

DETERMINAÇÃO DE CURVAS TÍPICAS DE CARGA ATRAVÉS DAS TÉCNICAS DE MINERAÇÃO DE DADOS SOM E K-MÉDIAS

Fábio Donisete Silva, João Areis Ferreira Barbosa Júnior, Carlos Eduardo Tavares
Núcleo de Qualidade de Energia Elétrica (NQEE)
Universidade Federal de Uberlândia, Faculdade de Engenharia Elétrica, Uberlândia – MG
fabiosilva.mg@hotmail.com, johnareis@gmail.com, cetavares@eel.ufu.br

Resumo – O presente trabalho dedica-se a determinação de curvas típicas de carga de consumidores alimentados em baixa tensão, fazendo uso da combinação das técnicas de mineração de dados de Mapas Auto-Organizáveis de Kohonen (SOM) e do Algoritmo das K-médias. Para tanto, são apresentadas as principais características da utilização das técnicas de redes neurais para tratamento de dados, e posteriormente, são conduzidos estudos em uma massa de dados representativa dos perfis de potência de 81 consumidores atendidos em baixa tensão por uma concessionária do país, informações estas, obtidas através de uma campanha de medição ainda em desenvolvimento. Tais estudos têm por objetivo, entre outros aspectos, a determinação das referidas curvas típicas destes consumidores, sendo estas, de grande importância para subsidiar informações para as empresas distribuidoras de energia elétrica em suas decisões: quanto a investimentos futuros, planejamento de expansão e estudos de tarifação do setor elétrico.

Palavras-Chave – Algoritmos das K-médias, Curvas Típicas de Consumidores, Mapas Auto-Organizáveis de Kohonen (SOM), Mineração de Dados.

DETERMINATION OF TYPICAL LOAD CURVES THROUGH SOM AND K-MEANS DATA MINING TECHNIQUES

Abstract - This paper is dedicated to the determination of the typical load curves of low voltage customers by the combination of data mining techniques as Kohonen's Self Organizing Maps (SOM) and the K-means algorithm. Thus, it is presented the main characteristics of this neural networks used for data processing and then, studies are realized on a representative dataset of power patterns of 81 low voltage consumers attended by a Brazilian power utility, which are obtained through a campaign of measures in development. This study aims, among other things, the determination of the typical load curve of these consumers, which are great important in the power utility decisions as future investment, expansion planning and pricing studies of the electricity sector.1

Keywords – K-means Algorithm, Typical Consumers Curves, Self-Organizing Maps (SOM), Data Mining.

I. INTRODUÇÃO

A determinação de curvas típicas de carga de consumidores consiste em uma tarefa de suma importância para o setor elétrico, pois as informações agregadas a estas permitem às concessionárias de energia o conhecimento do perfil de consumo de seus clientes. Estas informações, em curto e médio prazo, influenciam diretamente suas decisões quanto à estrutura tarifária de energia, no dimensionamento do sistema, em alternativas eficazes para gerenciamento da demanda e servem como fonte de dados para a formulação de estratégias de comercialização de energia [1], [2], [3].

Muito embora seja reconhecida a importância das curvas típicas, o processo de determinação das mesmas não se mostra um trabalho tão simples. Ele depende, inicialmente, da realização de uma campanha de medição que consiga abranger a maior diversidade possível de consumidores atendidos pela concessionária [4]. Geralmente, delas resultam volumosas massas de dados com uma infinidade de informações a serem trabalhadas, dificultando assim a capacidade humana de análise manual destes dados, e consequentemente, a obtenção de conclusões relevantes [1].

