



**XXIII SNPTEE
SEMINÁRIO NACIONAL
DE PRODUÇÃO E
TRANSMISSÃO DE
ENERGIA ELÉTRICA**

FI/GOP/25
18 a 21 de Outubro de 2015
Foz do Iguaçu - PR

GRUPO -IX

GRUPO DE ESTUDO DE OPERAÇÃO DE SISTEMAS ELÉTRICOS - GOP

USO COMBINADO DE REDES NEURAIS ARTIFICIAIS E LÓGICA FUZZY NA PREVISÃO DE CARGA PARA A PROGRAMAÇÃO DIÁRIA DA OPERAÇÃO

Victor A. Almeida
Eletrobras Cepel

José F.M. Pessanha (*)
Eletrobras Cepel

Tatiana M.L. Assis
UFRJ

RESUMO

Neste trabalho apresenta-se uma metodologia de previsão que combina métodos de inteligência computacional com a finalidade de fornecer previsões do perfil de carga diário até dois dias à frente. A metodologia baseia-se na decomposição da carga em duas componentes: demanda média diária em MW (nível) e perfil diário (em p.u. da demanda média diária). A previsão da componente nível é realizada por uma rede neural multicamadas e a previsão do perfil baseia-se na inferência *fuzzy* aplicada na interpretação do mapa gerado por uma rede auto-organizável. A metodologia é ilustrada por um experimento com a série de carga do submercado Nordeste.

PALAVRAS-CHAVE

Previsão de Carga, Programação Diária da Operação, Curva de Carga, Redes Neurais Artificiais, Lógica Fuzzy

1.0 - INTRODUÇÃO

Previsões de carga em bases horárias para um dia à frente constituem informações básicas para a programação diária da operação do Sistema Interligado Nacional (1). Na Tabela 1 apresenta-se o cronograma para envio da previsão de carga para a elaboração da programação diária da operação eletroenergética. A previsão de curto prazo (*Short-Term Load Forecasting* – STLF) conta com uma vasta literatura técnica contendo uma variedade de métodos (2). Tal fato reflete a busca dos operadores por métodos capazes de gerar previsões mais precisas, um requisito básico para otimizar o uso dos recursos energéticos disponíveis (3). O presente trabalho insere-se neste contexto ao propor uma metodologia alternativa para previsão do perfil diário da carga um dia à frente, portanto, útil na programação diária da operação.

Tabela 1 – Cronograma para envio das previsões de carga para a programação diária da operação

Dia de elaboração da programação	Carga prevista para o dia	Carga prevista para o dia (antecipação da programação)
2ª feira	3ª feira	4ª feira
3ª feira	4ª feira	5ª feira
4ª feira	5ª feira	6ª feira
5ª feira	6ª feira e sábado	domingo
6ª feira	domingo e 2ª feira	3ª feira

Fonte: ONS, Submódulo 5.4 Consolidação da previsão de carga para a programação diária da operação eletroenergética e para a programação de intervenções em instalações da rede de operação

A metodologia proposta baseia-se na observação de que os perfis diários da curva de carga de um mesmo dia da semana apresentam elevado grau de similaridade. Esta característica do comportamento da carga permite

construir previsores simplificados, porém com razoável capacidade preditiva, tais como os exemplos apresentados por Senju et al (4), Álvarez et al, (5), Mu et al, (6) e Paparoditis & Sapatinas (7). Porém, de forma distinta das metodologias descritas pelos autores supracitados, na metodologia proposta são empregadas técnicas de aprendizado não supervisionado e supervisionado (8) para quantificar a similaridade entre as formas dos perfis de carga e estabelecer uma previsão do perfil de carga um dia à frente.

Na metodologia proposta as curvas de carga são decompostas em duas componentes: nível e forma. Neste trabalho o nível é a demanda média diária (MW) e a forma é representada por um vetor cujos elementos correspondem aos valores horários da carga por unidade da demanda média diária. Assim, a previsão da curva de carga para os próximos dias é determinada pelo produto de duas previsões: a previsão da demanda média diária, realizada por uma rede neural *perceptron* multicamadas (9) e a previsão da forma da curva de carga, realizada por meio do algoritmo de Wang & Mendel (10) aplicado na interpretação de um mapa produzido por uma rede auto-organizável – SOM (Self Organizing Map)(11). A rede neural *perceptron* multicamadas e o algoritmo de Wang Mendel são exemplos de técnicas de aprendizagem supervisionada, enquanto a rede SOM emprega o aprendizado não supervisionado.

