

# **Metodologia para Processamento de Dados para Previsão de Energia e Curva de Carga em Edificações**

Leandro C. Gomes, Patrícia R.S. Jota

Centro Federal de Educação Tecnológica de Minas Gerais / Centro de Pesquisa em Energia Inteligente (lcgomes.leandro@gmail.com, prsjota@dppg.cefetmg.br)

## **RESUMO**

Com o advento das Redes Inteligentes ou Smart Grids, a coleta de dados de curvas de carga de edificações passa a ser uma realidade. As medições de energia em tempo real possibilitam o acompanhamento do consumo e consequente controle da demanda. Além das medições, as Redes inteligentes visam possibilitar a disponibilização de ferramentas de auxílio ao uso adequado da energia pelos usuários. Destaca-se dentre elas o uso de dados históricos para realizar a previsão de carga. A previsão de carga para edificações pode auxiliar os gestores de energia a estimarem o comportamento esperado da carga, permitindo ações antecipadas de reprogramação de cargas visando o consumo energético abaixo do limite estabelecido diariamente como meta de consumo. Neste contexto, este trabalho propõe o processamento de dados provenientes de medições energéticas em um edifício público em Belo Horizonte e apresenta uma metodologia para a estimação de consumo de energia elétrica e da curva de carga a partir de dados estimados de temperatura ambiente, estação do ano e dados históricos de medição energética. Para tal foi utilizado técnicas matemáticas computacionais fuzzy que auxiliaram na elaboração de uma estimação de consumo, baseado nos dados históricos.

**Palavras-Chave:** Processamento de Dados; Fuzzy; Estimação de Consumo.

## **1 Introdução**

Segundo o “National Institute of Standards and Technology”, NIST, o termo “Smart Grid” ou “Redes de Transmissão e Distribuição Inteligentes” se refere à modernização do sistema de fornecimento de energia elétrica com monitoramento, proteção e otimização automática dos elementos a ele interconectados, abrangendo desde a geração (centralizada ou distribuída) até as redes de transmissão (de alta-tensão) e distribuição, os consumidores industriais, a automação predial, os sistemas de armazenamento de energia e os usos finais (e sistemas associados) [1]. Com a instalação de medidores de energia inteligentes, haverá um aumento significativo da disponibilização de dados, que serão coletados em tempo real [1, 2, 3]. A transmissão e processamento desses dados devem ser realizados de forma a não prejudicar a sua análise. Assim o cuidado para que não haja perdas desses dados ao longo do caminho, influenciará na confiabilidade e estruturação dessas informações. Essa estruturação dos dados é denominada como Inteligência do Processo, onde acontece toda a

interpretação dos dados gerados, para extração de informações detalhadas de como o sistema está operando, para permitir a construção de aplicativos de auxílio ao consumidor, obtenção de novos parâmetros de qualidade do serviço, controle de cargas e outras funcionalidades a serem desenvolvidas. Estudos apontam que apenas 0,5% dos dados digitais gerados em 2012 estavam estruturados [6], ou seja, uma grande quantidade de dados obtida não está sendo analisada e processada. Isto ocorre devido a falta de pessoas especializadas, softwares e pesquisas que gerenciem e transformem esses dados em informações relevantes para os consumidores, concessionárias, reguladores, poder público, agentes de desenvolvimento e financiadores.

Um dos desafios da implementação do *Smart Grid* é fazer com que as empresas de energia forneçam, além do serviço básico, um conjunto mais amplo de serviços. Um destes serviços consiste na estimação da curva de carga diária.


O estudo sobre previsões de dados futuros está relacionado à orientação de qual tomada de decisão deverá ser estabelecido para um comportamento futuro, sendo comum no tratamento de problemas cujas decisões a serem tomadas são funções de fatos antecedentes [7]. Com dados sendo estruturados, conseqüentemente resultará em previsões com maior confiabilidade, permitindo que aplicativos de otimização do sistema elétrico auxiliem as concessionárias bem como os consumidores.