Assim, surge o interesse tanto da comunidade científica quanto das concessionárias e agências reguladoras no desenvolvimento de metodologias que sirvam como ferramentas para auxiliar na análise de grandes quantidades de dados e informações, técnicas estas também conhecidas como mineração de dados ou *data mining*. Estas são utilizadas para destacar as características da massa de dados e obter agrupamentos, *clusters*. Os elementos contidos no mesmo *cluster* possuem maior similaridade que elementos em *clusters* diferentes. Desses clusters já se pode visualizar como é o comportamento de vários conjuntos de dados, mas é possível ainda que a partir deles sejam empregados métodos estatísticos para determinar a tipologia de carga de cada classe de consumidores [2].

Os métodos automatizados ou auxiliados por computadores, quando aplicados em um conjunto de dados, conseguem revelar padrões, similaridades e diferenças que inicialmente estavam ocultas na massa de dados [3]. Além disso, permitem ainda o agrupamento e a redução de uma grande quantidade de curvas de consumidores em uma curva típica, que represente todos os consumidores com características semelhantes. Deve-se destacar que esta curva típica mantém as características dos dados iniciais e consegue representar cada classe de consumidores, sejam eles residenciais, comerciais, industriais ou rurais.



XI CEEL – ISSN 2178-8308
25 a 29 de novembro de 2013
Universidade Federal de Uberlândia – UFU
Uberlândia – Minas Gerais – Brasil

Diante do exposto, a presente propôs por objetivo a determinação de curvas típicas de carga para consumidores alimentados em baixa tensão pelo uso da combinação das técnicas de mineração de dados por redes neurais, ou Mapas Auto-Organizáveis de Kohonen (SOM), e técnica estatística do algoritmo das K-médias, em uma massa de dados de 81 consumidores, fruto de uma campanha de medição realizada por um concessionária nacional. Para tanto, foi utilizado nos estudos o aplicativo computacional MatLab, bem como a ferramenta “*som_toolbox*”, que oferece os recursos necessários tanto para a execução da técnica SOM quanto do algoritmo K-médias.

II. MÉTODOS ITERATIVOS PARA DETERMINAÇÃO DE CURVAS TÍPICAS

Dentre os recursos disponíveis ao processo de agrupamento almejado nesta do trabalho, necessário para a determinação das curvas típicas de consumidores, estes podem ser classificados basicamente em três técnicas distintas:

- Redes Neurais;
- Lógica Fuzzy;
- Técnicas estatísticas.

A seguir serão abordadas as principais características associadas com as duas técnicas utilizadas nesta proposta, quais sejam, SOM e K-médias.

A. Redes Neurais Artificiais (RNAs)

O cérebro humano é capaz de processar informações complexas em paralelo e em um curtíssimo intervalo de tempo [5]. A partir de seu estudo foi possível criar um modelo matemático computacional que se assemelha com a organização do mesmo, o que facilitou a resolução de problemas complexos em que os métodos computacionais mostravam-se ineficientes. Assim, com essa estrutura de processamento surgiram as Redes Neurais Artificiais. O modelo do neurônio artificial proposto em 1943 por McCulloch e Pitts [5] é inspirado no neurônio biológico humano, atualmente, bastante estudado, conforme esquema ilustrado através da Figura 1.

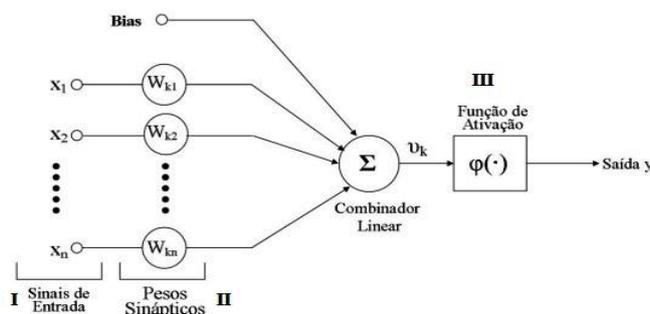


Fig. 1. Modelo de um neurônio artificial [6].

Este modelo de neurônio artificial é composto por três elementos principais:

- **Conexões de entrada:** no neurônio biológico corresponde aos detritos e aqui cada entrada (x_m) é ponderada por um peso sináptico (w_{km}).

