

# OBTENÇÃO E APLICAÇÃO DE CURVAS DE CARGA REPRESENTATIVAS UTILIZANDO CLUSTERIZAÇÃO OU CADEIA DE MARKOV

TIAGO M. BARBOSA, TIAGO R. RICCIARDI, WALMIR FREITAS

*Dept. de Sistemas e Energia, Faculdade de Eng. Elétrica e Computação, Universidade Estadual de Campinas  
Av. James Clerk Maxwell, 30, 13083-868, Campinas, SP, Brasil*

*E-mails: {barbosat, tiago, walmir}@dsee.fee.unicamp.br*

**Abstract**— It is very important that the utilities of electric energy know the behavior of their customers in relation of consumption of energy to realize many kind of studies. The consumption of electrical energy of the customers can be represented by load profiles. In this way, this paper presented two modes to obtain representatives curves. The first mode is trough of method of clustering Modified Follow the Leader but considering the curves divided in levels. The second mode is trough of generation of synthetic curves applying Markov chain. Both methods are applied from a set of measurements acquired from a process of tariff review of a Brazilian utility of electric energy. The results show that both cluster and the synthetic curves can be used as representatives load profile to reproduce the behaviour of different kind of customers.

**Keywords**— Load Profile, Cluster, Markov Chain, Synthetic Curve, Tariff Review.

**Resumo**— É de grande importância que as concessionárias de energia elétrica tenham conhecimento do comportamento de seus consumidores com relação ao consumo de energia para a realização de diversos estudos. Tal comportamento pode ser representado por curvas de carga. Baseado nisso, neste trabalho são apresentadas duas formas para se obter curvas representativas, uma através do método de clusterização *Modified Follow the Leader* porém considerando as curvas divididas em patamares e outro através da geração de curvas sintéticas aplicando cadeia de Markov. Ambos os métodos são aplicados a partir de um conjunto de medições relativas a um processo de revisão tarifária de uma concessionária brasileira. Os resultados obtidos demonstram que tanto os clusters quanto as curvas sintéticas podem ser utilizadas como curvas de carga representativas para reproduzir o comportamento de diferentes tipos de consumidores.

**Palavras-chave**— Curva de Carga, Cluster, Cadeia de Markov, Curva Sintética, Revisão Tarifária.

## 1 Introdução

É cada vez mais importante que as concessionárias de distribuição de energia elétrica tenham conhecimento sobre o comportamento do consumo de eletricidade de seus consumidores, pois tais informações podem ser utilizadas em estudos relacionados tanto a questões técnicas quanto a questões comerciais. O comportamento dos consumidores pode ser representado por curvas de carga que indicam a potência média (demanda) em intervalos de tempo específicos ao longo do dia, porém modelar essas curvas continua sendo um desafio dada a grande variabilidade comportamental dos consumidores, sejam residenciais, comerciais ou industriais.

Apesar de já existirem vários estudos e aplicações utilizando infraestrutura de medição avançada, (do inglês *Advanced Metering Infrastructure*, AMI) como pode ser observado em (Quilumba, 2015; Wang, 2015; Harvey, 2016; Qiu, 2016; Wang, 2016), obter uma curva específica para cada cliente ainda está distante de se tornar uma realidade para grande parte das concessionárias de distribuição de energia, principalmente no caso de consumidores residenciais. Mesmo considerando essa evolução, em um primeiro momento seria necessário buscar uma forma eficiente de trabalhar com o grande volume de dados que seriam gerados com o uso dos medidores inteligentes (*smart meters*). Portanto, tanto para o caso conside-

rando a presença de medição inteligente, quanto para o caso com uma estrutura convencional, é importante a obtenção de curvas de cargas representativas para cada classe de consumidor (Jardini, 2000; Gerbec, 2003; Quilumba, 2015; Wang, 2015; Harvey, 2016; Qiu, 2016; Wang, 2016). Não é possível se obter um modelo matemático capaz de representar a realidade com 100% de precisão, porém a ideia é que se trabalhe com um modelo adequado para cada situação.