Este trabalho aborda este tema e apresenta uma metodologia de processamento de dados históricos obtidos através de um sistema de monitoramento e uma proposta de previsão de curva de carga utilizando ferramentas fuzzy. Algumas variáveis podem influenciar a previsão de consumo energético, passando por condições climáticas, tipo de consumidor, residencial ou industrial, tipo de construção do consumidor, casa, galpão, edifício, e tipo de carga a ser analisada [8]. Não apenas o clima, mas também o funcionamento interno de edifícios e outras construções possuem relevância na previsão [9]. Deve-se levar em consideração eventos atípicos que podem alterar as rotinas e portanto o uso energético da edificação [10]. Apesar de ferramentas serem usadas na previsão de carga de grandes blocos de energia, a previsão para edificações torna-se mais desafiador devido a grande variabilidade de uso, o que é menor para grandes blocos de energia.

## **2 Metodologia**

A metodologia proposta será apresentada juntamente com os resultados obtidos em um caso analisado. Para se desenvolver a metodologia proposta, foi utilizado uma base de dados de medição de uma edificação pública localizada em Belo Horizonte – MG, Brasil. Utilizou-se dados históricos de um ano, com taxa de amostragem de um minuto, e medição estratificada dentro da edificação. A medição dessa edificação foi dividida em 53 tipos de cargas diferentes. Esse levantamento de dados foi realizado pelo Centro de Monitoramento de Usos Finais (CMUF) [1, 2, 3, 4, 11], desenvolvido para acompanhamento e apuração do desempenho energético das edificações, através de um sistema de monitoramento contínuo, permitindo assim um estudo mais detalhado do consumo de energia.

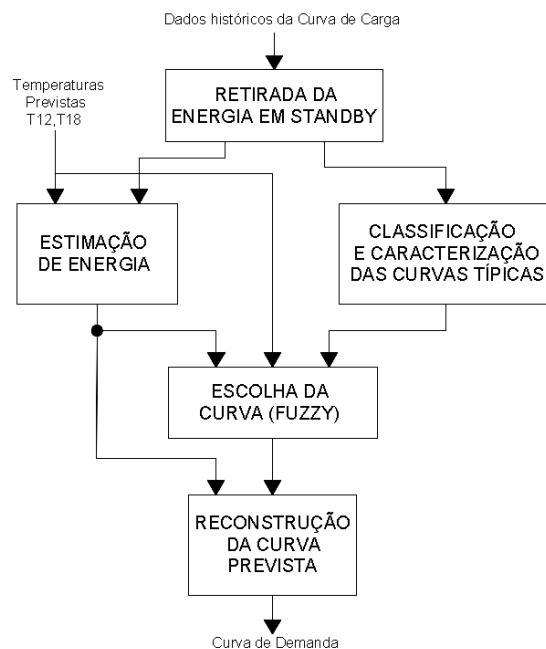
Realizou-se uma análise da curva diária das cargas do edifício, sendo assim possível levantar uma curva de carga diária, ao longo de todo o ano avaliado e verificar o perfil de consumo do mesmo. Esta edificação possui um consumo quase constante fora do período de trabalho. No horário comercial, sua energia cresce atingindo um máximo no meio da manhã. Observa-se uma redução no período do meio do dia e novamente um pico no meio da tarde. A curva de carga varia com as estações do ano. Esta edificação utiliza sistema de condicionamento de ar e portanto, sofre efeito do clima [4, 5].



**Fig. 1.** Curva de consumo energético típico do edifício analisado.

Como foi demonstrado em [4], a temperatura externa exerce uma forte influência no comportamento da curva de carga deste edifício. O edifício possui 12 andares e é condicionado artificialmente. Este sistema possui uma corrente de standby elevada e permanece consumindo energia mesmo sem o seu acionamento [4]. O acionamento do ar condicionado é individualizado a cada dois andares e é feito manualmente conforme a sensação térmica dos ocupantes ao longo do dia. Assim espera-se que dias com uma temperatura externa elevada apresentem um consumo maior de energia entretanto existem outros fatores que podem influenciar o consumo, tais como mudanças de rotinas internas, posição do Sol no céu, dentre outros fatores. Para avaliar a dependência do consumo com as variáveis climáticas, foram coletadas as temperaturas no local nos horários de 0, 12 e 18 horas [12].