- **A junção soma:** é responsável pela combinação dos sinais de entrada ponderada pelos seus respectivos pesos sinápticos.
- **Função de ativação:** coloca o intervalo de ativação dos neurônios confinado entre $[0,1]$ ou $[-1,1]$, restringindo a amplitude de saída do neurônio a um valor finito.

Onde $x_0, x_1, x_2, \dots, x_m$ são os sinais de entrada que serão convertidos em um neurônio de entrada e $w_{k0}, w_{k1}, w_{k2}, \dots, w_{kp}$ são os pesos sinápticos do neurônio k . Com isso, temos que v_k produz o nível de atividade interna do neurônio, sendo que se $w_{km} > 0$ a conexão sináptica é conhecida como excitatória e se $w_{km} < 0$ ela é chamada de inibitória. O valor de bias, b_k , serve para aumentar ou diminuir a influência do valor das entradas. Deve-se submeter essa saída à função de ativação $f(v_k + b_k)$, que normalmente é um do tipo não linear e que limita a saída do neurônio onde $x \in \mathcal{R}$ e $y(x) \in [-1,1]$ [1].

A principal característica das RNAs é a capacidade de aprendizado através de exemplos *input/output*. Isso é feito automaticamente ajustando os pesos sinápticos e os níveis de bias, sendo que existem muitos algoritmos de aprendizagem para as RNAs que podem ser divididos em: aprendizado supervisionado e aprendizado não supervisionado [6]. A diferença básica é que no aprendizado supervisionado existe um “professor externo” que estimula às entradas da rede por meio de padrões de entrada e monitora a saída calculada comparando-a com a desejada. Já o não supervisionado como não há um professor para acompanhar o aprendizado, isso é feito utilizando-se somente os padrões de entrada e a rede é ajustada de acordo com regularidades estatísticas desses dados. Nesse contexto destaca-se o aprendizado não supervisionado por competição em que há disputa para ganhar a camada de saída e somente um neurônio poderá ser ativado a qualquer momento (*winner-takes-all*). O neurônio vencedor terá seus pesos sinápticos atualizados no treinamento e esse tipo de aprendizado é a base para os modelos ART de Grosberg e para os Mapas de Kohonen [1,7].

Uma Rede Neural Artificial é constituída por um conjunto de neurônios interligados para aumentar a capacidade de resolução de problemas. Normalmente, é convencionado na representação das RNAs que os vértices sejam os neurônios, as arestas as sinapses e as pontas das flechas mostram o caminho de alimentação [7]. Com isso, a organização da rede está ligada ao tipo de problema que deve ser solucionado, sendo possíveis três configurações: Rede *Feedforward*, Rede *Feedback* e a Rede Auto-organizáveis.

As Redes *Feedforward*, também chamadas de Redes Alimentadas Adiante, caracterizam-se pela disposição dos neurônios em forma de camadas e o fluxo de informação sempre ser levado para frente. Pode haver as Redes de Camadas Únicas e as Redes de Múltiplas Camadas que se diferenciam apenas pelo número de camadas.

Enquanto isso, nas redes *Feedback*, também chamadas de Redes Recorrentes, há a realimentação, ou seja, a saída de um neurônio é aplicada como entrada de neurônios anteriores da rede. Essa organização topológica é muito utilizada em problemas que envolvem previsões de eventos futuros e para recuperação de padrões de entrada.

Por fim, nas redes auto-organizáveis, os neurônios estão divididos na camada de entrada e na camada de saída, chamada de “grade”, na qual cada grupo de neurônios responde a um estímulo da entrada de dados. A principal aplicação é sua utilização para o agrupamento e compressão da massa de dados, sendo o maior exemplo os Mapas Auto-organizáveis de Kohonen. Um exemplo ilustrativo de uma rede auto-organizável pode ser observado na Figura 2.

