

# Electrical Customer Profile Using Fuzzy Logic Theory

T. Abreu, C. Minussi, M. Lopes, U. Alves, and A. Lotufo, *Senior Member, IEEE*

**Abstract**—Considering the increasing electrical energy demand in residences, it is necessary to know the detailed pattern of electricity use, to change the behavior of the final consumer and to reduce the global consumption. Knowing the load curve profile in advance is very important for detecting the peaks and valleys to change habits of energy consumption, principally during periods when the prices are lower, i.e., following the electrical power industry opportunities. This work studies how the consumer behaves individually, as well as identifies similarities with other consumers. Thus, we herein propose a procedure for obtaining the residential load profile using fuzzy-logic theory. As the residential electrical energy consumption is highly correlated to the active occupation, the quantity of dwellers and the different periods of the day for typical consumers are considered. However, the ideas presented in this work can be applied to other regions in different countries. To verify the efficiency of the proposed system, the obtained results are compared with real load curves.

**Index Terms**—Fuzzy logic theory, Peak time, Residential consumer, Residential load curve, Residential load profile.

## I. INTRODUÇÃO

A previsão de cargas elétricas tem grande utilidade no gerenciamento da demanda de energia elétrica. É indispensável em consequência do crescimento do número de usuários, principalmente no setor residencial [1 - 3]. O setor elétrico residencial representa 30% do total de consumidores brasileiros [4] e tem impactos significativos nos períodos de pico de demanda de energia elétrica ao longo do dia. Esses picos de carga afetam consideravelmente a eficiência do sistema de energia, resultando no congestionamento da rede elétrica [5, 6]. Assim, faz-se necessário ter-se um melhor conhecimento da curva de carga elétrica no setor residencial. Essa informação permite, aos usuários, detectar o uso indevido de energia elétrica, visando reduzir o seu consumo e viabilizando o uso da energia nas horas do dia em que a tarifa de energia elétrica possui um preço menor [7].

Os autores agradecem a CAPES (Coordenação de Aperfeiçoamento de Pessoal de Ensino Superior) e à FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) (Processo 2013/03853-4) pelo apoio financeiro.

T. Abreu, IFSP - Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Hortolândia, São Paulo, Brasil (thays7abreu@gmail.com).

C. R. Minussi, UNESP - Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, São Paulo, Brasil (carlos.minussi@unesp.br).

M. L. M. Lopes, UNESP - Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, São Paulo, Brasil (mara.lopes@unesp.br).

U. N. L. T. Alves, IFPR- Instituto Federal de Educação, Ciência e Tecnologia do Paraná, Jacarezinho, Paraná, Brasil, (uiliam.alves@ifpr.edu.br).

A. D. P. Lotufo, UNESP - Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, São Paulo, Brasil (annadiva@ieec.org).

Na literatura são encontradas diversas publicações que buscam a modelagem da carga elétrica residencial. Esses modelos são classificados em dois grupos: (a) de cima para baixo (*top-down*) e (b) de baixo para cima (*bottom-up*) [1].

Os modelos *top-down* não implicam numa grande complexidade, mas para realizar sua implementação, faz-se necessário utilizar uma extensa base de dados empíricos. Os dados utilizados são informações gerais, como: produto interno bruto (PIB), taxa de desemprego, apresentação estatística sobre a população-alvo, evolução predita, taxas de saturação de aparelhos etc. Este conceito também pode ser interpretado como de previsão agregada [8].

Os modelos *bottom-up* começam a partir das menores unidades possíveis de um sistema (residências) e, sucessivamente, vão agregando estas unidades para alcançar níveis mais elevados do sistema elétrico, obtendo o consumo de energia no setor residencial, de acordo com as suas características. Os dados de entrada são caracterizados por aparelhos domésticos, informações meteorológicas, conta de energia elétrica das famílias, comportamento humano etc. Neste caso é o que se chama de desagregado.

Usualmente os previsores são aplicados em dados de demanda agregados, em uma abordagem *top-down*, porém nos últimos anos, graças à popularização dos *smart meters*, dados de consumidores individuais passaram a estar cada vez mais disponíveis, permitindo que a previsão seja realizada para cada consumidor individualmente. Então, a demanda agregada obtida, a partir da soma das previsões de demanda individuais. Esta abordagem é denominada *bottom-up*.

Os modelos *top-down* apresentam maior vantagem por causa do seu nível de detalhes [1, 7].

Neste artigo, é utilizada uma estratégia *bottom-up*, sendo desenvolvido um modelo para obter o perfil da curva de carga elétrica residencial baseada na lógica *fuzzy* (LF) [9]. Esta abordagem é adotada tendo em vista a existência limitada (ou insuficiente) de dados no ambiente residencial que descrevem residências brasileiras, e a complexidade de modelar o comportamento humano. A partir do uso da lógica *fuzzy*, será estimado o perfil da carga baseado na observação comportamental dos usuários residenciais.

Obter o perfil de consumo de carga elétrica, em residências, não é uma tarefa fácil, pois mesmo que os clientes tenham as mesmas características gerais, (por exemplo, duas residências distintas com o mesmo número de habitantes, o mesmo tipo de habitação, número iguais de cômodos, aparelhos eletrônicos iguais etc.) é improvável que as duas curvas de demanda de energia serem iguais, ou muito similares. Essa é a razão pela qual a modelagem da demanda de energia em uma área específica é uma tarefa árdua.

Considerando que o perfil da demanda de eletricidade no setor residencial está altamente correlacionado com o tempo de ocupação das residências, no modelo proposto consideram-se a quantidade de habitantes em uma residência em diferentes períodos do dia, assim como as atividades diárias que caracterizam como as pessoas usam o seu tempo. Neste modelo, considera-se a ocupação como ativa os períodos em que os usuários estão na residência acordados ou dormindo. Nas principais publicações disponibilizadas na literatura [7, 10] são consideradas a ocupação como ativa apenas o tempo em que os usuários estão na residência e acordados.

O perfil do consumo de energia utilizando um sistema inteligente pode simular as atividades diárias dos ocupantes em suas residências e, também, contribuir no gerenciamento de demanda de energia [11-13], na resposta da demanda [11], [14-16] e, futuramente, no projeto da rede inteligente (*smart grid*) [17-19]. A rede inteligente constitui-se num novo paradigma de relacionamento entre sistema, ambiente e os consumidores. A produção de energia é caracterizada por várias fontes de geração, como, por exemplo, hidráulica, térmica, eólica, solar etc., na qual, o consumidor terá livre escolha do fornecimento de energia, podendo consumir e/ou produzir energia elétrica.