De posse dos dados históricos das curvas de carga da edificação e das temperaturas dos horários indicados anteriormente, fez-se a proposta de uma metodologia para processamento dos dados e previsão da curva de carga. Um fluxograma da metodologia é apresentado na figura 2.



**Fig. 2.** Metodologia Proposta.

A metodologia pode ser dividida nas seguintes fases:

- Determinação do standby
- Estimação da energia
- Classificação e caracterização das curvas típicas
- Escolha da curva típica
- Reconstrução da curva prevista

A seguir, cada uma das fases indicadas acima é descrita, detalhada e exemplificada com o caso analisado.

#### Standby

As edificações, geralmente possuem cargas que funcionam ininterruptamente. Por esta razão, existe um consumo denominado de standby que se apresenta constante nos horários fora do intervalo de funcionamento da edificação. Assim, a primeira fase da metodologia consiste em determinar esta energia que não varia ao longo do dia ou dos meses e eliminá-la das demais fases de análise. Esta energia será usada novamente ao final da previsão, compondo a curva final, bem como a energia total estimada.

#### Estimação da energia

Para se estimar a energia consumida em uma edificação, pode-se levar em consideração variáveis disponíveis para análise e que tenham uma correlação forte com o consumo. No caso desta edificação, verificou-se que a temperatura externa é uma variável que está disponível para acesso. A previsão da temperatura horária com antecedência cada vez maior e com precisão razoável é cada vez mais disponível.

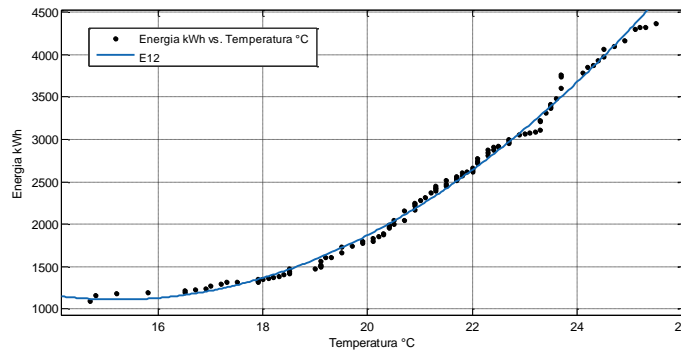
Avaliou-se portanto, a relação entre as temperaturas disponíveis para análise e o consumo variável diário da edificação (consumo diário subtraído do standby).

Propôs-se analisar a relação entre as temperaturas nas faixas de 0, 12 e 18 horas e o consumo diário de energia do edifício. Foram feitos ajustes polinomiais entre as variáveis e avaliou-se o Erro Médio Quadrático (*Root Mean Square Error* - RMSE), tabela 1.

**Tab. 1.** RMSE entre energia x temperatura.

	TEMPERATURA		
	0h	12h	18h
RMSE	140,4	108,1	112,2

Verificou-se uma melhor relação entre os dados de temperatura nas faixas de 12 e 18 horas e a energia consumida diariamente. A figura 3 ilustra a relação entre a temperatura às 12h com o consumo energético diário, que apresentou o menor RMSE.



**Fig. 3.** Relação entre a temperatura (faixa de 12h) com a energia consumida.

Desta forma, construíram-se duas curvas para a edificação estudada, sendo que a primeira relaciona o consumo variável com a temperatura às 12h e a outra com a temperatura às 18h. Estas duas temperaturas são obtidas com antecedência pelo sistema de previsão de clima existente no país. Assim, com antecedência, pode-se saber os valores de temperatura prevista para estes horários e portanto, estimar a energia a ser consumida pela edificação.