O presente trabalho está organizado em cinco seções. A seguir, na seção 2 tem-se uma breve introdução às redes neurais artificiais e lógica *fuzzy* (12). Na seção 3 tem-se uma descrição da metodologia proposta. Para ilustrar a aplicação da metodologia foi realizado um experimento computacional com os registros de carga do Submercado Nordeste. Os resultados do experimento computacional são apresentados na seção 4. Por fim, na seção 5 são resumidas as principais conclusões do trabalho.

2.0 - TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL

2.1. Redes neurais artificiais

As Redes Neurais Artificiais (RNA) são técnicas computacionais que se assemelham à estrutura neural dos organismos inteligentes e adquirem conhecimento através da experiência. A estrutura básica do modelo matemático para o neurônio pode ser vista na Figura 1, na qual é possível visualizar as sinapses (w), onde o conhecimento é armazenado, um somador que serve para acumular os sinais de entrada (x) multiplicados pelos seus respectivos pesos sinápticos e uma função de ativação ϕ que produz a saída da rede y . Este modelo básico é chamado de *perceptron*.




FIGURA 1 – Perceptron

No modelo de neurônio artificial na Figura 1 os terminais de entrada representam os dendritos e o único terminal de saída representa o axônio. A intensidade das sinapses é representada pelos pesos (w) nos terminais de entrada, cujos valores podem ser negativos ou positivos, definindo sinapses inibidoras ou excitadoras respectivamente. De forma análoga ao que acontece no cérebro humano, onde as sinapses são reforçadas ou enfraquecidas, os pesos são ajustados durante a evolução do processo de aprendizagem da rede. O comportamento do corpo celular é emulado por um mecanismo que faz a soma ponderada dos valores recebidos. A relação da resposta do neurônio com a soma ponderada dos valores recebidos é estabelecida pela função de ligação.

Os pesos sinápticos são ajustados através de um processo de aprendizagem (treinamento). Os algoritmos de treinamento podem ser classificados em dois grupos distintos: supervisionados e não supervisionados. No treinamento supervisionado a rede é treinada utilizando-se pares entrada/saída desejada. O objetivo do treinamento consiste em ajustar os pesos sinápticos de forma a minimizar o erro entre a saída desejada e a resposta gerada pela rede para um dado padrão de entrada. No treinamento não-supervisionado não há uma saída desejada e são utilizados apenas vetores de entrada para que a rede identifique os padrões latentes e agrupe-os em classes (*clusters*).

2.1.1. Redes neurais supervisionadas

Um tipo muito comum de rede neural artificial é a *multilayer perceptron* (MLP) na qual vários neurônios artificiais são organizados em uma estrutura determinada pelo número de camadas e pela forma de como eles se interligam. A definição do número de camadas escondidas e do número de neurônios em cada camada é feita de forma empírica (13). A arquitetura mais usual é a MLP com três camadas na Figura 2: uma camada de entrada

que recebe os valores das variáveis explicativas, uma camada intermediária que processa as variáveis de entrada e uma camada de saída responsável pela resposta da rede.

O treinamento da rede consiste em um processo iterativo de ajuste dos pesos das conexões entre os neurônios de forma a minimizar o erro na resposta da rede. No caso das redes MLP o treinamento supervisionado é realizado por meio do método de retropropagação do erro (*error backpropagation*) (14), no qual os desvios entre a saída gerada pela rede e a saída desejada são utilizados em um mecanismo de correção de erro para ajustar os pesos da rede. Essa dinâmica é repetida por todo conjunto de padrões entrada/saída inúmeras vezes, até que a taxa de erro esteja dentro de uma faixa considerada satisfatória.