Portanto, nesta pesquisa, baseado num sistema *fuzzy* (SF), as curvas de carga residencial são “construídas” considerando as características de um grupo de domicílios brasileiros, considerando-se os períodos do dia e o número de ocupantes na casa.

Este texto encontra-se organizado do seguinte modo. O sistema *fuzzy* utilizado, para a determinação do perfil de carga residencial, é apresentado na Seção II. Na Seção III são relacionados os resultados e as discussões. Finalmente, as conclusões são apresentadas na Seção IV.

## II. SISTEMA *FUZZY* UTILIZADO PARA A DETERMINAÇÃO DO PERFIL DE CARGA RESIDENCIAL

### A. Construção da Curva de Carga Residencial

Usualmente, na literatura, o problema de previsão de carga é abordado considerando a carga global do sistema, ou seja, todos os consumidores (residenciais, comerciais e industriais). Nessa condição, os dados históricos disponíveis são usados. Portanto, é estatisticamente provável que o perfil de carga seja repetido. O problema não se limita a valores repetidos. Outras informações (exógenas) são igualmente importantes e, juntamente com os dados históricos, são utilizados como entrada do sistema de previsão. Este passo geralmente é desenvolvido usando uma alternativa clássica, por exemplo, a abordagem de Box-Jenkins [20]. Recentemente, os pesquisadores preferem usar técnicas inteligentes, por exemplo, redes neurais artificiais [21] e lógica *fuzzy* [9]. A carga global prevista está dividida entre várias barras do sistema para investigar o fluxo de energia, análise de estabilidade etc., que são estudos necessários para o planejamento e a operação do sistema de energia elétrica. No entanto, em relação às barras (dividindo a carga global), a previsão é complexa, pois o comportamento da carga não segue estatísticas regulares, isto é, no caso de residências, essa complexidade aumenta.

O caso do consumo interno é intrigante e desafiador. Neste estudo pretende-se contribuir para a previsão do consumo de energia residencial. O objetivo é propor um padrão de comportamento dos usuários residenciais e, em particular, fornecer uma ferramenta para racionalizar o uso da energia no país. Portanto, foi desenvolvido um procedimento baseado em lógica *fuzzy* [9] que precisa de pouca informação para executá-lo. É robusto e confiável, ou seja, algo simples e útil para o usuário e capaz de receber inovações.

Na metodologia proposta, emprega-se a teoria da lógica *fuzzy* para modelar o comportamento residencial com objetivo de obter o perfil da curva de carga residencial. A grande vantagem da lógica *fuzzy* é que não necessita muitas informações do hábito dos consumidores. É importante enfatizar, que este trabalho tem como objetivo fornecer a curva de perfil de consumo em residências, e não realizar a previsão de carga elétrica e calcular erros percentuais.

Para construir o perfil de consumo de energia, usando LF, foram realizadas pesquisas sobre moradores que trabalham 8 horas por dia, que é a rotina da maioria dos brasileiros.

Este estudo foi elaborado de modo empírico, observando o comportamento das famílias brasileiras em duas cidades: uma de pequeno porte e outra de grande porte. O levantamento dos dados de consumo das duas residências foi realizado de hora em hora para gerar a curva diária e comparar com a obtida pelo sistema *fuzzy*.

Isso envolveu uma pesquisa com perguntas sobre, por exemplo, os hábitos diários e quais aparelhos elétricos estão disponíveis na residência. Assim, uma entrada do FS é o parâmetro "Períodos do dia", e o outro parâmetro é definido como sendo a "Ocupação". O resultado (saída) é "Consumo de energia".

Se for desejado obter o perfil de carga de um grupo diferente de consumidores, é necessário conhecer a rotina dos novos consumidores e alterar as regras difusas usando essas informações. À medida que mais informações são obtidas dos moradores em estudo, tão próximo ao perfil de energia real é o perfil de carga por lógica *fuzzy*.

O modelo proposto é implementado no ambiente MATLAB.

### B. Entradas do SF

Para formular os conjuntos de entrada do sistema *fuzzy*, foram consideradas residências brasileiras específicas, com no máximo cinco habitantes, que realizam uma jornada de trabalho de 8 horas por dia. Foram criados dois conjuntos de entradas “Períodos do Dia” e a “Ocupação”, que serão utilizadas como variáveis de entrada do sistema *fuzzy*.

A função de pertinência utilizada para representar os conjuntos de entrada foi a função sino (gaussiana), sua escolha se deve ao fato desta função interpretar de melhor forma a representação dos períodos e das ocupações na residência.

#### 1) Períodos do dia

Para definir os diferentes períodos do dia a serem usados como conjunto de entrada SF, foi realizada uma pesquisa domiciliar (PD) para obter informações sobre a rotina diária das pessoas que trabalham 8 horas por dia, de segunda a sexta-feira. Esta é a rotina básica da maioria dos brasileiros. Considerando

esta rotina diária, oito períodos diferentes entre 0 e 24 h são definidos.

O primeiro período considerado corresponde ao primeiro período de sono. Neste período, normalmente, são utilizados os aparelhos de ar-condicionado e/ou ventiladores quando a temperatura está alta.

O segundo período, refere-se ao café da manhã. Neste período, os habitantes acordam e começam a ligar os diversos aparelhos elétricos, como: iluminação, chuveiro elétrico, micro-ondas, entre outros.

O próximo período considerado é o primeiro período de trabalho, sendo este o terceiro período do dia. Nestes períodos, os habitantes deixam suas casas para irem para o trabalho desligando todos aparelhos elétricos, excetos os aparelhos de consumo contínuo, como geladeira e freezer.

O quarto período é o do almoço. Trata-se de um período em que as pessoas dispõem de um intervalo de 2 horas (em média), para almoçarem. Neste período, consideram-se dois casos distintos, ou seja, o caso das pessoas que voltam para suas respectivas casas e, assim, consomem energia elétrica em suas residências, caso as pessoas que não retornam para suas respectivas casas.

O quinto período considerado é o segundo período de trabalho, que é o momento em que os habitantes retornam para seus respectivos trabalhos.

Ao acabar o expediente de trabalho, os moradores voltam para suas respectivas casas, ativando diversos aparelhos elétricos, como chuveiro elétrico, iluminação, TV e já começam a preparar o jantar, ou algo para se alimentarem. Esse é o sexto período considerado.

O sétimo período considerado é o descanso, sendo este o momento em que os moradores descansam após um longo dia de trabalho, ativando algum aparelho para refrigeração de ar quando a temperatura esta alta, o chuveiro elétrico quando a temperatura está amena ou fria, aparelho de TV, entre outros.