Estas curvas são utilizadas por muitas concessionárias do mundo para a realização de diversos estudos de planejamento e operação, como pode ser visto em artigos e relatórios de empresas e órgãos relacionados ao setor elétrico (MSA Report, 2004; Manhães, 2006; ATCO Electric, 2018; Florida Public Service Commission, 2017). Tais curvas auxiliam seus engenheiros nas tomadas de decisões tanto em áreas relacionadas ao planejamento quanto em áreas relacionadas à operação do sistema, com o objetivo de reduzir custos e melhorar a qualidade dos serviços prestados, através de melhores previsões de carga, planejamento da extensão do sistema, análises do mercado de energia elétrica, entre outros. Uma aplicação interessante seria melhorar o fator de carga, visto que com o conhecimento prévio dos comportamentos dos consumidores pode-se adequar cada vez mais a geração à demanda e, também, buscar alternativas de se reduzir o pico.

Uma forma para se obter estas curvas de demanda representativas é através do processo de clusteriza-

ção, o qual realiza a classificação de dados formando grupos baseados em características similares. Muitas técnicas de clusterização têm sido propostas na literatura para obtenção de padrões de curva de carga de consumidores, de acordo com as várias necessidades encontradas, como *K-Means*, *Weighted Fuzzy Average K-Means*, *Modified Follow the Leader* (MFTL), *Self-Organizing Maps*. Em seus trabalhos, Mahmoudi (2009) e Bidoki (2011) fazem comparações entre alguns métodos. Neste trabalho o método MFTL é escolhido para ser aplicado devido à vantagem de não necessitar da definição do número de *clusters* para a inicialização do algoritmo, além de calcular os centros dos *clusters* automaticamente (Bidoki, 2011). Uma característica adicionada para formação dos *clusters* consiste em dividir as curvas de cargas em patamares, aplicando o método MFTL para cada patamar, de tal forma que para duas ou mais curvas serem agrupadas em um *cluster*, é necessário que elas pertençam aos mesmos conjuntos em todos os patamares.

Outro método apresentado neste trabalho é a obtenção de curvas de cargas sintéticas aplicando-se cadeia de Markov, método utilizado por Wagner (2016) para modelagem de perfis de cargas residenciais. Este método pode ser muito interessante dependendo da aplicação, uma vez que se obtém um perfil mais detalhado do consumidor, o que não ocorre com o processo de clusterização, que ao agrupar muitas curvas, acaba modificando, algumas vezes de forma considerável, o perfil de algumas curvas. Neste caso, o processo de obtenção das curvas é estocástico, portanto os perfis de cargas são construídos ponto a ponto utilizando um conjunto de medições fixas como banco de dados. O primeiro ponto (estado) da curva é obtido de forma aleatória e, a partir deste, o valor de cada novo ponto é determinado, também aleatoriamente, utilizando como base a probabilidade de transição do ponto atual para o próximo.

Neste contexto, este trabalho está dividido da seguinte forma. Na Seção II é apresentada uma breve descrição do conjunto de medições utilizadas para a aplicação dos métodos propostos. Na Seção III o método de clusterização e o método utilizando a cadeia de Markov são detalhados. Na Seção IV são apresentados os resultados obtidos com a aplicação dos métodos e um estudo de caso através da comparação de medições em um alimentador com uma simulação utilizando o programa OpenDSS para modelar a rede e considerando as curvas de cargas dos consumidores sendo modeladas com cada um dos métodos. Na Seção V são resumidas as principais conclusões.

## 2 Conjunto de Medições

Para a realização dos estudos deste trabalho foram utilizadas medições fornecidas por uma concessionária

brasileira, obtidas durante o processo de revisão tarifária. O intervalo das medições é de 5 minutos, resultando, portanto, em curvas diárias de 288 pontos. As medições foram divididas em estratos de acordo com o estabelecido pelo módulo 2 do PRODIST (ANEEL, 2016). Após realização de um tratamento inicial nas medições, foram selecionados 1.344 consumidores de baixa tensão (BT), divididos em 396 residenciais, 219 industriais, 234 comerciais, 273 rurais e 222 de serviços públicos, além de 136 consumidores de média tensão (MT), divididos por faixa de demanda contratada. Na Tabela 1 são apresentados os estratos das três principais classes de consumidores BT e na Tabela 2 são apresentados os estratos dos consumidores de média tensão (MT) já descartando as curvas que estavam com todos os valores nulos. Para o agrupamento das curvas de carga, a classe residencial foi dividida em faixas de consumo, conforme estratos da Tabela 1, enquanto as demais foram agrupadas pelo código de Classificação Nacional de Atividade Econômica (CNAE), definidos pela Secretaria da Receita Federal do Brasil (2013). Vale ressaltar que cada classe de consumidor possui características bem distintas.