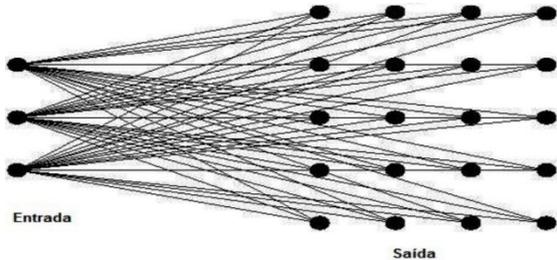


Fig. 2. Esquema de uma Rede Auto-organizável [5].

B. Redes neurais Auto-Organizadas de Kohonen (SOM, “self-organizing maps”)

O SOM foi desenvolvido pelo finlandês Teuvo Kohonen em 1982 e é uma Rede Neural Artificial (RNA) com treinamento competitivo e não supervisionado, ou seja, que é capaz de estabelecer relações complexas entre os dados sem a necessidade de fornecer as regras sobre as funções que as relacionam e ainda, decidir quais critérios usará para agrupar os dados, processo conhecido como auto-organização [8].

Ele pode realizar uma projeção não linear do espaço de dados de entrada em \mathcal{R}^D para o espaço de dados do arranjo em \mathcal{R}^P , reduzindo a dimensionalidade quando $P < D$. Entretanto, costuma-se utilizar um arranjo uni ou bidimensional, ou seja, $P = 1$ ou $P = 2$. Observa-se nesse arranjo a formação de um mapa topográfico de duas camadas sendo uma a camada de entrada e a outra a camada de Kohonen, na qual as localizações dos neurônios seguem características intrínsecas dos padrões de entrada que caracteriza a auto-organização como na figura 3 [9].

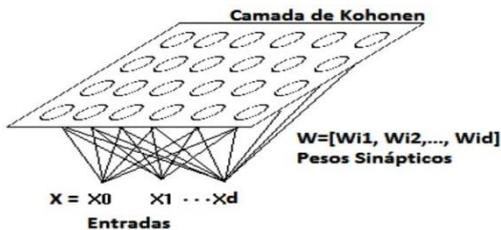


Fig. 3. Representação do SOM [5].

Aplicando esses conceitos ao agrupamento de curvas de carga observamos o seguinte diagrama da figura 4.

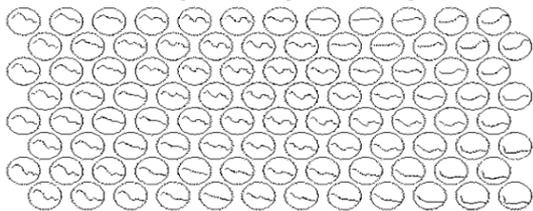


Fig. 4. Neurônios representando a curva de carga de cada cliente [9].

Na figura anterior, observar que após a aplicação do SOM em curvas de carga dos clientes, ele retornou uma grade bidimensional em que cada neurônio representa as características de um conjunto de clientes. Temos ainda que um neurônio apresenta grande similaridade com neurônios próximos a ele e também uma grande distinção entre neurônios que estejam mais afastados.

A U-Mat é a matriz de distâncias entre cada neurônio do mapa e seu vizinho. Por isso, é uma técnica mais eficiente de detecção de *cluster* da rede SOM. Em sua análise, há duas formas de se caracterizar um cluster. Observa-se que valores mais altos na barra de cores que deve ser mostrada ao lado do mapa, correspondem às distâncias maiores entre os neurônios do mapa, e os mais baixos, representado por cores mais claras mostram a similaridade entre os neurônios adjacentes, o que caracteriza um *cluster* [1]. Isso pode ser observado claramente na figura 5.

