disponíveis para análise são referentes ao consumo de energia dos consumidores do Grupo A em um determinado período, mais especificamente os dados coletados da memória de massa de consumo destes consumidores.

A partir dos dados históricos de consumo da unidade consumidora (UC), a rede neural é capaz de gerar curvas de tendências do consumo e do fator de carga para períodos futuros. Na Figura 2, é apresentado um exemplo de um gráfico de tendência de consumo de uma determinada UC. Nesta figura, é possível observar, ainda, se o consumo de determinada UC está ou não extrapolando o previsto no contrato horosazonal na ponta ou fora ponta.

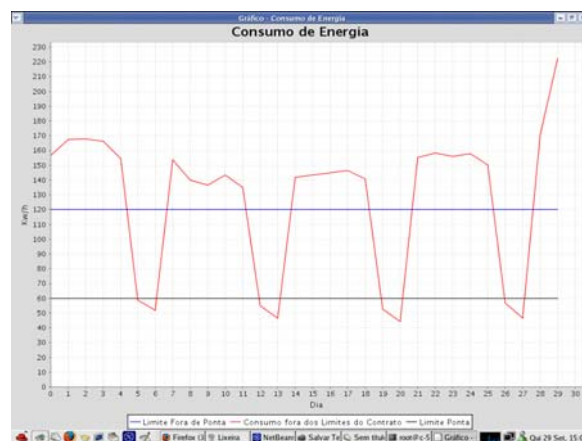


Figura 2. Curva de Tendência de Consumo.

Além do gráfico de previsão de consumo, é possível analisar a tendência do fator de carga da UC, que pode dar subsídios para o gestor de possíveis irregularidades. Na Figura 3, é possível verificar o gráfico de tendência do Fator de Carga da mesma UC, mostrada na Figura 1.

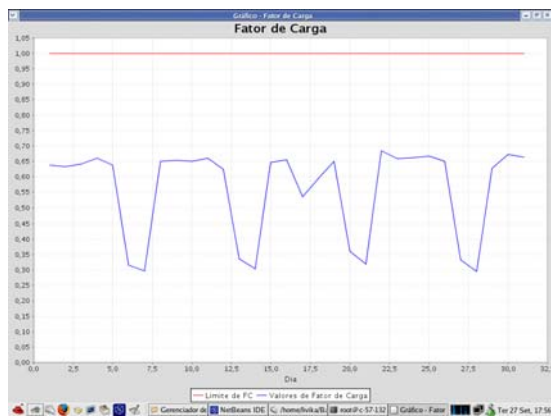


Figura 3. Gráfico de Tendência para o Fator de Carga.

Além das redes neurais, utilizadas com a meta basilar de gerar gráficos de tendência de consumo, foram empregados métodos Bayesianos, os quais são apresentados na próxima seção.

4.2. Redes Bayesianas

As Redes Bayesianas podem ser entendidas como modelos que codificam os relacionamentos probabilísticos entre as variáveis que representam um determinado domínio [3][4]. Esses modelos possuem como componentes uma estrutura qualitativa, representando as dependências entre os nós, e quantitativa (tabelas de probabilidades condicionais (TPCs) desses nós), avaliando, em termos probabilísticos, essas dependências [5], [6]. Juntos, esses componentes propiciam uma representação eficiente da distribuição de probabilidade conjunta (DPC) do conjunto de variáveis X de um determinado domínio [7]. A distribuição conjunta é dada pela seguinte equação:

$$P(X) = \prod_{i=1}^n P(X_i | Pa_i)$$

na qual Pa_i são os nós-pais do nó X_i . Essa representação acarreta uma redução substancial do número de probabilidades a serem manipuladas.

A escolha das Redes Bayesianas para a construção do Sistema apresentado neste trabalho deveu-se principalmente a semântica das mesmas, a qual facilita, dada a inerente representação causal dessas redes, o entendimento e o processo de tomada de decisão, por parte dos usuários desses modelos. Isto se deve, basicamente, ao fato das relações entre as variáveis do domínio poderem ser visualizadas

graficamente, além da quantificação, em termos probabilísticos, dos efeitos dessas relações.