A partir da obtenção das temperaturas das 12 e das 18 horas, utiliza-os para prever o consumo a partir dos polinômios ajustados, extraídos através da regressão não linear por mínimos quadrados, As equações (1) e (2) apresentam os polinômios encontrados para a edificação avaliada,

$$E_{12}(T_{12})=33,32*T_{12}^2-1015*T_{12}+8835 \text{ (kWh)} \quad (1)$$

$$E_{18}(T_{18})=21,37*T_{18}^2-770,5*T_{18}+8070 \text{ (kWh)} \quad (2)$$

onde

$E_{12}$  e  $E_{18}$  - energia estimada na faixa de horário de 12h e de 18h respectivamente,  
 $T_{12}$  e  $T_{18}$  - temperatura prevista (graus Celsius), para as respectivas faixas de horários.

A estimação da energia final é conseguida através da equação (3), onde é feita uma média dos consumos obtidos pelas equações (1) e (2), adicionando ainda o consumo dos equipamentos presentes no edifício que ficam em standby, (energia base),

$$E_T = \frac{E_{12}(T_{12}) + E_{18}(T_{18})}{2} + E_b \text{ [kWh]} \quad (3)$$


onde

$E_T$  é a energia estimada, e

$E_b$  é a energia base (standby).


#### Classificação e caracterização das curvas típicas

Nesta fase, os dados históricos da medição de energia do edifício são analisados para levantar as diferentes curvas de carga ao longo do ano. Para realizar esta classificação, as curvas foram normalizadas para a realização da técnica de agrupamento (cluster analysis) [2]. Esse tipo de agrupamento identifica similaridades entre as séries temporais analisadas, comparando as distâncias entre as séries e agrupando-as pelas menores distâncias. Foi utilizada a distância Euclidiana, que corresponde a medidas de distância entre as coordenadas geométricas no espaço. Utilizou-se o método de agrupamento hierárquico aglomerativo, onde a cada passo as séries ou curvas agrupadas com proximidade são combinadas em um novo grupo, reduzindo o numero de grupos. A figura 4 ilustra este procedimento com um gráfico de dendograma dos últimos passos.



**Fig. 4.** Gráfico Dendograma.

Para a edificação sob análise, foram encontrados 4 comportamentos diferentes correspondentes aos dias uteis no agrupamento B, o agrupamento A representa dias atípicos ou finais de semana. Foram analisadas as subdivisões G1, G2, G3 e G4 do agrupamento B, uma subdivisão no grupo G3 se dá por diferentes amplitudes para um mesmo padrão de curva. A figura 5 apresenta os agrupamentos obtidos.



**Fig. 5.** Grupos de classificação da curva de carga normalizada.

Para a classificação desses dados, foi retirada a parte de energia correspondente ao consumo de equipamentos em *standby* do edifício, que apresenta uma demanda média de aproximadamente 68kW, com consumo diário de 1,64MWh. Dias atípicos, finais de semana, feriados e férias, por apresentarem comportamentos de consumo fora dos padrões, não foram analisados neste trabalho. Para cada uma das curvas típicas, determinou-se a demanda por unidade. Sendo definido por um valor base (o valor de pico de demanda do dia) conforme a equação (4).

$$D_{i_{pu}} = \frac{D_i}{D_b} \quad (4)$$

onde


$D_{i_{pu}}$  é a demanda no intervalo  $i$  por unidade,

$D_i$  é a demanda observada a cada intervalo de tempo  $i$ , e

$D_b$  é a demanda máxima observada no dia sob análise.

#### Escolha da curva típica (Fuzzy)

A partir dos dados históricos e a classificação das curvas em cada um dos grupos formados, levantou-se o comportamento típico das curvas por estação do ano e por conjunto de temperatura ( $T_{12}$  e  $T_{18}$ ). A figura 6 ilustra o resultado obtido para o Outono. Quanto mais dados históricos coletados, melhor a caracterização destas curvas.