**Tabela 1. Estratos dos conjuntos de medições de consumidores de baixa tensão.**

Residencial		Industrial		Comercial *	
Estr. (kWh)	Qtd	Estr. (kWh)	Qtd	Estr. (kWh)	Qtd.
0-100	81	0-1000	138	0-500	101
100-220	113	1000-3000	44	500-2000	75
220-500	107	3000-7000	21	2000-5000	34
500-1000	54	>7000	16	>5000	24
>1000	41	---	---	---	---

\* Inclui as curvas das classes poder público e consumo próprio.

**Tabela 2. Estratos dos conjuntos de medições de consumidores de média tensão.**

Estr. (kW)	Qtd
0 - 50	23
50 - 150	58
150 - 300	36
300 - 800	17
> 800	2

A quantidade total de curvas de carga (devido à validação, a quantidade de curvas associadas a cada consumidor é diferente) de baixa tensão foi 43.160 (12.550 residenciais, 7.135 industriais, 7.685 comerciais, 8.818 rurais e 6.972 serviços públicos) e 3.538 de média tensão (610 0-50, 1.465 50-150, 946 150-300, 459 300-800 e 58 maiores que 800 kW).

Em muitas análises, convém normalizar as curvas pelo seu valor máximo, porém visando facilitar a volta para os valores reais, uma vez que o valor disponível para a grande maioria dos consumidores BT é o consumo mensal, neste trabalho as curvas foram normalizadas para um mês médio de 30 dias através de suas potências médias. O valor da potência média  $P_b$  pode ser obtido através de (1):

$$P_b = \frac{1}{24} \int_1^{24\text{horas}} C(t) dt \approx \frac{\text{consumo mensal (kWh)}}{24 * 30} \quad (1)$$

em que  $C(t)$  seria a curva de carga diária de um determinado consumidor no intervalo  $t$  (0-24 h)

### 3 Descrição dos Métodos

Nesta seção são apresentados os métodos que foram utilizados neste trabalho para obtenção das curvas representativas.

#### 3.1 Clusterização com Modified Follow the Leader

Para a aplicação deste método, se obteve previamente para cada consumidor presente no conjunto de medições, três curvas de carga, uma relativa aos dias úteis, uma para o sábado e outra para o domingo.

Dado um conjunto de curvas de carga  $L = \{l^{(c)}, c = 1, \dots, C\}$ , a ideia é que ao longo das iterações do processo de clusterização, as curvas que possuam características semelhantes sejam agrupadas em um subconjunto  $L^{(k)}$ , o qual está contido em  $L$ . Este é um processo iterativo que segue os seguintes passos:

1. na primeira iteração, uma determinada curva  $l$  é selecionada para ser o centro do  $k$ -ésimo *cluster*;
2. a distância de cada curva com relação ao centro  $q_i^{(k)}$  do *cluster* é calculada;
3. caso uma distância seja menor que o limite estabelecido, a curva associada passa a fazer parte deste *cluster*, que tem seu centro atualizado; caso contrário, um novo *cluster* é definido;
4. nas demais iterações, para cada curva, é comparada a distância com todos os *clusters* existentes e escolhe-se aquele com a menor distância para verificar se está dentro do limite. O processo se repete até que não existam modificações nos *clusters* entre duas iterações sucessivas.