O último período utilizado é o do segundo período do sono. Neste período os habitantes estão se preparando para dormir, desativando praticamente todos os aparelhos elétricos, exceto os de consumo contínuo e os equipamentos de climatização caso a temperatura esteja alta (ar condicionado e/ou ventiladores).

Assim, oito funções de pertinência no intervalo de [0, 24] horas são definidas, o que corresponde a 24 horas do dia, para identificar os diferentes períodos do dia, ou seja, os períodos em que os habitantes estão em suas respectivas casas utilizando aparelhos elétricos ou dormindo e também os períodos que estão fora da casa.

Logo, a variável linguística "Períodos de Dia" possui oito valores linguísticos, onde cada termo é caracterizado por uma função de pertinência. de acordo com a Fig. 1.

no qual:

- Primeiro período do sono (PS1) : [0h, 6h];
- Café da manhã (CM) : [6h, 8h];
- Primeiro período de trabalho (T1) : [8h, 12];
- Almoço (AL) : [12h, 14h];
- Segundo período de trabalho (T2) : [14h, 18h];
- Jantar (JA) : [18h, 21h];

- Descanso (DE) : [21h, 23h];
- Segundo período do sono (PS2) : [23h, 24h].

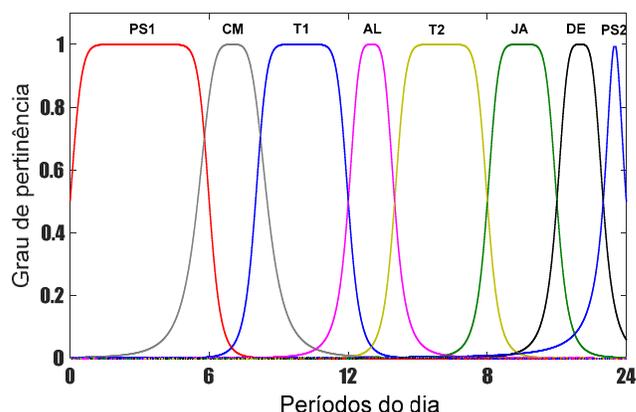


Fig. 1 . Funções de pertinência "períodos do dia".

## 2) Ocupação

Como consequência da alta correlação que existe entre o perfil da demanda de eletricidade no setor residencial, com o tempo de em que os habitantes estão nas residências, é criada a variável de entrada ocupação.

A variável linguística "Ocupação" é definida por 7 valores linguísticos que determinam se a ocupação é alta, média ou baixa, dependendo da quantidade de usuários disponíveis para utilizar aparelhos elétricos. Este trabalho propõe uma residência com um máximo de 5 habitantes. A ocupação é considerada alta quando 4 ou 5 habitantes estão na residência, médio, quando há 2 ou 3, e baixa quando há apenas um ou nenhum habitante. Cada valor linguístico é caracterizado por uma função de pertinência ilustrada na Fig. 2.

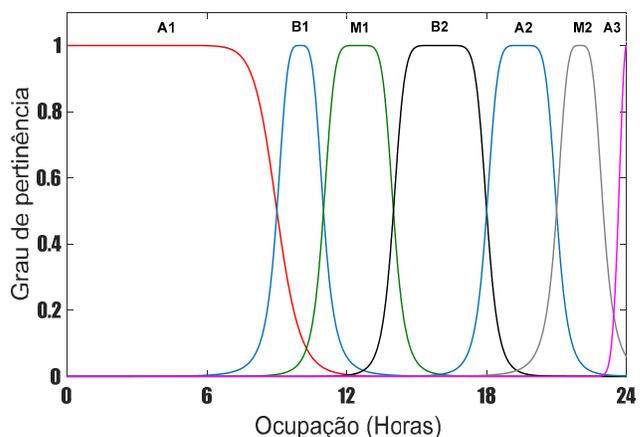


Fig. 2 . Funções de pertinência "ocupação".

sendo:

- Alta 1 (A1) : ocupação alta no período [0h, 8h];
- Baixa 1 (B1) : ocupação baixa no período [8h, 12h];
- Media 1 (M1) : ocupação média no período [12h, 14h];
- Baixa 2 (B2) : ocupação baixa no período [14h, 18h];
- Alta 2 (A2) : ocupação alta no período [18h, 21h];
- Media 2 (M2) : ocupação média no período [21h, 23h];
- Alta 3 (A3) : ocupação alta no período [23h, 24h].

### C. Saída do SF

A saída FS é representada pelo consumo de energia elétrica em um período de 24 h. O objetivo é ilustrar os perfis de consumo dos usuários durante todo o dia, indicando os tempos com mais e menos uso dos aparelhos elétricos.

#### 1) Consumo de energia elétrica

Para representar a saída do SF "Consumo de energia elétrica", cinco funções de pertinência são definidas dentro do intervalo [0, 1]. Na Fig. 3, são ilustradas as funções de pertinência, que são determinadas pelos valores linguísticos ("Muito Alto", "Alto", "Médio", "Baixo" e "Muito Baixo"). Estas informações são convertidas em valores reais entre 0 e 1. Um valor próximo de 1 significa que várias pessoas na casa para ativar os aparelhos eletrônicos e a iluminação. Um valor próximo de zero significa que há poucas pessoas e que o potencial de consumo de energia é pequeno.

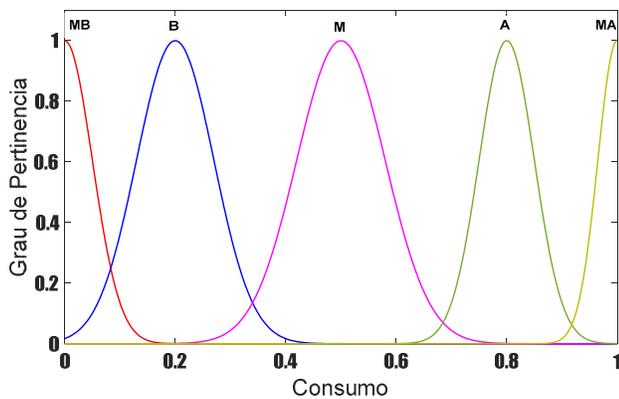


Fig. 3. Funções de pertinência "consumo de energia elétrica".

sendo:

- "Muito Baixo" (MB) : muito baixo consumo;
- "Baixo" (B) : baixo consumo;
- "Médio" (M) : médio consumo;
- "Alto" (A): : alto consumo;
- "Muito Alto" (MA) : muito alto consumo.

A função de pertinência gaussiana é escolhida porque possui a melhor representação dos valores linguísticos.