**Fig. 6.** Relação entre as temperaturas (12 e 18h) com o tipo de curva para o Outono.

A figura 6 ilustra a classificação dos dias de Outono levando em consideração as temperaturas e o tipo de curva típica encontrada. A simbologia “+ G1”, “o G2” e “\* G4”, referem-se respectivamente aos comportamentos de curva dos grupos G1, G2 e G4. A partir desta caracterização, realizada na estação de Outono, foi construído um Sistema Base de Regras Fuzzy (SBRF) para indicar a melhor curva em uma previsão futura. A Lógica Fuzzy (LF) foi implementada para realizar essa classificação. É uma aplicação de inteligência computacional, de inserção do nível de aproximação de valores, onde até então existia apenas duas respostas extremas: falso ou verdadeiro, ou lógica binária: 0 e 1. Essa aproximação é realizada através do conceito de conjuntos fuzzy, onde foram desenvolvidos métodos e algoritmos de modelagem, que tornaram possíveis a solução de problemas que eram intratáveis com a lógica clássica. A LF ficou amplamente conhecida com a publicação do artigo do professor Lofti Zadeh [13], ganhando aplicação em muitos campos da engenharia e computação, nas áreas de controle de processo, classificação e estimação. Decisões que apresentam um grau de incerteza e que não podem ser contemplados por uma lógica clássica, acarretariam em perda de informações. Assim estes casos são altamente recomendáveis para a LF, que apresenta um modelo capaz de combinar a imprecisão de eventos naturais e o poder computacional, produzindo respostas inteligentes [14].

Com a relação entre as temperaturas de  $T_{12}$  e  $T_{18}$ , conforme demonstrado na figura 6, estabeleceu-se qual tipo de curva que predominaria para cada faixa de temperatura, através do SBRF.

Na estação de Outono, não foram encontradas curvas típicas do grupo G3, ficando as suas respectivas curvas fora da caracterização mostrada na figura 6. Dessa forma, foram estabelecidos três conjuntos fuzzy em duas partições, sendo uma na faixa de 12 e outra às 18 horas, configurando-se como as entradas da LF, conforme figura 7.



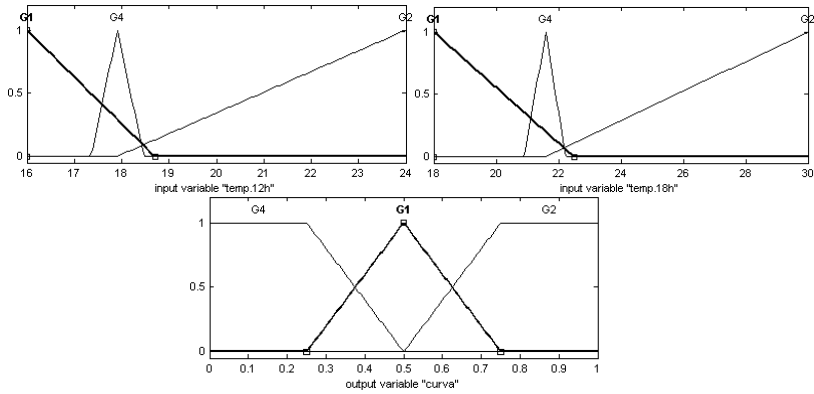


Fig. 7. Partições e conjuntos fuzzy de entrada e saída para a estação de Outono.

O modelo fuzzy adotado foi o Mamdani, ou seja, baseado na transformação de dados quantitativos em informações qualitativas. Funções utilizadas: operador AND das regras - MIN; operador de implicação - MIN; agregação das saídas - MAX; defuzzificação - centroide. Uma parte das regras e a representação gráfica do SBRF são demonstradas na figura 8.