Neste algoritmo, o cálculo da distância euclidiana descrita em (2) é modificado através de um fator  $\sigma_j^2/\bar{\sigma}^2$  aplicado a cada ponto da curva  $C$ , cujo parâmetro  $\sigma_j^2$  é a variância do ponto  $j$  de todas as curvas incluídas nas amostras e  $\bar{\sigma}^2$  é a média dos valores da variância  $\sigma_j^2$ , para  $j=1, \dots, J$ , em que  $J$  é a quantidade de pontos da curva. O parâmetro  $q_i^{(k)}$  indica o centro do *cluster* em questão para a  $i$ -ésima iteração do processo de clusterização  $q_{ih}^{(k)}$  e seu  $h$ -ésimo componente.

$$d(l^{(m)}, q_i^{(k)}) = \sqrt{\sum_{h=1}^H \sigma_j^2 / \bar{\sigma}^2 (l_h^{(m)} - r_{ih}^{(k)})^2} \quad (2)$$

O algoritmo de clusterização está detalhado na Figura 1. O primeiro passo consiste em definir os parâmetros de entrada: os patamares nos quais as curvas serão divididas e o limite da distância para agrupar as curvas (esse limite pode ser fixo ou variável para cada *cluster*, devido à grande variabilidade existente).

Neste trabalho, os patamares definidos foram:

- madrugada – 00:00 às 6:00 horas;
- manhã – 6:00 às 12:00 horas;
- tarde – 12:00 às 18:00 horas;
- pico – 18:00 às 21:00 horas;
- noite – 21:00 às 24:00.

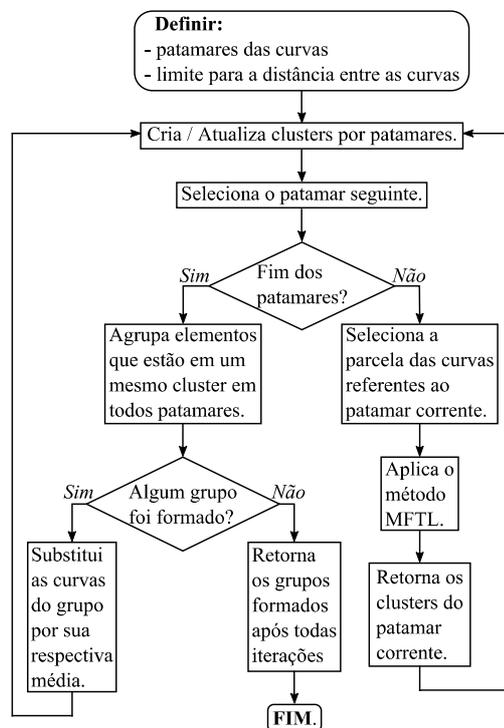


Figura 1. Fluxograma do método de clusterização – Modified Follow the Leader

Para cada patamar definido no passo anterior são formados *clusters* através do método MFTL descrito anteriormente.

Após o processo ser realizado para todos os patamares, dentro de cada *cluster* verificam-se quais curvas se encontram juntas em todos os patamares e com isso forma-se um *cluster* do conjunto. Quando nenhum novo grupo for formado, o algoritmo é finalizado.

#### 3.2 Cadeia de Markov

Para a aplicação deste método as curvas não são agrupadas, portanto, foram utilizadas todas as curvas individuais de cada consumidor (43.160 curvas de BT e 3.538 curvas de MT). Nesse caso, a normalização novamente foi feita utilizando-se a potência média de cada curva de carga, conforme (1).

Um processo estocástico é dito Markoviano quando seus estados futuros dependem apenas dos estados atuais, portanto, independente dos estados passados. Essa descrição é matematicamente representada por (3).

$$P \left\{ \begin{array}{l} X(t_{k+1}) \leq x_{k+1} | X(t_k) = x_k, \\ X(t_{k-1}) = x_{k-1}, \dots, X(t_1) = x_1, X(t_0) = x_0 \end{array} \right\} \\ = P \left\{ X(t_{k+1}) \leq x_{k+1} | X(t_k) = x_k \right\} \\ \text{com } t_0 \leq t_1 \leq \dots \leq t_k \leq t_{k+1} = 0, 1, \dots$$

Em uma cadeia de Markov, as probabilidades de transição podem ser descritas matricialmente, por meio da Matriz de Probabilidade de Transição (do inglês, *Transition Probability Matrix*, TPM), conforme (4).