#### D. Base de Regras do SF

Depois de definidas as entradas e as saídas pelas variáveis linguísticas, é possível criar um conjunto de regras para a obtenção da curva de consumo de energia elétrica. A regra base é um dos principais componentes do SF [22]. As regras são definidas de acordo com o conhecimento de um especialista e são eficazes para obter bons resultados.

As regras utilizadas neste trabalho foram definidas de acordo com a seguinte relação:

$$\text{se } X_1 \text{ é } A \text{ e } X_2 \text{ é } B, \text{ então, } Y \text{ é } C$$

sendo:  $X_1$  (período do dia) e  $X_2$  (ocupação) são as entradas do sistema;  $Y$ , o consumo de energia, é a saída; e  $A$ ,  $B$  e  $C$  são os valores assumidos para as variáveis linguísticas. Esta relação pode ser expressa da seguinte forma: "SE antecedente, ENTÃO, consequente".

O procedimento utilizado nas entradas do SF é convertido pelas funções de pertinência para as saídas. Ao aplicar as regras, a saída é obtida, que é um número *fuzzy*, que deve ser convertido em um valor real (*crisp*). Este processo é conhecido como defuzificação. No presente estudo, emprega-se o método centroide, que é definido do seguinte modo [22]:

$$CA = \frac{\sum_{i=1}^n \mu_i v_i}{\sum_{i=1}^n \mu_i} \quad (1)$$

na qual:

$n$  : número de regras *fuzzy*;

$\mu_i$  : grau de pertinência da regra  $i$ ;

$v_i$  : atividade de controle recomendada referente a regra  $i$ .

Na Fig. 4, é representado o processo de inferência *fuzzy* em relação ao horário 17h30min, sendo consideradas as entradas como sendo as informações "Períodos do Dia" e "Ocupação". A saída corresponde ao "Consumo de Energia Elétrica". As regras (i) e (ii) são ativas neste horário. Considerando a entrada "Períodos do Dia", observa-se que às 17h30min, a variável linguística T2 possui um valor de pertinência aproximadamente igual a 0.9. A variável linguística JA possui um valor de pertinência igual a 0.15. A entrada "Ocupação", neste mesmo horário, possui a variável linguística B2 com pertinência igual a 0.9 e a variável linguística A2 com pertinência 0.15.

Utilizando a regra (i), tem-se que a pertinência, em relação à saída, é igual variável linguística B ("Baixo"):

$$\mu_i = \min\{\mu_{T2}, \mu_{B2}\} = \min\{0.9, 0.9\} = 0.9$$

Ao utilizar a regra (ii), é obtida a pertinência, em relação à saída, igual à variável linguística A ("Alto"):

$$\mu_{ii} = \min\{\mu_{JA}, \mu_{A2}\} = \min\{0.15, 0.15\} = 0.15$$

O valor real (*crisp*)  $P$ , obtido no processo de defuzificação, em relação à hora 17h30min, considerando as regras (i) e (ii):

$$P = \frac{\mu_i * v_B + \mu_{ii} * v_A}{\mu_i + \mu_{ii}} = \frac{0.9 * 0.2 + 0.15 * 0.8}{0.9 + 0.15} = 0.3$$

#### E. Base de Regras

A variável climática "Temperatura" é considerada visando definir as regras básicas que influenciam a carga residencial [23]. A "Estação do Ano" pode ser considerada como uma variável; No entanto, considerando que o Brasil é um país tropical, as quatro estações não ocorrem em períodos regulares. Em várias regiões, a temperatura no inverno é tão alta quanto a do verão. Assim, a estação é considerada uma variável climática e não fornece boas informações. As regras *fuzzy* usam a "Temperatura" como variável, o que influencia a ativação de aparelhos elétricos de alto consumo.

Diferentes regras de base são criadas em relação à variação de temperatura. Quando a temperatura é inferior a 15°C, esta é classificada como "Muito Fria" / "Fria". Se for entre 15 e 25°C, é classificada como "Muito Agradável" / "Agradável". Se a temperatura estiver acima de 25°C, esta é classificada como "Quente" / "Muito Quente".