1. If (temp.12h is G4) and (temp.18h is G4) then (curva is G4)
2. If (temp.12h is G4) and (temp.18h is G1) then (curva is G1)
3. If (temp.12h is G4) and (temp.18h is G2) then (curva is G2)
4. If (temp.12h is G1) and (temp.18h is G4) then (curva is G1)
5. If (temp.12h is G1) and (temp.18h is G1) then (curva is G1)

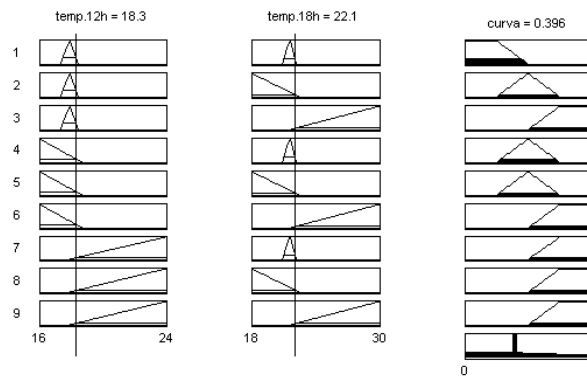


Fig. 8. SBRF para a estação de Outono.

O gráfico da figura 9 mostra como as variáveis de entrada  $T_{12}$  e  $T_{18}$  se relacionam com a escolha da curva/grupo do modelo fuzzy empregado para esta estação de Outono.




Fig. 9. Gráfico de superfície do modelo fuzzy para a estação de Outono.

#### Reconstrução da curva prevista

Nesta última fase da metodologia, de posse da energia estimada pelos polinômios e da curva mais provável normalizada pela LF, passa-se para a fase de reconstrução da curva final estimada. Nesta fase, a curva normalizada é reconstruída com o valor da energia estimada pelos polinômios, conforme a equação (5).

$$D_{\max} = \frac{E_T}{\frac{1}{60}(\sum D_{i_{pu}})} \quad (5)$$

onde

$D_{\max}$  é a demanda máxima do dia.

Com a demanda máxima ( $D_{\max}$ ) corrigida de 1 pu (100%) para o valor calculado pela equação (5), todos os demais valores de demanda ( $D_{i_{pu}}$ ) serão corrigidos automaticamente, pois são proporções de  $D_{\max}$ .

### 3 Resultados

As energias diárias reais obtidas pelas medições feitas na estação de Outono foram comparadas com as previsões obtidas após análise e processamento dos dados pela metodologia proposta, para averiguar a eficiência da ferramenta desenvolvida. A figura 10 mostra um dia previsto x medido.

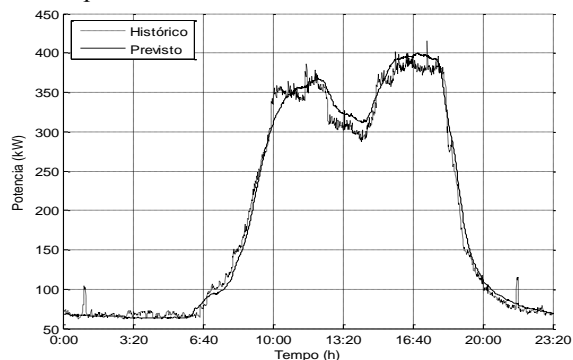



Fig. 10. Curva de dados históricos x Curva Prevista.

Para a análise das comparações entre os dados das medições históricas obtidas no período da estação de Outono, com as curvas de demanda previstas utilizou-se o Erro Médio Absoluto Percentual (*Mean Absolute Percentage Error* - MAPE). Os valores dos MAPE obtidos é apresentado na figura 11, em um gráfico do tipo boxplot.



**Fig. 11.** Boxplot dos valores do índice de erro MAPE.

A mediana dos erros obtidos ficou em 10,85%, e o percentil 75% foi igual a 24,56% de erro, ou seja, 75% dos resultados analisados apresentou um erro menor que 24,56%.

Variações do índice de erro podem ser justificadas pelos comportamentos atípicos dos funcionários no edifício público aqui estudado, em especial o acionamento do sistema de ar condicionado de forma manual e não automático.