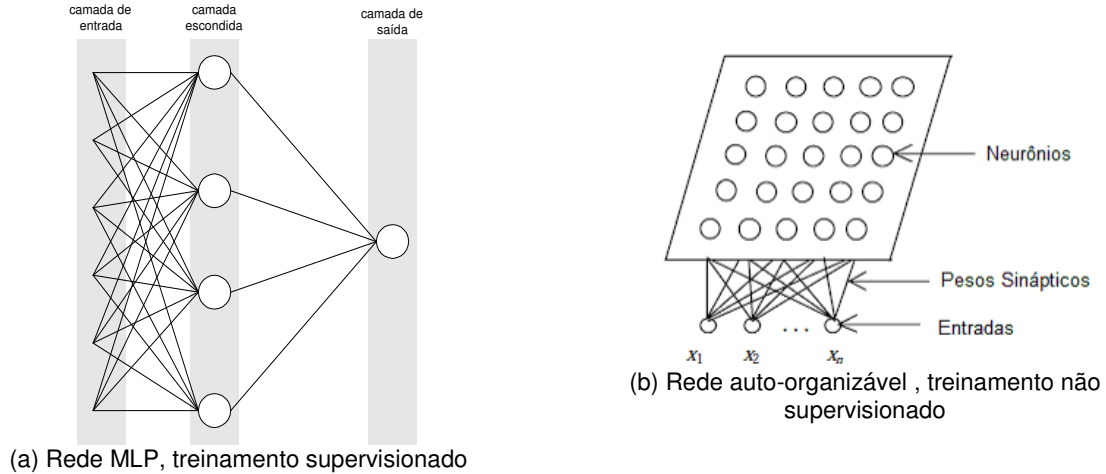


FIGURA 2 – Arquiteturas de redes neurais artificiais

2.1.2. Redes neurais não supervisionadas

Nesta classe de redes neurais não há comparação da saída gerada pela rede com uma saída desejada. O tipo de rede mais comum nesta categoria é o mapa auto-organizável (SOM), cuja principal aplicação consiste na identificação de padrões em um conjunto de dados de entrada e a organização dos mesmos em uma saída topologicamente ordenada (mapa). A rede SOM é útil na análise de agrupamentos (*clustering*) com a finalidade de classificar objetos caracterizados por n atributos em c grupos (*clusters*) não conhecidos a priori, de tal forma que os grupos formados sejam internamente homogêneos. Em uma rede SOM os neurônios estão organizados em uma estrutura unidimensional ou bidimensional (Figura 1b). Cada neurônio da camada de saída representa um *cluster* e está conectado a todos os neurônios da camada de entrada através de sinapses com pesos w . Quando um vetor de entrada p é apresentado, a rede SOM classifica o vetor de entrada no neurônio com vetor de pesos w mais similar ao vetor p , de tal forma que para uma dada entrada somente o neurônio com o maior valor de saída se torna ativo (neurônio vencedor) assumindo o nível lógico um, enquanto os demais assumem o nível lógico zero e assim os objetos são classificados entre os neurônios. Os pesos sinápticos são atualizados por meio de um treinamento competitivo (13), no qual apenas o neurônio vencedor e sua vizinhança têm seus pesos ajustados.

2.2. Lógica fuzzy

Na lógica *fuzzy* o grau de verdade de uma declaração é representado por um número no intervalo $[0,1]$, ao contrário do que ocorre na lógica clássica em que o grau de verdade é binário: 0 (declaração falsa) e 1 (declaração verdadeira). Esta característica da lógica *fuzzy* é útil em muitas situações práticas onde o grau de intensidade de um fenômeno é descrito de maneira imprecisa por meio de variáveis linguísticas, por exemplo: carga leve, carga média ou carga pesada. A teoria da lógica *fuzzy* pode ser utilizada para traduzir em termos matemáticos a informação imprecisa expressa por um conjunto de regras linguísticas, sentenças expressas através de implicações lógicas da forma *SE antecedente ENTÃO conseqüente*. O processo de inferência *fuzzy* avalia os níveis de compatibilidade (pertinência) das variáveis de entradas com os antecedentes das regras, ativando os conseqüentes com intensidades proporcionais aos mesmos. A resposta do sistema de inferência *fuzzy* é a média dos conseqüentes ponderados pelos graus de compatibilidade das respectivas regras.

3.0 - METODOLOGIA PROPOSTA

A demanda por energia elétrica em uma hora h em um dia d , $D(h,d)$, pode ser expressa da seguinte maneira:

$$D(h,d) = D(d) * D(h,d)/D(d) \quad \forall h=1,24 \quad (1)$$

em que $D(d)$ é a demanda média diária do dia d e $D(h,d)/D(d)$ é o perfil de carga normalizado pela demanda média.

Uma previsão para a demanda $D(h,d) \forall h=1,24$ pode ser obtida por meio do produto de duas previsões: a previsão da demanda média diária (MW) e a previsão do perfil de carga (p.u. da demanda média), ambos para o dia d . Na metodologia proposta a previsão da demanda média diária é determinada por uma rede MLP. Já a previsão do perfil de carga padronizado envolve duas etapas: construção de perfis típicos e previsão do perfil padronizado.