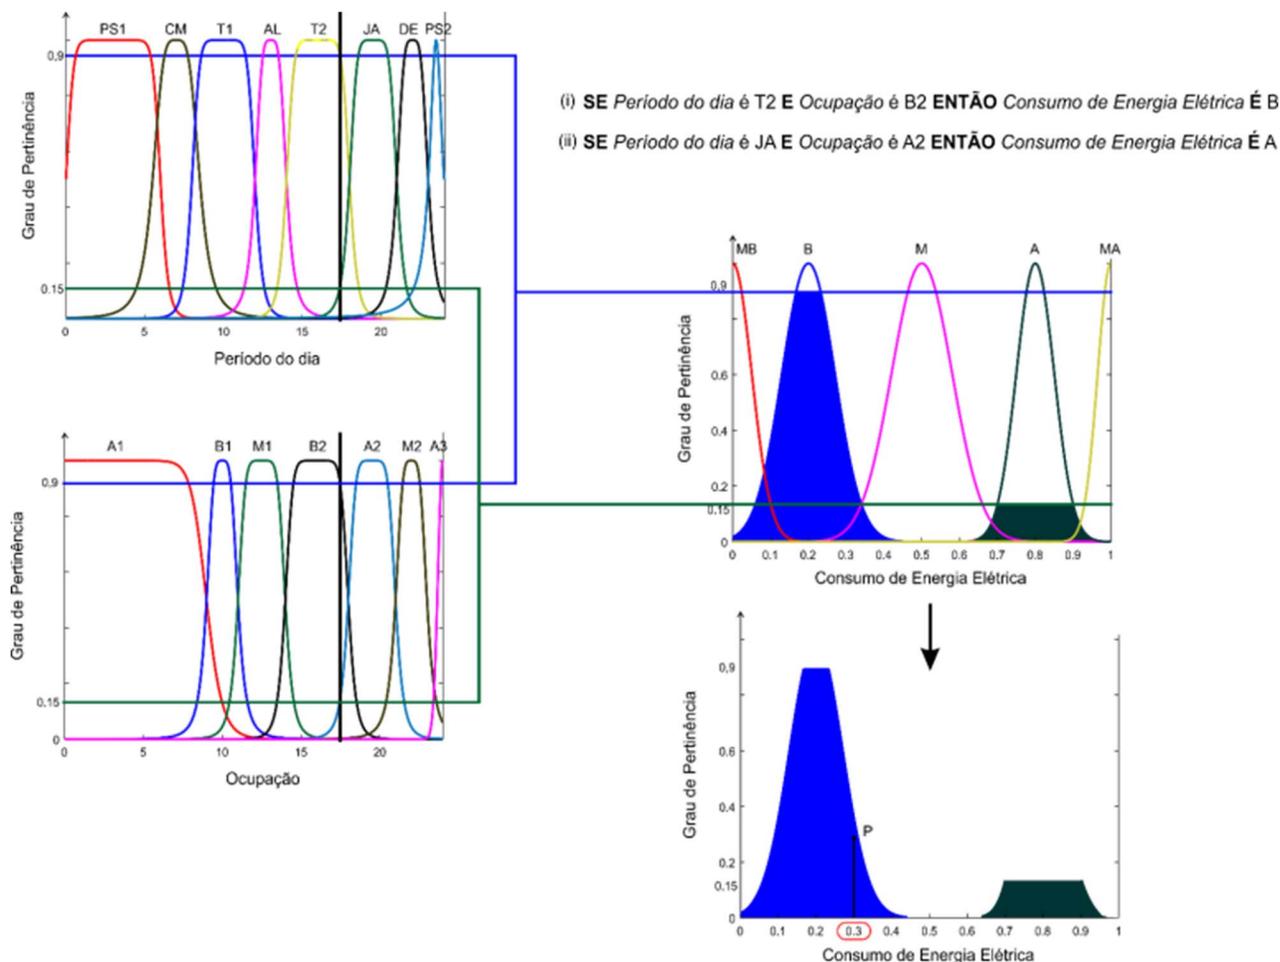


Fig. 4. Processo de inferência fuzzy.

O maior desafio é encontrar regras básicas que melhor representem o consumo de carga residencial considerando as diferentes temperaturas. Portanto, um PD é realizado em diferentes residências que correspondem ao perfil do consumidor estudado nesta pesquisa. Perguntas são feitas sobre os hábitos diários dos habitantes, quais aparelhos estão disponíveis nas residências.

O PD revela que os hábitos das pessoas que vivem em grandes cidades diferem daquelas pessoas que vivem em pequenas cidades, especialmente quando for o horário do almoço. Assim, são criadas duas base de regras diferentes, de acordo com as rotinas dos moradores em grandes cidades e em cidades pequenas.

Os aparelhos disponíveis na maioria das residências (de acordo com o PD), para a geração das regras são: refrigeradores, aparelhos de ar-condicionado, televisores, máquinas de lavar roupa, chuveiros elétricos e lâmpadas.

Nesta pesquisa serão mostrados os perfis residenciais obtidos, via execução do SF, considerando-se a temperatura acima de 25°C, ou seja, “Quente”/ “Muito Quente”. Este caso foi escolhido, pelo fato do Brasil ser um país tropical. Assim, a maioria de dos dias durante o ano apresenta temperaturas elevadas.

Serão apresentados dois conjuntos de regras, considerando-se que são distinguidos por habitantes que moram em grandes

cidades, e normalmente não retornam para suas respectivas residências no período do almoço, e o outro é definido por habitantes que moram em pequenas cidades, e assim retornam para suas residências para almoçar, ou descansar. Na Tabela I, apresenta-se o “Conjunto de Regras (A)”, que foi criado baseado em informações e observações do hábito de habitantes que vivem em pequenas cidades, enquanto na Tabela II apresenta-se o “Conjunto de Regras (B)”, sendo estas regras desenvolvidas considerando-se um habitante de grandes centros, que apresentam hábitos um pouco diferentes das pessoas que moram em pequenas cidades.

F. Geração do Banco de Dados

As regras básicas são constituídas por informações disponíveis para usuários interessados em receber benefícios fornecidos pelas empresas de energia [24]. O usuário fornece pouca informação, uma vez que os dados necessários para implementar o programa estão disponíveis no banco de dados das empresas elétricas (informações obtidas desde que a pessoa se tornou um usuário). Ao implementar este sistema, a previsão do consumo residencial com precisão aceitável pode ser realizada ajustando a curva de carga inicialmente obtida de acordo com a predição disponível em pontos próximos aos usuários, por exemplo, no transformador de alimentação onde a carga está conectada.

TABELA I  
BASE DE REGRAS (A)

Regra	Período do dia	Ocupação	Consumo
01	PS1	A1	A
02	PS1	A1	M
03	CM	A1	B
04	CM	B1	B
05	CM	M1	M
06	T1	A1	B
07	T1	B1	B
08	AL	B1	M
09	AL	M1	M
10	AL	B2	M
11	T2	B2	B
12	T2	B2	B
13	JA	A2	M
14	JA	M2	A
15	DE	M2	M
16	DE	A3	M
17	PS2	A3	A
18	S2P	A3	M

TABELA II  
BASE DE REGRAS (B)

Regra	Período do dia	Ocupação	Consumo
01	PS1	A1	A
02	PS1	A1	M
03	CM	A1	M
04	CM	B1	M
05	CM	M1	M
06	T1	A1	B
07	T1	B1	B
08	AL	B1	B
09	AL	M1	B
10	AL	B2	B
11	T2	B2	B
12	T2	B2	B
13	JA	A2	M
14	JA	M2	A
15	DE	M2	A
16	DE	A3	A
17	PS2	A3	A
18	S2P	A3	M

A carga no transformador pode ser prevista usando a proposta apresentada em [25] (previsão de carga multinodal). O ajuste pode ser realizado iterativamente, de modo que a carga total dos usuários conectados ao transformador seja igual à carga prevista do transformador (com uma tolerância predefinida). Uma vez que esta previsão está disponível, o custo computacional adicional, para ajustar a demanda de carga residencial, é basicamente insignificante. Este sistema é útil para ambientes de redes inteligentes, onde os medidores inteligentes fornecem informações abundantes [26].

Ressalta-se que uma forma de inferir a qualidade das curvas obtidas é empregar uma métrica de inferência. A mais popular forma empregar o conceito *mean absolute percentual error* (MAPE) [27]:

$$\text{MAPE} = \frac{1}{K} \sum_{k=1}^K \left| \frac{y_{\text{real}}(k) - y_{\text{calculado}}(k)}{y_{\text{real}}(k)} \right| \times 100 \quad (2)$$

Sendo  $K$  o número de amostras no período considerado;  $k$  o tempo discreto;  $y_{\text{real}}(k)$  o valor efetivamente observado/medido

no tempo discreto  $k$ ; e  $y_{\text{calculado}}(k)$  o valor obtido via aplicação da proposta apresentada neste artigo no tempo discreto  $k$ .

### III. RESULTADOS E DISCUSSÕES

#### A. Resultados

Os resultados foram obtidos de acordo com as definições dos conjuntos de entrada e de saída, bem como as regras baseadas no comportamento humano e conhecimento sobre as atividades diárias obtidas por meio do PD.