$$TPM = \begin{bmatrix} P_{0.00 \rightarrow 0.00} & \dots & P_{0.00 \rightarrow M} \\ \vdots & \ddots & \vdots \\ P_{M \rightarrow 0.00} & \dots & P_{M \rightarrow M} \end{bmatrix}, \quad (4)$$

em que  $p_{i \rightarrow j} = P\{X(k+1) = j | X(k) = i\}$  representa a probabilidade de transição do estado  $i$  para o estado  $j$ . A TPM geralmente é esparsa e a tendência é que a variação entre um determinado estado e o estado seguinte seja próxima, embora algumas curvas de carga possam apresentar algumas variações bruscas ao longo do dia, como por exemplo, na partida de um motor, ou quando se liga um chuveiro elétrico. A soma das colunas da matriz TPM é igual a 1 (ou a soma das linhas, dependendo de como for estruturada a matriz). A quantidade de estados é definida de acordo com a necessidade de cada estudo. Neste trabalho, após algumas análises, foram definidos 151 estados para cada tipo de curva. Como se utiliza valores em por unidade (p.u.) e as curvas foram normalizadas pela potência média, optou-se por dividir os estados em dois grupos, em que no primeiro grupo se encontram os estados com valor até 1 pu (onde é esperado a maior concentração dos pontos) e o segundo grupo, os estados com valor acima de 1 pu, portanto:

- Grupo 1: 101 pontos, onde o limite inferior é dado pelo menor valor entre todos os pontos das curvas do conjunto e o limite superior é dado pelo mínimo entre 1 pu e o maior valor de todos os pontos das curvas analisadas;
- Grupo 2: 50 pontos, onde o limite inferior é igual a 1.01 pu e o limite superior é o maior valor entre todos os pontos das curvas analisadas. Se o valor máximo encontrado é menor que 1 pu, estes estados são descartados. Caso o valor máximo esteja entre 1 e 1.01, ele pode ser adicionado como um novo estado.

Após a definição dos estados da TPM, para cada curva do conjunto analisado são percorridos todos os pontos. Para cada ponto é verificado qual é o estado mais próximo e, a partir do estado futuro (ponto seguinte) são formadas as transições de estado. Caso a transição de estado já exista, incrementa-se 1 na contagem; caso contrário, inicia com valor igual a 1.

Com isso, para cada ponto da curva de carga é construída uma matriz de 151 x 151. No fluxograma apresentado na Figura 2, o algoritmo é detalhado.

Com a TPM definida, para cada nova solicitação feita ao algoritmo será construída uma curva sintética através de um processo estocástico, em que o primeiro ponto da curva é obtido de forma randômica e, a partir deste, o valor de cada novo ponto é determinado utilizando como base a probabilidade de transição do ponto atual para o próximo.

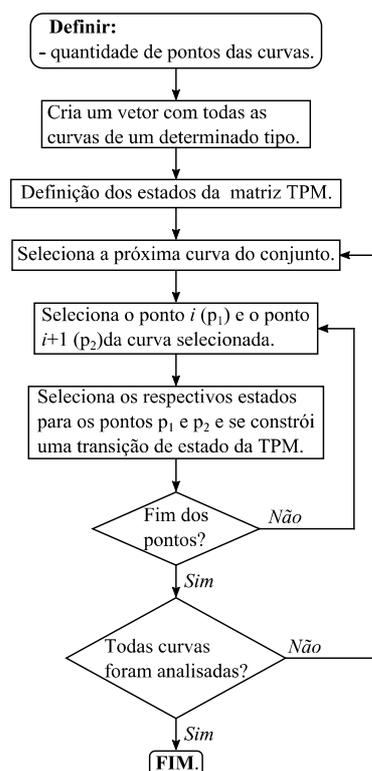


Figura 2. Fluxograma do método cadeia de Markov

## 4 Resultados

Nesta seção são apresentados alguns resultados obtidos com o objetivo de validar ambos os métodos e realizar um comparativo entre os dois.