Na etapa de construção dos perfis típicos, inicialmente os perfis diários são normalizados pelas respectivas demandas médias e na sequência são agrupados em conjuntos disjuntos denominados *clusters*, de tal forma que curvas com perfis semelhantes pertençam ao mesmo grupo e curvas com formas distintas sejam alocadas em grupos diferentes. A identificação dos grupos de perfis semelhantes é realizada por meio de uma rede neural SOM. Ao final, K *clusters* são formados e cada *cluster* recebe um rótulo $C_i \forall i=1,K$ que é compartilhado por todas as curvas classificadas no *cluster*. Assim, a sequência temporal dos perfis diários de carga pode ser codificada como uma série temporal de rótulos dos *clusters* em que os perfis diários foram alocados.

Na etapa de previsão do perfil padronizado considera-se uma abordagem que segue as linhas gerais do algoritmo proposto por Wang & Mendel, um algoritmo para extração automática de regras *fuzzy* a partir de um conjunto de dados numéricos. A opção por esta abordagem deve-se a sua relativa facilidade de implementação computacional, bem como a sua flexibilidade na modelagem dos efeitos de outros fatores que afetam o perfil da carga como temperatura, feriados e horários de verão. O algoritmo tem duas etapas: construção da base de regras e previsão. Considere uma série temporal com duração de N dias, cujos respectivos perfis de carga foram previamente classificados e codificados em K *clusters* pela rede SOM. Assim, cada dia recebe um código C_i , um número entre 1 e $K \forall i=1,N$. Na fase de construção da base de regras use a série codificada para gerar janelas de entrada/saída. Considere uma janela de entrada formada pelos L dias passados e uma janela de saída um dia à frente. Por exemplo, considere uma janela de entrada de tamanho $L=3$ (C_{d-2}, C_{d-1}, C_d) e uma janela de saída com o código do dia seguinte C_{d+1} . Movendo-se as janelas de entrada e saída ao longo da série pode-se gerar um conjunto de regras *SE antecedente ENTÃO consequente* como a ilustrada a seguir:

$$\text{SE (dia } d \text{ é feriado) e (dia } d \in \text{ horário de verão) e (perfil}_{d-L+1} \in C_i) \text{ e... (perfil}_d \in C_m) \text{ ENTÃO perfil}_{d+1} \in C_n \quad (2)$$

em que i, m e n denotam os índices dos *clusters* onde foram classificados os perfis dos dias $d-L+1$ até d .

Durante a extração de regras podem aparecer regras repetidas e regras conflitantes, regras com antecedentes idênticos, porém com consequentes diferentes. As regras repetidas são facilmente identificadas e todas as repetições devem ser descartadas. No caso de regras conflitantes é necessário calcular o grau de pertinência da regra e reter apenas a regra com o maior grau de pertinência. O grau de pertinência da regra é o produto das pertinências dos antecedentes e do consequente. A pertinência $\mu(d,j)$ de um perfil diário d ao *cluster* j é avaliada pela fórmula abaixo, na qual m é um parâmetro de entrada usualmente fixado entre 1,5 e 2 e q_j denota o centroide do *cluster* $j \forall j=1,K$ (perfil de carga padronizado representativo do *cluster*, uma curva típica).


$$\mu(d, j) = 1 / \left(\sum_{c=1}^K \left(\frac{\| \text{perfil}_d - q_j \|}{\| \text{perfil}_d - q_c \|} \right)^{\frac{1}{m-1}} \right) \quad (3)$$

A função de pertinência em (3) é uma medida de similaridade do perfil ao centroide do *cluster*. No caso das características como feriados e horário de verão a pertinência é uma função binária: 1 pertence e 0 não pertence. Na etapa de previsão são conhecidos apenas os elementos que compõem o antecedente, por exemplo, para uma determinada instância sabe-se que (dia d é feriado) e (dia $d \in$ horário de verão) e ($\text{perfil}_{d-L+1} \in C_i$) e... ($\text{perfil}_d \in C_m$). Para fazer a previsão deve-se avaliar o grau de pertinência da instância de entrada em cada uma das regras que compõem a base de regras. Denotando o grau de pertinência da instância em uma regra i por μ_i , a previsão é a média dos consequentes das regras (perfis dos centroides q_i) ponderados pelos respectivos graus de pertinência:


$$\text{Perfil}_{d+1} = \frac{\sum_{i=1}^{N^\circ \text{ de regras}} \mu_i \cdot q_i}{\sum_{i=1}^{N^\circ \text{ de regras}} \mu_i} \quad (4)$$