Para validar o perfil de carga residencial obtido pela execução do SF proposto, o consumo de energia elétrica foi medido considerando-se duas residências diferentes: o experimento foi conduzido levando-se em conta um conjunto de residências da cidade de Ilha Solteira (SP) (25.000 habitantes) e da cidade de São Paulo (SP) cerca de 15 milhões de habitantes). A rotina dos habitantes e a quantidade de habitantes para essas residências foram descritas nas entradas do SF proposto. O consumo de eletricidade foi medido hora a hora durante 24 h em um dia de trabalho (Quinta-Feira). A temperatura média nesse momento era de 28°C.

A qualidade e quantidade de informações, por certo, é parte essencial para o desenvolvimento desta pesquisa. Contudo, neste artigo, foi usado um conjunto basilar de informações, sendo que novas informações poderão ser incluídas visando melhorar o desempenho do sistema. Neste sentido, está-se trabalhando com vistas à realização de um módulo adicional para a extração do conhecimento permanentemente (de forma incremental) de modo semelhante ao modelo apresentado na referência [28] baseado na teoria de sistemas imunológicos artificiais (SIA).

As Fig. 5 e 6 ilustram o perfil de consumo obtido. Duas bases de regras diferentes foram criadas, considerando dois grupos de pessoas com rotinas diferentes.

Na Fig. 6 mostra-se o perfil de consumo durante 24 h, que foi obtido usando o SF e também os dados reais. Considera um dia de trabalho, para um grupo de residências em pequenas cidades, nos quais os moradores retornam para casa durante o período do almoço. Considerando que a clima em análise é quente, o maior consumo ocorre durante a noite (primeiro e segundo período de sono), por causa do uso de aparelhos de ar-condicionado, que possuem alto consumo de energia.

Para realizar a comparação, o consumo medido é normalizado considerando os aparelhos disponíveis em cada residência (potência total); isto é, a comparação é ajustada de acordo com a unidade da demanda elétrica.

Assim, a carga diária estimada total depende dos valores obtidos pela execução do SF multiplicado pela energia total consumida pela residência.

Na Fig. 5, o perfil de carga gerado pelo SF é otimista, acompanhando a curva de perfil real de consumo de energia praticamente nas 24 horas. Os picos locais ocorrem no horário de almoço entre às 12h e às 14h e outro ocorre a partir das 19h, ou seja, quando os moradores chegam em casa.

Além disso, o maior consumo ocorre entre as 23h e as 5h, tanto nos perfis reais como *fuzzy*, por causa do uso de aparelhos de ar-condicionado, formando um platô correspondente a uma

carga quase constante.

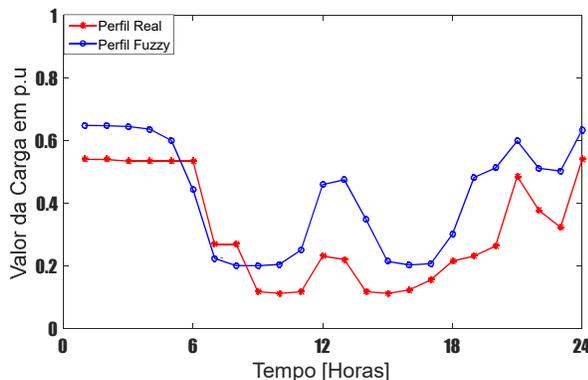


Fig. 5. Perfil de consumo residencial (a).

Na Fig. 6 ilustra-se o perfil de consumo de energia elétrica obtido pelo SF e o perfil real (medido hora a hora) durante 24 h em uma residência na cidade de São Paulo (SP).

Na Fig. 6, nota-se que o perfil do SF é o mesmo perfil do consumo real basicamente em todos os horários. O pico mais alto da carga real ocorre às 21h e o pico mais alto gerado pelo SF está entre 21h e 22h, permanecendo alto e constante das 24h às 5h nas duas curvas de carga. Considerando que os consumidores não retornam para casa durante a hora do almoço, há um vale entre às 9h às 18h.

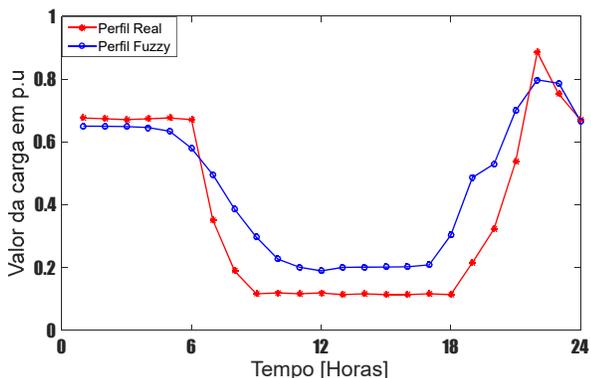


Fig. 6. Perfil de consumo residencial (b).

Na Fig. 5, bem como na Fig. 6, os resultados obtidos tomando-se como base a metodologia proposta, foram comparados com resultados conhecidos, a partir da conta de energia elétrica do cliente-alvo. Este procedimento é usado com vistas a evidenciar a qualidade das soluções, ou seja, a precisão obtida. Esta métrica é similar ao emprego métrica MAPE, a qual se constitui numa métrica *benchmark* na área de previsão de carga em sistemas elétricos, como em (2).

### B. Discussões

Nesta pesquisa propõe-se o uso de um SF para obter o perfil de consumo de energia elétrica residencial de acordo com a rotina de um grupo de consumidores.

Uma das principais contribuições desta pesquisa, é considerar como ocupação ativa o tempo que os moradores permanecem na residência, independentemente de estarem dormindo ou acordados. Os estudos relatados [8] consideraram

apenas as pessoas em casa acordadas como ocupação ativa. No Brasil, um país tropical com um clima quente quase todo o ano é necessário considerar os momentos em que as pessoas estão em casa dormindo, quando é necessário usar aparelhos com alto consumo de energia, por exemplo, aparelhos de ar condicionado.

Para confirmar que o SF pode gerar perfis satisfatórios, o consumo de duas residências diferentes é medido de hora em hora. As residências estão localizadas nas cidades da Ilha Solteira (SP) e de São Paulo (SP) O dia de trabalho selecionado é uma quinta-feira. Estas duas cidades são escolhidas por suas características muito diferentes: a primeira é pequena, com poucos habitantes e a segunda é grande, com milhares de habitantes.