### 4.1 Clusterização com Modified Follow the Leader

Após a aplicação do método MFTL, se obteve para cada *cluster* uma curva média  $M(t)$  e uma curva de desvio padrão  $S(t)$  (Jardini, 2000), portanto, uma curva representativa, com certa probabilidade de não ser excedida, assumindo uma distribuição normal dos valores, pode ser matematicamente dada por (5):

$$F(t) = M(t) + \rho \cdot S(t) \quad (5)$$

em que  $\rho$  é o valor em uma distribuição Gaussiana que estabelece a probabilidade  $pr(\%)$ , por exemplo, para  $\rho=1,3$ ,  $pr=90\%$ ; para  $\rho=2$ ,  $pr=98\%$ .

Na Figura 3 é apresentado um *cluster* obtido para a classe residencial da faixa de consumo entre 100 e 220 kWh. O *cluster* é representado pela curva média e de desvio padrão de todas as curvas de cargas per-

tencentas ao respectivo *cluster*. É possível verificar que muitas das curvas dos consumidores (na cor cinza) possuem elevados valores em pu, isso ocorre principalmente devido ao fato da curva ter sido normalizada pela potência média, visto que equipamentos como o chuveiro elétrico causam elevações no consumo de energia por um curto instante de tempo, e como este instante de tempo varia a cada dia mesmo considerando um único consumidor, isso acarreta em uma elevação no desvio padrão.

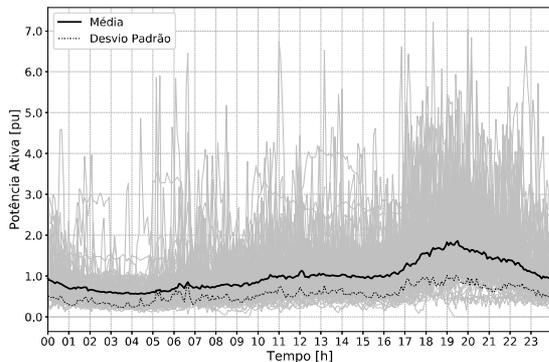


Figura 3. Curvas residenciais - faixa 100 a 220 kWh e suas respectivas curvas representativas (média e desvio padrão)

#### 4.2 Cadeia de Markov

Após a construção da TPM conforme apresentado na Seção 3, sempre que é solicitada uma curva de um determinado tipo de consumidor, o algoritmo constrói com base nas probabilidades de transições de estados obtidas a partir de um conjunto de medições. Na Figura 4 são demonstradas duas curvas obtidas para a classe residencial da faixa de consumo entre 100 e 220 kWh. Como esperado, o comportamento entre as curvas é distinto, podendo representar dois consumidores ou dias diferentes de um mesmo consumidor. Esse método pode ser útil quando se deseja construir uma quantidade considerável de curvas de cargas sintéticas para análises probabilísticas nos sistemas de distribuição de energia elétrica.

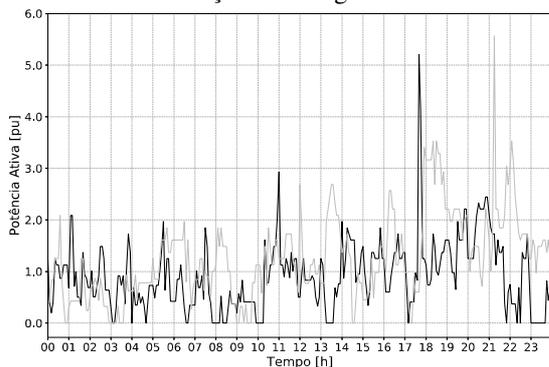


Figura 4. Curvas sintéticas residenciais (faixa 100 a 220 kWh) geradas a partir do método de cadeia de Markov

#### 4.3 Aplicação

Como teste e validação dos métodos apresentados, foi utilizada uma rede real com dados fornecidos pela mesma concessionária que disponibilizou as medições de revisão tarifária. A rede selecionada representa um alimentador de distribuição primária em

média tensão e possui 1.994 pontos de carga distribuídos conforme Tabela 3.