4.0 - EXPERIMENTO COMPUTACIONAL

Para ilustrar a aplicação da metodologia proposta foi realizado um experimento computacional com a série da carga horária do Submercado Nordeste. A série analisada abrange o período de 1/3/2010 até 31/12/2013 (1402 dias). No ajuste dos modelos considerou-se o período de treinamento com início em 1/3/2010 e término em 30/9/2013 (1310 dias). O período de validação considerado abrange o intervalo entre 1/10/2013 e 31/12/2013 (92 dias). Todas as etapas da metodologia foram implementadas em ambiente R (15), um *software* livre. Inicialmente foi construída a série temporal da demanda média diária (Figura 3a). Na sequência a série foi diferenciada uma vez para eliminar a tendência. A função de autocorrelação (FAC) da série de diferenças na Figura 3b exibe um padrão sazonal no qual a demanda média de um dia d está associada com a demanda média dos dias $d-7$, $d-14$, $d-21$ e assim sucessivamente.



(a) Demanda média diária



(b) FAC da série de diferenças

FIGURA 3 – Série temporal da demanda média diária e FAC da primeira diferença da demanda média

Em seguida foram avaliadas algumas configurações para uma rede neural MLP capaz de fornecer previsões da demanda média diária um dia à frente. A configuração selecionada é ilustrada na Figura 4, uma rede MLP com três camadas e sete neurônios na camada escondida. A camada de saída tem apenas um neurônio cuja saída fornece a previsão da demanda média para o dia d , quando a camada de entrada é alimentada com dados das 26 variáveis descritas na Figura 4. Destaca-se que no experimentos foram considerados apenas os feriados nacionais.

Demanda média dos dias anteriores

$d-1$, $d-7$, $d-14$ e $d-21$

Mês do dia d

jan: 1 se janeiro, 0 caso contrário

fev: 1 se fevereiro, 0 caso contrário

mar: 1 se março, 0 caso contrário

abr: 1 se abril, 0 caso contrário

mai: 1 se maio, 0 caso contrário

jun: 1 se junho, 0 caso contrário

jul: 1 se julho, 0 caso contrário

ago: 1 se agosto, 0 caso contrário

set: 1 setembro, 0 caso contrário

out: 1 se outubro, 0 caso contrário

nov: 1 se novembro, 0 caso contrário

Dia da semana do dia d

dom: 1 se domingo, 0 caso contrário

seg: 1 se segunda, 0 caso contrário

ter: 1 se terça, 0 caso contrário

qua: 1 se quarta, 0 caso contrário

qui: 1 se quinta, 0 caso contrário

sex: 1 se sexta, 0 caso contrário

Tipo do dia d

feriado1: 1 se feriado, 0 caso contrário

feriado2: 1 se carnaval, 0 caso contrário

feriado3: 1 se quarta-feira de cinzas, 0 caso contrário

feriado4: 1 se véspera de feriado, 0 caso contrário

Horário do dia d

verão: 1 se horário de verão, 0 se horário normal




FIGURA 4 – Rede neural artificial MLP para previsão da demanda média diária

Na sequência, a partir da série horária relativa ao período de treinamento foram construídos os perfis diários da curva de carga em p.u. da demanda média. Os 1310 perfis diários foram agrupados em 25 *clusters* (Figura 5a) por uma rede SOM (5 x 5), cujos centroides (curvas típicas) são apresentados na Figura 5b.

Cada *cluster* é identificado por um rótulo, um número de 1 até 25 conforme indicado pela matriz na Figura 6a. A distribuição relativa dos 1310 perfis entre os 25 *clusters* é apresentada na Figura 6b, na qual observa-se que os agrupamentos 4 e 15 concentram, respectivamente, 12,4% e 11% dos perfis diários e que apenas 13 agrupamentos concentram pouco mais de 80% dos perfis diários. Com base nos perfis apresentados na Figura 5, nos rótulos na Figura 6a e na matriz de incidência de feriados em cada *cluster* na Figura 6c pode-se concluir que os *clusters* 16, 17, 18, 19, 21, 22, 23, 24 e 25 são formados por curvas de sábado, domingo e feriados. Por exemplo, o

cluster 24 é basicamente composto por feriados. Os demais *clusters* são formados por curvas entre segunda feira e sexta feira, vésperas de feriados e as três quarta feiras de cinzas presentes no período de treinamento (um perfil no *cluster 11* e os outros dois no *cluster 20*). A matriz de incidência de horário de verão na Figura 6d indica que os *clusters* 1, 2, 6, 7, 11, 12, 16, 17 e 21 são majoritariamente formados por perfis do período do horário de verão.