Desta forma, as redes bayesianas permitem que sejam descobertas as dependências entre os parâmetros de consumo da base de dados fornecida e a quantificação dessas dependências em termos de probabilidades.

A partir do diagrama de dependências, é possível observar a propagação dos efeitos da manipulação de atributos na rede bayesiana. Dessa forma, o analista será capaz de tomar decisões baseadas na previsão de eventos diante de situações pré-definidas. Na figura 4, é apresentada uma rede Bayesiana gerada para a mesma UC utilizada como exemplo na seção 3.1.

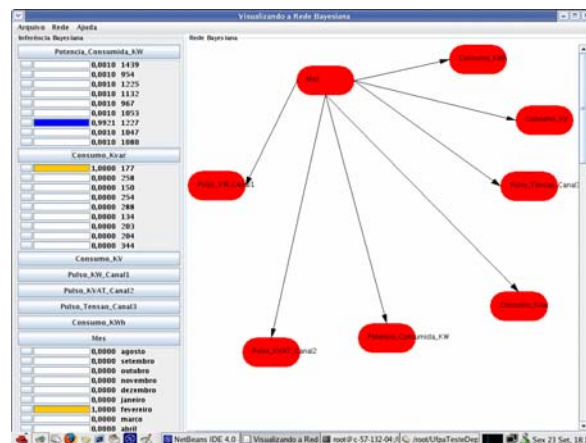


Figura 4 – Interface de representação da Inferência Bayesiana (À direita, a rede bayesiana representada através de nós. À esquerda, representação numérica das dependências entre os nós da rede).

Na Figura 4, é mostrada uma rede Bayesiana constituída dos seguintes atributos retirados do relatório de massa da UC: Mês, Potência Consumida em KW, Pulso KVAT Canal 2, Consumo em KWh, Pulso Tensão canal 3. A partir desta rede pode-se perceber, por exemplo que todos os atributos são dependentes do atributo Mês. Portanto, qualquer inferência realizada em qualquer atributo, afetará diretamente o atributo Mês, bem como a quantificação em termos de valores de probabilidades (apresentada no lado esquerdo da Figura 4) desta correlação. Ressalta-se ainda que é permitida qualquer inferência entre os atributos da base. Assim, é possível verificar a influência, em termos probabilísticos, de quaisquer grandezas em relação às

outras e não apenas do atributo mês em relação aos demais itens de dados.

5. Funcionalidades do Sistema de Suporte à Decisão

Como forma de manter o sigilo dos padrões de consumo obtidos, nesta seção, não são apresentados os resultados alcançados nos ensaios realizados com as UCs ou categorias de UCs. Assim, serão focalizadas as potencialidades das análises permitidas pelo Sistema proposto.

A partir dos resultados obtidos no Sistema de Suporte à Decisão implementado neste projeto, foi possível realizar um conjunto de inferências que apóiam a ação dos gestores, principalmente no que tange à caracterização de padrões por setores de consumo, a demandas contratadas e ao levantamento estatístico de possíveis anomalias.

Assim, ao utilizar o Sistema os usuários podem analisar os resultados a partir de quatro funcionalidades:

Visualização das Dependências (correlação entre parâmetros de consumo), a qual possibilita (graficamente) a visualização, na forma de redes bayesianas, das dependências entre os parâmetros de consumo da base de dados fornecida e a quantificação dessas dependências em termos de probabilidades.

Dessa forma, foi possível, a partir das prospecções sobre as redes Bayesianas obtidas, apresentar aos usuários de níveis decisórios os diversos cenários que podem promover variações no consumo de energia elétrica.