Tabela 3. Distribuição das Cargas – Alimentador Real

Classe / Grupo Tensão	Qtd.	Classe / Grupo Tensão	Qtd.
Residencial / BT	1743	Serv. Público / BT	1
Industrial / BT	1	Industrial / MT	3
Comercial* / BT	233	Comercial / MT	10
Rural / BT	1	Rural / MT	2

\* Inclui as classes poder público e consumo próprio.

A partir das informações do alimentador, os dados foram convertidos para o formato do programa OpenDSS e com o auxílio da linguagem de programação Python, desenvolveu-se uma rotina para realizar a simulação da rede.

Foram utilizados 59 dias de medições do alimentador (apenas dias úteis) e se obteve uma curva representativa conforme equação (5). Para a análise utilizando os *clusters* obtidos com o método MFTL modificado, nos casos em que um determinado tipo de consumidor possui mais de um *cluster*, a curva representativa é selecionada de acordo com a probabilidade de sua ocorrência analisando quantas curvas pertencem a cada *cluster*. Para a análise utilizando cadeia de Markov, o processo foi executado mais de uma vez para se obter um conjunto de curvas, nas quais também foi aplicado a equação (5) com o objetivo de se obter uma curva representativa. Na Figura 5 é mostrado o resultado obtido e na Tabela 4 é feito um comparativo das curvas das soluções com a curva relativa às medições.

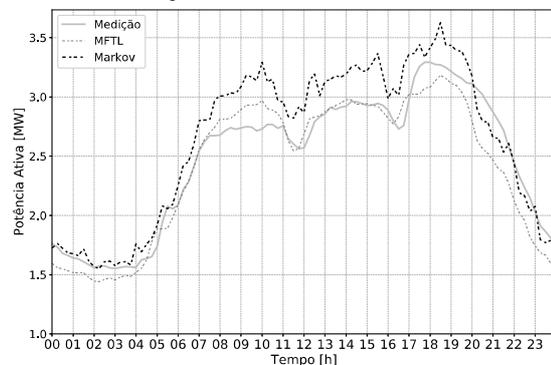


Figura 5. Aplicação das curvas representativas – Alimentador Real

Tabela 4. Comparativo – Medição x Métodos

	Medição	MFTL		Markov	
		Cálc.	Er.(%)	Cálc.	Er.(%)
Energia (MWh)	59,16	57,64	-2,60	63,00	6,49
Val. Pico (MW)	3,29	3,18	-3,37	3,63	10,11
Fator de Carga	0,75	0,76	0,80	0,73	-3,32

## 5 Conclusão

Neste trabalho foram apresentados dois métodos para obtenção de curvas de cargas representativas de consumidores em redes de distribuição de energia elétrica, um por meio de clusterização utilizando o método MFTL modificado e outro utilizando cadeia de Markov para geração de curvas sintéticas com base em um conjunto de medições.

Os métodos apresentados neste trabalho demonstram que podem ser uma opção para se obter curvas de cargas representativas, porém vale ressaltar que a qualidade dos dados e o pré-processamento dos mesmos é de extrema importância para que os resultados sejam satisfatórios. Mais testes serão realizados, principalmente em redes menores, como transformadores, visando buscar formas de se melhorar as curvas representativas obtidas.

As curvas representativas obtidas por ambos os métodos podem ser aplicadas em diversos estudos. O método utilizando clusterização (MFTL modificado) possui a vantagem de exigir um esforço computacional baixo comparado ao esforço exigido para a construção da TPM pelo método de cadeia de Markov. Uma vez obtido os *clusters*, as curvas representativas não são alteradas, portanto, trabalha-se com um conjunto fixo de curvas, já as curvas sintéticas geradas pelo método de cadeia de Markov possuem a vantagem de representar uma diversidade muito maior de curvas de carga, porém não é interessante que tais curvas sejam criadas durante a simulação, pois isso demandaria um tempo muito maior para a realização do estudo, principalmente para redes de grande porte, portanto nesse caso, o mais recomendado é se construir um banco de dados de curvas sintéticas que pode ser atualizado sempre que houver uma atualização no conjunto de medições. Outro ponto que deve ser mencionado é que quanto maior for o número de consumidores da rede a ser analisada, menor será o impacto da aleatoriedade comportamental destes consumidores.