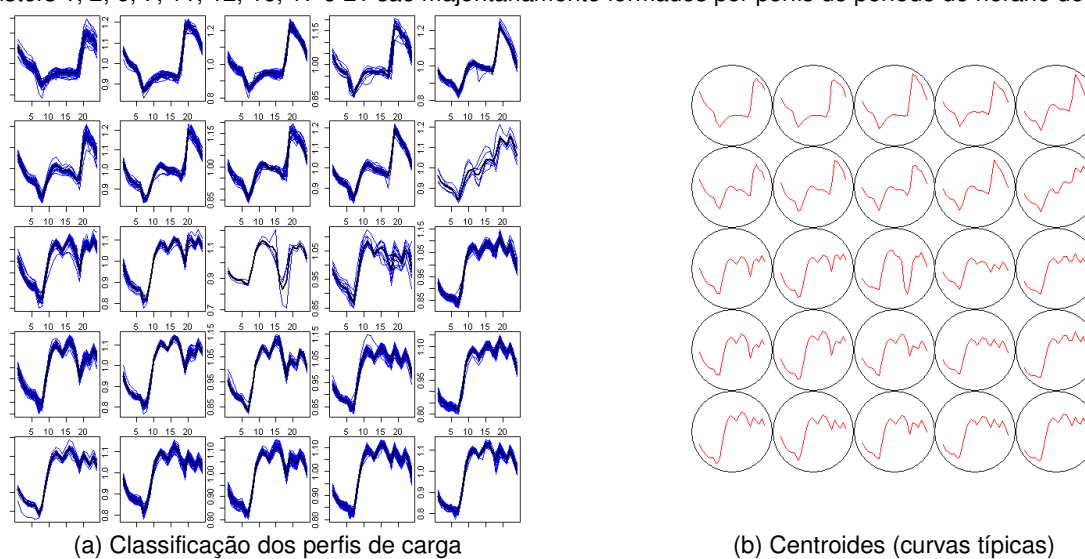


FIGURA 5 – Mapas produzidos pela rede SOM

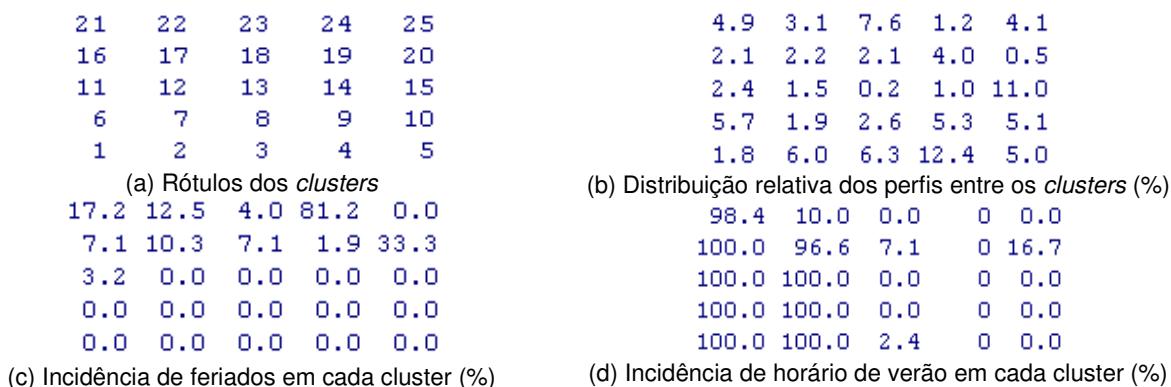


FIGURA 6 – Identificação e composição dos *clusters* (neurônios da rede SOM)