## 4 Conclusão

A análise do consumo energético deve levar em conta diversos aspectos internos do consumidor, como aspectos construtivos das edificações, geração própria de energia e também externas, como temperatura, dias atípicos, dias úteis, etc. Cada tipo de consumidor irá apresentar um padrão de curva de carga diferente, conforme o seu consumo, que deverá ser analisado e processado para tal finalidade.

A base de dados de medições realizadas é outra importante ferramenta para este tipo de pesquisa, com o desenvolvimento de medidores de energia inteligentes, um aumento da quantidade de informações é esperado. Toda a arquitetura de recebimento e envio desses dados deve ser estruturado de forma a proteger e garantir a confiabilidade dos dados coletados.

O processamento de dados em informações relevantes foi demonstrado neste trabalho, através da utilização da LF. Essa lógica contribuiu para que informações importantes, dos dados coletados, fossem extraídas com o objetivo de oferecer novos serviços ao consumidor e concessionárias. O uso de ferramentas de inteligência computacional como a LF é indicado na estimação de consumo energético, devido a precisão que pode ser dada a fenômenos de características naturais como medições climáticas, conforme demonstrado neste trabalho.

## Agradecimentos

Este trabalho foi apoiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES , e utilizou dados do Banco de Dados Meteorológicos para Ensino e Pesquisa – BDMEP – INMET, além dos dados energéticos obtidos pelo Projeto CMUF, Centro de Monitoramento de Usos Finais - UFMG/CEFET-MG/FINEP/CT-ENERG/CEMIG e apoio do Centro de Pesquisa em Energia Inteligente – CPEI – CEFET-MG.

## 5 Referências

1. Jota, Fábio Gonçalves ; Jota, P. R. S. ; Rocha, D. A. . Monitoramento e Controle Remotos de Consumo e Geração de Energia em Tempo Real Via Internet. In: VI CIERTEC (2009)
2. Jota, P. R. S.; Silva, Valéria R.B. ; Jota, Fábio G. . Building load management using cluster and statistical analyses. Elsevier, IJEPES (2011)
3. Silva, Valéria Romeiro Borges da ; Jota, P. R. S. . Predicting load using cluster analysis. WSEAS Transactions on Systems (2004)
4. Jota, P. R. S.; Freitas, M. E. A. ; Bracarense, Mirna Suely dos Santos ; Silva, André Augusto Pinto ; Jota, Fábio Gonçalves . Análise dos Índices de Desempenho Energético em Sistemas de Ar Condicionado em Edificação Pública. II CBEE. (2007)
5. Papa, Renata Pietra ; Jota, P. R. S. . Evaluation of influences of the external temperature in the building energy consumption. PALENC (2005)
6. Davenport, T.H.: Big Data: The Opportunity and the Challenge for Competitive Advantage. Big Data: The Future of Information and Business, <http://vivaldipartners.com>
7. Nogueira, F.: Modelagem e Simulação: Modelos de Previsão, Notas de Aula. UFJF, Juiz de Fora (2009)
8. Lazos, D; Sproul, A.B; Kay, M.: Optimization of energy management in commercial buildings with weather forecasting inputs: A review - Renewable and Sustainable Energy Reviews 39 (2014)
9. Reddy, T.A; Claridge, D.E.: Using synthetic data to evaluate multiple regression and principal component analyses for statistical modeling of daily building energy consumption. Energy Build (1994)
10. Rezende, S.O.: Sistemas Inteligentes – Fundamentos e Aplicações. Ed. Manole (2003)
11. Jota, F.G; Jota, P.R.S; Nobre, E.C.: Centro de Monitoramento de Usos Finais. I Congresso Brasileiro em Eficiência Energética, Belo Horizonte (2005)
12. BDMEP.: Banco de Dados Meteorológicos para Ensino e Pesquisa, <http://www.inmet.gov.br>
13. Zadeh, L.: Fuzzy Sets, Journal Information and Control (1965)
14. Cox, E.: The fuzzy system handbook: a practitioner’s guide to building, using, and maintaining fuzzy system, New York (1994)