As Fig. 5 e 6 evidenciam que os perfis de carga obtidos pelo SF são satisfatórios, combinando as curvas reais em quase todos os casos.

Conforme supracitada, a estimativa de carga diária e é determinada considerando os valores obtidos pelo SF multiplicado pela energia total consumida pela residência. Assim, o FS proposto pode ser interpretado como sendo uma previsão de como os moradores de uma residência usam a energia elétrica. De acordo com essa previsão, podem ser obtidas outras informações, levando a benefícios econômicos e ao uso racional da energia.

Esta predição contém imprecisões inerentes à estocasticidade do problema. A proposta encontra-se no estágio inicial e deve ser melhorada.

Alternativamente, pode-se melhorar o desempenho deste sistema via implementação de sintonia dos pesos das regras, empregando, por exemplo, o conceito do controle *fuzzy* adaptativo [29].

Ressalta-se que na literatura especializada [30], o número de funções de pertinência recomendado está compreendido entre 3 e 7 regras. Após vários experimentos, constata-se ser mais adequado usar 5 funções de pertinência nesta pesquisa. Isto evita um aumento considerável do número de regras e mantém uma boa precisão dos resultados auferidos. Desta forma, há pouca chance de produzir uma explosão de regras. Se o número de regras for bastante elevado, pode-se recorrer a um processo de redução do número de regras, por exemplo, eliminando regras redundantes, ou proximalmente redundantes. Este dispositivo tem sido sugerido em várias publicações, e.g., na referência [30].

Também, podem-se obter melhorias, de modo contínuo, na qualidade das soluções mediante a inclusão de um módulo semelhante ao que foi proposto, por exemplo, na referência [28], evidentemente com as devidas adaptações em razão de que na referência [28], na qual o método usado refere-se aos SIA. Neste artigo, emprega-se a teoria de sistemas *fuzzy*.

## IV. CONCLUSÃO

O estudo abordando a previsão de carga elétrica residencial no Brasil é escasso, por causa, a princípio, da falta de dados reais. Na Espanha, estudos com modelos estocásticos estão bem avançados. Aqui, propomos o uso de um sistema inteligente que com poucos dados de entrada pode obter o perfil de carga

residencial. Assim, um SF é proposto para obter perfis de carga residencial diária e incentivar os consumidores a mudar seu consumo nos horários de pico para momentos em que a capacidade de distribuição está aliviada.

Foram desenvolvidas duas bases de regras diferentes: uma para pessoas que vivem em grandes cidades que não voltam para casa durante o período do almoço e outra para pessoas que vivem em cidades pequenas que retornam para casa durante a hora do almoço para almoçar ou descansar. Se as pessoas retornam para casa afetam o consumo nesse período, o que é interessante para a gestão da demanda. As Fig. 5 e 6 comparam o perfil de consumo obtido usando o SF com o consumo real. Os perfis reais foram obtidos medindo a energia durante 24h nas duas cidades acima mencionadas, quando a temperatura média era de 28°C. Os perfis de consumo são semelhantes aos obtidos pelo SF e a carga real que foi medida, confirmando a confiabilidade do modelo proposto.

Com o perfil de consumo, é possível identificar os períodos de pico e evitar o congestionamento e interrupções da transmissão de energia elétrica. Além disso, essa informação pode ajudar os consumidores residenciais a economizar energia durante os horários de pico, horários em que a energia é mais cara. Por se tratar de uma versão “embrionária”, a sua concepção contempla essencialmente a modalidade em *software*. Em versões subsequentes, pretende-se, a princípio, torná-la mais eficientes contemplando a integração *hardware e software*.

#### REFERÊNCIAS

- [1] A. Grandjean, J. Adnot, and G. Binet, “A review and an analysis of the residential electric load curve models,” *Renewable and Sustainable Energy Reviews*, vol. 16, pp. 6539-6565, Oct. 2012.
- [2] F. Ferro, R. Wazlawick, R. Bastos and C. Oliveira, “Improvement of the short term load forecasting through the similarity among consumption profiles,” *IEEE Latin America Transactions*, vol. 7, pp. 527-532, Sep. 2009.
- [3] J. Jiménez, K. Donado and C. G. Quintero, “A methodology for short-term load forecasting,” *IEEE Latin America Transactions*, vol. 15, pp. 400-407, Mar. 2017.
- [4] “Anuário Estatístico de Energia Elétrica 2017 ano base 2016”, Ministério de Minas e Energia, Abr. 29, 2019 [Online]. Disponível: <http://www.epe.gov.br>.
- [5] K. V. Zúñiga, I. Castilla and R. M. Aguilar, “Using fuzzy logic to model the behavior of residential electrical utility customers,” *Applied Energy*, vol. 115, pp. 384-393, Dec. 2013.
- [6] T. Abreu, M. L. M. Lopes, U. N. L. T. Alves, C. R. Minussi and A. D. P. Lotufo, “Residential electric load curve profile based on fuzzy systems,” in: *IEEE PES Innovative Smart Grid Technologies Latin America*, Montevideo, Uruguay, 2015, pp. 624-629.
- [7] J. Torrini, “Demand side management for the European supergrid: occupancy variances of European single-person households,” *Energy Policy*, vol. 44, pp. 199-206, May 2012.
- [8] L. G. Swan and V. I. Ugursal, “Modeling of end-use energy consumption in the residential sector: a review of modeling techniques,” *Renewable and Sustainable Energy Reviews*, vol. 13, pp. 1819-1835, Oct. 2009.
- [9] L. Zadeh, “Fuzzy sets,” *Information and Control*, vol. 8, pp. 338-353, Jun. 1965.
- [10] M. A. López-Rodríguez, I. Santiago, D. Trillo-Montero, J. Torrini and A. Moreno-Munoz, “Analysis and modeling of active occupancy of the residential sector in Spain: An indicator of residential electricity consumption,” *Energy Policy*, vol. 62, pp. 742-751, Aug. 2013.
- [11] G. Strbac, “Demand side management: benefits and challenges,” *Energy Policy*, vol. 36, pp. 4419-4426, Oct. 2008.