A partir da sequência de rótulos dos *clusters* e considerando que o perfil do dia d (dia da previsão) pode ser explicado pelos perfis dos dias $d-1$, $d-7$, $d-14$ e $d-21$ bem como pelo tipo do dia d (se normal, véspera de feriado, feriado ou carnaval) e período do ano (se horário normal ou horário de verão) foi possível gerar regras de associação como a ilustrada a seguir para previsão do perfil em um dia útil logo após um domingo:

SE $\text{perfil}(d-1) \in \text{cluster 22}$ E $\text{perfil}(d-7) \in \text{cluster 3}$ E $\text{perfil}(d-14) \in \text{cluster 5}$ E $\text{perfil}(d-21) \in \text{cluster 3}$ E
 dia d não é dia normal E dia d não está no horário de verão ENTÃO $\text{perfil}(d) \in \text{cluster 10}$

Ao todo foram geradas 683 regras de associação a partir da sequência de rótulos no período de treinamento. Aplicando o algoritmo de Wang-Mendel ao conjunto de regras, tendo como medida de pertinência a fórmula em (3) com $m=2$, é possível prever o rótulo e consequentemente a forma do perfil de carga (em p.u. da demanda média) um dia à frente por meio da fórmula (4). Ao final, o produto da previsão do perfil de carga pela previsão da demanda média, ambas para o mesmo dia, fornece a previsão do perfil em MW. O desempenho da metodologia proposta é avaliado pelas métricas MAPE (*Mean Absolute Percentage Error*) e MAD (*Mean Absolute Deviation*) apresentadas na Tabela 2 para os períodos de treinamento e validação. Para ter uma base de comparação as mesmas métricas foram calculadas para o predictor ingênuo no qual a previsão do perfil de carga (MW) para o dia d é determinada pelo perfil observado no dia $d-7$.

Tabela 2 – Desempenho da metodologia proposta na previsão 1 dia à frente


Metodologia	Período	MAPE	MAD
Proposta	Treinamento	1,77 %	150,42 MW
	Validação	2,08 %	194,25 MW
Predictor ingênuo	Treinamento	3,16 %	266,64 MW
	Validação	3,92 %	359,55 MW

A metodologia proposta apresentou um desempenho ligeiramente superior ao método ingênuo, pois conseguiu fazer previsões melhores nos feriados. Exemplos de previsões realizadas no período de validação são apresentados na Figura 7.


Para ser útil na programação diária da operação o previsor deve ser capaz de fornecer previsões até 2 dias à frente. Para atender este requisito a previsão um dia à frente pode ser realimentada no modelo para que este produza a previsão para o segundo dia do horizonte. Na Tabela 3 são apresentadas as métricas de desempenho para as previsões até 2 dias à frente.

Tabela 3 – Desempenho da metodologia proposta na previsão dois dias à frente


Metodologia	Período	MAPE	MAD
Proposta	Treinamento	2,09 %	177,58 MW
	Validação	2,66 %	248,27 MW
Previsor ingênuo	Treinamento	3,16%	266,57 MW
	Validação	3,93%	360,56 MW




(a) Previsão 1 dia à frente para 30/11/2013



(b) Previsão 2 dias à frente para 23 e 24 de dezembro



(c) Previsão 1 dia à frente para a véspera de Natal



(d) Previsão 1 dia à frente para o Natal

FIGURA 7 – Exemplos de previsões realizadas no período de validação

5.0 - CONCLUSÕES

O presente artigo descreveu uma metodologia de previsão de carga que pode ser útil nos estudos para programação diária da operação. A metodologia baseia-se na similaridade dos perfis de carga e emprega métodos de inteligência computacional para fornecer previsões do perfil de carga em bases horárias até dois dias à frente. Os resultados do experimento computacional conduzido com a série de carga do Submercado Nordeste são satisfatórios e mostram que a metodologia proposta é promissora, porém mais investigações devem ser realizadas no sentido de diminuir o nível de erro por meio da incorporação de outras variáveis explicativas não consideradas neste artigo, por exemplo, a temperatura e a indicação de feriados regionais. Destaca-se também o fato de todas as etapas da metodologia proposta, a leitura de dados e a apresentação dos resultados terem sido implementadas em ambiente R, um *software* livre para análise de dados.