### Agradecimentos

Agradecimentos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES e a Companhia Paulista de Força e Luz – CPFL.

### Referências Bibliográficas

- ANEEL, (2016). Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST, “Módulo 2: Planejamento da Expansão do Sistema de Distribuição,” (revisão 7).
- ATCO Electric (2018). “Load Settlement System Procedures and Methods”. [Online]. Disponível: <http://www.atcoelectric.com/Services/Retailers/Documents/Load-Settlement-Procedures-Effective-2018-01-01.pdf>
- Bidoki, S. M., Mahmoudi-Kohan, N. and Gerami, S. (2011). "Comparison of several clustering methods in the case of electrical load curves classification", Electrical Power Distribution Networks.
- Classificação Nacional de Atividades Econômicas – CNAE. [Online]. Disponível: [http://idg.receita.fazenda.gov.br/orientacao/tributaria/cadastros/cadastro-nacional-de-pessoas-](http://idg.receita.fazenda.gov.br/orientacao/tributaria/cadastros/cadastro-nacional-de-pessoas-juridicas-cnpj/classificacao-nacional-de-atividades-economicas-2013-cnae)
- juridicas-cnpj/classificacao-nacional-de-atividades-economicas-2013-cnae
- Florida Public Service Commission (2017), “Review Of The 2017 Ten-Year Site Plans Of Florida’S Electric Utilities”. [Online] pp. 13-25. Disponível: <http://www.psc.state.fl.us/Files/PDF/Utilities/Electricgas/TenYearSitePlans/2017/Review.pdf>
- Gerbec, D., Gasperic, S., Smon I. and Gubina F. (2003), “Consumers load profile determination based on different classification methods”. Power Engineering Society General Meeting, IEEE
- Harvey, P. R., Stephen, B. and Galloway, S. (2016). Classification of AMI Residential Load Profiles, IEEE Transactions on Smart Grid, vol. 7, no. 4.
- Jardini, J. A., Tahan, C. M. V., Gouvea, M. R., Ahn, S. U. and Figueiredo, F. M. (2000). Daily Load Profiles for Residential, Commercial and Industrial Low Voltage Consumers, IEEE Trans.on Power Delivery, vol. 15, no. 1.
- Mahmoudi-Kohan, N., Moghaddam, M.P., Bidaki, S. M. (2009). "Evaluating performance of WFA K-means and Modified Follow the leader methods for clustering load curves", Power Systems Conference and Exposition.
- Manhães, L. R. and Martins, B. A. S. (2006). “Aplicação de Curvas de Carga Típicas de Consumidores Integradas a Sistema GIS, na CPFL”, Seminário Nacional de Distribuição de Energia Elétrica.
- MSA Report (2004), “Residential Load Profiles”. [Online]. Disponível: <https://albertamsa.ca/files/ResidentialLoadProfiles042804.pdf>
- Qiu, W., Zhai, F., Bao, Z., Li, B., Yang, Q. and Cao, Y. (2016). “Clustering approach and characteristic indices for load profiles of customers using data from AMI”, Electricity Distribution (CICED), China International Conference.
- Quilumba, F. L., Lee, W., Huang, H., Wang, D. Y., and Szabados, R. L. (2015). Using Smart Meter Data to Improve the Accuracy of Intraday Load Forecasting Considering Customer Behavior Similarities, IEEE Transactions on Smart Grid, vol. 6, issue: 2.
- Wagner, C., Waniek, C. and Häger, U. (2016). “Modeling of Household Electricity Load Profiles for Distribution Grid Planning and Operation”, Power System Technology (POWERCON), IEEE.
- Wang, Y., Chen, Q., Kang, C., Zhang, M., Wang, K., Zhao, Y. (2015). Load profiling and its application to demand response: A review, Tsinghua Science and Technology, vol. 20, issue: 2.
- Wang, Y., Chen, Q. and Kang, C. (2016). Clustering of Electricity Consumption Behavior Dynamics Toward Big Data Applications, IEEE Transactions on Smart Grid, vol. 7, no. 5.