- [12] P. Antunes, P. Carreira and M. M. Silva, “Towards an energy management maturity model,” *Energy Policy*, vol. 73, pp. 803-814, Jul. 2014.
- [13] M. Pipattanasomporn, M. Kuzlu and S. Rahman, “An algorithm for intelligent home energy management and demand response analysis,” *IEEE Trans. on Smart Grid*, vol. 3, pp. 2166-2173, Dec. 2012.
- [14] C. Bartusch and K. Alvehag, “Further exploring the potential of residential demand response programs in electricity distribution,” *Applied Energy*, vol. 124, pp. 39-59, Apr. 2014.
- [15] P. Siano, “Demand response and smart grids - A survey,” *Renewable and Sustainable Energy Reviews*, vol. 30, pp. 461-478, Nov. 2014.
- [16] S. H. Hong, M. Yu and X. Huang, “A real-time demand response algorithm for heterogeneous devices in building and homes,” *Energy*, vol. 80, pp. 123-132, Dec. 2015.
- [17] A., Molderink, V. Bakker, M. G. C. Bosman, J. L. Hurink and G. J. M. Smit, “Management and control of domestic smart grid technology,” *IEEE Trans. on Smart Grid*, vol. 1, pp. 109-119, Sept. 2010.
- [18] Z. Li and T. Yao, “Renewable energy basing on smart grid,” in: *Proc. of the 6th international conference on wireless communications networking and mobile computing*, Chengdu, China, 2010, pp. 1-4.
- [19] Y.I. Ikim, J. M. Koand and S.H. Choi, “Methods for generating TLPs (typical load profiles) for smart grid-based energy programs,” in: *IEEE Symposium on Computational Intelligence Applications In Smart Grid*, Paris, France, 2011, p. 1-6.
- [20] G. E. Box and G. M. Jenkins. *Times series analysis: forecasting and control*. San Francisco, USA: Holden-Day, 1970, pp. 1-543.
- [21] S. Haykin. *Neural networks and learning machines*. 3rd ed., Upper Saddle River, NJ, USA: Prentice-Hall, 2008, pp. 21-906.
- [22] E. H. Mamdani, “Application of fuzzy algorithms for control of simple dynamic plant”, *Proceedings of IEEE*, vol. 121, pp. 1585-1588, 1974.
- [23] T.M. O'Donovan. *Short term forecasting: an introduction to the box-jenkins approach*. New York, USA: John Wiley & Sons, 1983, pp. 1-282.
- [24] N. Ruiz, B. Claessens, J. Jimeno, J. A. López, D. Six, “Residential load forecasting under a demand response program based on economic incentives,” *International Trans. on Electrical Energy Systems*, vol. 25, pp. 1436-1451, Aug. 2015.
- [25] T. Abreu, A. J. Amorim, C. R. Santos-Junior, A.D.P. Lotufo and C.R. Minussi, “Multinodal load forecasting for distribution systems using a fuzzy-ARTMAP neural network”, *Applied Soft Computing*, vol. 71, pp. 307-3016, Oct. 2018.
- [26] D. Alahakoon, X. Yu, “Smart electricity meter data intelligence for future energy systems: a survey”, *IEEE Transactions on Industrial Informatics*, vol. 12, pp. 425-436, Feb. 2016.
- [27] D. Srinivasan, S. S. Tan, C. S. Chang and E. K. Chan, “Practical implementation of a hybrid fuzzy neural network for one day ahead load forecasting”, *IEEE Proceedings Generation, Transmission and Distribution*, vol. 145, pp. 687-692, Nov. 1998.
- [28] F. P. A. Lima, M. L. M. Lopes, A. D. P. Lotufo and C. R. Minussi, “An Artificial immune system with continuous-learning for voltage disturbance diagnosis in electrical distribution systems,” *Expert Systems with Applications*, vol. 1, pp. 131-142, Sept. 2016.
- [29] E. Cox, “Adaptive fuzzy svstems,” *IEEE Spectrum*, vol. 30, pp. 27-31, Feb. 1993.
- [30] T. J. Ross, “Classical Sets and Fuzzy Set,” in *Fuzzy Logic with Engineering Applications*, 3rd ed., Chichester, United Kingdom: Wiley, 2011, pp. 25-47.



**Thays Abreu** graduated in Mathematics from UFMS (Universidade Federal de Mato Grosso do Sul), Três Lagoas, Brazil, in 2009, MSc. and PhD. in Electrical Engineering from UNESP (Univ Estadual Paulista), Campus de Ilha Solteira, Ilha Solteira (SP), Brazil in 2012 and 2016, respectively. At this moment, she is Mathematics teacher in Federal Institute of

Education, Science and Technology of São Paulo, campus Hortolândia. She has experience in load forecasting, artificial neural network, artificial immune systems and fuzzy logic.



**Carlos R. Minussi** is graduated in Electrical Engineering from UFSM (Universidade Federal de Santa Maria) (1978). MSc and PhD in Electrical Engineering from UFSC (Universidade Federal de Santa Catarina) (1981, 1990), respectively. At present, he is full professor at UNESP, Campus of Ilha Solteira-SP. He has experience with transient stability analysis, load flow, load forecasting, dynamic and preventive control, contingency analysis, artificial neural networks, artificial immune systems, evidence theory, and fuzzy logic.



**Mara L. M. Lopes** is graduated in Mathematics from UFMS, Três Lagoas, Brazil. She received the MSc. and PhD. degrees, in Electrical Engineering, from UNESP, Campus of Ilha Solteira, in 2000 and 2005, respectively. She realized a Post-doctoral research by CNPq Project and FAPESP first doctors Project at Campus of Ilha Solteira, SP in 2007. At this moment, she is an Assistant Professor at Mathematics Department at UNESP, campus of Ilha Solteira, SP, Brazil. She has experience in Bio-statistics, Electrical Engineering with Artificial Neural Networks applications, Fuzzy Logic, electric load forecasting, and function approach.



**Uiliam Nelson L. T. Alves** is graduated in Control and Automation Engineering from UniCesumar, Maringa, PR, Brazil (2011). MSc. and PhD. in Electrical Engineering from UNESP (Universidade Estadual Paulista), Campus of Ilha Solteira, SP, Brazil in 2014 and 2017, respectively. At this moment, he is Control and Industrial Processes teacher in IFPR (Instituto Federal de Educação, Ciência e Tecnologia do Paraná), campus Jacarezinho. His research interests include Fuzzy modeling and control, Robust and nonlinear control.



**Anna Diva P. Lotufo** is graduated in Mathematics (1977) from Faculdade de Filosofia Ciências e Letras Imaculada Conceição, Santa Maria, RS, Brazil and graduated in Electrical Engineering from UFSM (1978), Santa Maria, RS, Brazil; MSc in Electrical Engineering from UFSC (1982) Florianopolis, SC, Brazil; and PhD in Electrical Engineering from UNESP, Campus of Ilha Solteira (2004), Ilha Solteira, SP, Brazil. Since 1984 she works at Electrical Engineering Department at UNESP, Campus of Ilha Solteira-SP, being an associate professor at present. She has experience with transient stability analysis, load forecasting, fuzzy logic and artificial neural networks.