Observação da Propagação, a partir do diagrama de dependências, é possível observar a propagação dos efeitos da manipulação de atributos na rede bayesiana. Dessa forma, o analista será capaz de tomar decisões baseadas na previsão de eventos diante de situações pré-definidas. Estes cálculos probabilísticos são realizados por um algoritmo de propagação orientado a metas baseado no método de árvore de junção, proposto por Jensen[8].

Perfil do usuário. O tratamento dos dados e o estudo das dependências entre os atributos da rede definirão os perfis de cada Unidade Consumidora (UC) agrupando-as em classes por setor de consumo.

Geração de gráficos de tendência de consumo e de Fator de Carga (gráficos gerenciais). Com o estudo estatístico do histórico de consumo da UC, o software é capaz de gerar curvas de tendências, utilizando redes neurais, do consumo e do fator de

carga para períodos futuros, comparando-os com a tendência do seu setor.

Através dos gráficos gerenciais, a UC poderá verificar o quanto já consumiu e fazer uma previsão do quanto irá consumir até o fim do referido mês. Além disso, através desses gráficos, é possível verificar diariamente, como se comporta o histórico de consumo mensal da UC, através de informações contratuais de limites de consumo presentes nos gráficos, facilitando assim, tomadas de decisões que influenciem em seu consumo futuro, evitando penalidades descritas em contrato.

Vale ressaltar que os resultados obtidos com a aplicação dos métodos computacionais empregados neste projeto, a partir das fontes de dados utilizadas, estão na fase de Consolidação do Conhecimento Extraído.

6. Conclusões

O Sistema de Suporte à Decisão desenvolvido tem como objetivo basilar especializar o sistema de gestão, permitindo um tratamento estatístico dos dados de consumo coletados das empresas contratantes, através das técnicas de redes bayesianas e de redes neurais.

A intenção da realização dos estudos propostos no Projeto e Implementação do Sistema de Suporte à Decisão para Gerenciamento da Energia em Consumidores do Grupo A é diagnosticar as relações entre as grandezas relacionadas ao consumo, bem como efetuar predição de consumo de energia. Assim, é possível disponibilizar um sistema que pode auxiliar tanto o consumidor, que podem estabelecer contratos mais vantajosos de energia, quanto para a própria Concessionária de Energia que poderá oferecer um serviço de maior qualidade, além de antever algum sinal de irregularidade no consumo.

À luz desses indicativos, a principal contribuição deste trabalho foi aplicar o processo de extração de padrões de consumo, com o objetivo de prever o consumo de energia, bem como dar subsídios, por intermédio dos gráficos gerenciais providos pelo Sistema, aos gestores da Concessionária de Energia Elétrica e das UCs efetuarem o acompanhamento com maior precisão do consumo e da influência do mesmo em relação às demais grandezas, bem como de eventuais anomalias.

Bibliografia:

- [1] S. Haykin. Redes Neurais, Bookman, 2001.

[2] A P. Braga, T. B. Ludermir, A. P. L. Carvalho, *Redes Neurais Artificiais - Teoria e Aplicações*, LTC, 2000.

[3] J. Gill, *Bayesian Methods: A Social and Behavioral Sciences Approach*, Chapman & Hall/CRC, 2002.

[4] S. Russel, P. Norvig, *Artificial Intelligence – A Modern Approach*. Prentice Hall, 2003.

[5] Z. CHEN, *Data Mining and Uncertain Reasoning - an Integrated Approach*, John Wiley Professional, 2001.

[6] S. O. Rezende, C. A. J. Rocha, *Bayesian Networks for Knowledge Discovery in a Database*

from the Program for Genetic Improvement of the Nelore Breed. In: 2nd International Conference on Data Mining, 2000, London, In Proceedings of 2nd International Conference on Data Mining. Londres: WIT Press, p.15 – 24, 2000.

[7] J. Pearl, *Probabilistic Reasoning in Intelligent System*, Morgan Kaufmann Publishers, 1988.

[8] F. V. Jensen e F. Jensen. Optimal junction trees, In Proceedings of the 10th Conference on Uncertainty in Artificial Intelligence, p. 360–366. 1994.