6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) Chipp, H.J. Estrutura da Operação do Sistema Interligado Nacional, In: Nery, E. mercados e Regulação de Energia Elétrica, Editora Interciência, Rio de Janeiro: Interciência, 2012.
- (2) Hahn, H.; Meyer-Nieberg, S.; Pickl, S. Electric load forecasting methods: Tools for decision making, European Journal of Operational Research, 199, pp. 902–907, 2009
- (3) Gross, G; Galiana, F.D. Short-Term Load Forecasting, Proceedings of IEEE, vol. 75, no. 12, pp. 1558 – 1573, Dec. 1987.
- (4) Senjyu, T., Higa, S., Uezato, K. Future load curve shaping based on similarity using fuzzy logic approach, IEE Proceedings Generation, Transmission and Distribution, v. 145, n. 4, July, 1998.
- (5) Álvarez, F.M., Troncoso, A., Riquelme, J.C., Ruiz, J.S.A. Energy time series forecasting based on pattern sequence similarity, IEEE Transactions on Knowledge and Data Engineering, v. 23, n. 8, pp 1230-1243, November, 2010.
- (6) Mu, Q., Wu, Y., Pan, X., Huang, L., Li, X. Short-term load forecasting using improved similar days method, Asia-Pacific Power and Energy Engineering Conference, Chengdu, 2010.
- (7) Paparoditis, E., Sapatinas, T. Short-term load forecasting: the similar shape functional time-series predictor, IEEE Transactions on power systems, v. 28, n. 4, November, 2013.
- (8) Palit, A.K.; Popovic, D. Computational Intelligence in time series forecasting : theory and engineering applications. 1. ed. London, Springer, 2005.
- (9) Hippert, H.S; Bunn, D.W.; Souza, R.C. Large neural networks for electricity load forecasting: are they overfitted? International Journal of Forecasting 21, pp. 425– 434, 2005.
- (10) Wang, L.X.; Mendel, M. Generating fuzzy rules by learning from examples, IEEE Transactions on systems, man, and cybernetics, v. 22, n. 6, November/December, 1992.
- (11) Jang, J.-S. R.; Sun, C.T.; Mizutani, E. Neuro-Fuzzy and Soft Computing : A Computational Approach to Learning and Machine Intelligence, Prentice Hall Inc, 1997.
- (12) Cox, E. Fuzzy Modeling and Genetic Algorithms for Data Mining and Exploration, Morgan Kaufmann: San Francisco, 2005.
- (13) Haykin, S. Redes Neurais – Princípios e Prática, 2a edição. Editora Bookman, 2001.
- (14) Werbos, P.J. Backpropagation through time: What it does and How to do it, Proceedings of the IEEE, v. 78, n. 10, October 1990.
- (15) R Core Team (2014). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>.

7.0 - DADOS BIOGRÁFICOS

Victor Andrade de Almeida: Engenheiro Eletricista pela Universidade Federal do Rio de Janeiro (UFRJ, 2013), aluno do mestrado em Engenharia Elétrica da Universidade Federal do Rio de Janeiro (Coppe/UFRJ) e pesquisador do Centro de Pesquisas de Energia Elétrica (Eletrobras Cepel).

José Francisco Moreira Pessanha: Bacharel em Estatística pela Escola Nacional de Ciências Estatísticas (1992) e Engenheiro Eletricista pela Universidade do Estado do Rio de Janeiro (Uerj, 1994), Mestre em Engenharia Elétrica pela Universidade Federal do Rio de Janeiro (1999) e Doutor em Engenharia Elétrica pela Pontifícia Universidade Católica do Rio de Janeiro (2006). É pesquisador do Centro de Pesquisas de Energia Elétrica (Eletrobras Cepel) e professor adjunto do Instituto de Matemática e Estatística da Uerj.

Tatiana Mariano Lessa Assis: possui graduação em Engenharia Elétrica pela Universidade Federal Fluminense (1998), mestrado em Engenharia Elétrica pela Universidade Federal do Rio de Janeiro (2000) e doutorado em Engenharia Elétrica pela Universidade Federal do Rio de Janeiro (2007). De janeiro a março de 2009 atuou como pesquisadora visitante no Rensselaer Polytechnic Institute (EUA). Entre 2006 e 2011 foi professora da Universidade Federal Fluminense. Atualmente é professora adjunta da UFRJ e realiza pós-doutorado no Imperial College London. Tem experiência na área de planejamento da operação de sistemas interligados, aplicações computacionais em sistemas de potência, dinâmica e controle de sistemas de potência, qualidade de energia e eletrônica de potência. Atua como voluntária do IEEE desde 2010 e atualmente é vice-presidente da Seção Rio de Janeiro. É Senior Member do IEEE.