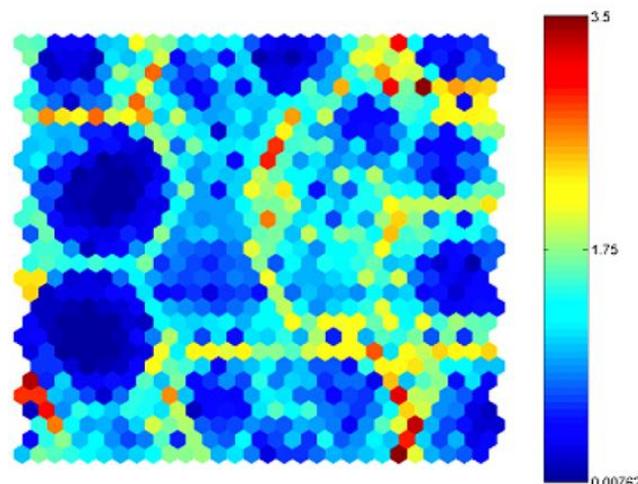


Fig. 5. Matriz de Distâncias Unificadas (U-Mat) [10].

Para ajudar na escolha do mapa é possível utilizar duas métricas computacionais mais simples e menos dependente de $h_{k,i}$ que são o Erro Médio de Quantização (*Quantization Error – QE*) e o Erro Topográfico (*Topographic Error – TE*) [1].

1) Erro Médio de Quantização

Esse erro corresponde à média das distâncias entre cada vetor de dados v_n e o correspondente vetor de pesos m_c do BMU. O QE mostra a resolução do mapa, sendo que se o valor de QE diminui a resolução do mapa aumenta, mas, para isso, aumentará também o número de neurônios no mapa. Devemos, então, nos atentar para um número máximo de neurônios para que o SOM consiga fazer a generalização dos dados de entrada. Esse erro é dado por:

$$QE = \frac{1}{N} \sum_{n=1}^N \|m_c - v_n\|$$

Onde N é o número de neurônios.

2) Erro Topográfico

O TE mede a capacidade do mapa de representar a topologia dos dados de entrada quantitativamente. Para isso, de cada objeto de v_n é calculado o primeiro BMU m_c e o segundo BMU m_d , o que define o erro como:

$$TE = \frac{1}{N} \sum_{n=1}^N u(v_n)$$

Onde N é o número de neurônios e $u(v_n) = 1$ quando m_c e m_d não são adjacentes.

C. Considerações sobre os parâmetros do SOM

Devido à ausência de fundamentação teórica sobre o SOM [1], podem ser propostas heurísticas baseadas na observação do comportamento do mapa e em medidas estatísticas de qualidade. Assim, resumidamente temos:

- O cálculo do número de neurônios possui mais de uma heurística, a citar o SOM Toolbox no MatLab que propõe $Q = 5\sqrt{N}$, onde N é a quantidade de dados de entrada como uma estimativa razoável.
- Para facilitar na facilidade de visualização dos agrupamentos na U-mat é aconselhável a utilização do arranjo de vizinhança hexagonal com a função de vizinhança, $h_{k,i}$, que adapta a vizinhança do neurônio vencedor, baseado na função gaussiana.
- Utilizar inicialização linear para o arranjo hexagonal, no caso, procurando prevenir torções indesejáveis no arranjo ao longo do treinamento, embora seja importante lembrar que o SOM não tem garantia teórica de convergência, sendo essa “convergência” chamada de estados de absorção.
- Utilizar duas fases de treinamento mesmo se houver inicialização linear do arranjo. Deve-se dar preferência ao algoritmo *batch* ao incremental, onde a taxa de aprendizado $\eta(t)$ é fixa e vale 0,5 na fase inicial e 0,05 na fase de convergência.
- O raio da função $h_{k,i}$ é calculado de acordo com a fase do treinamento: na fase inicial o raio varia de $\frac{md}{4}$, onde md é a maior dimensão do arranjo plano, largura ou altura, e termina em $\max(1, \frac{md}{4})$. Já na fase final de convergência, o raio inicial começa em $\frac{md}{4}$ e termina em 1.
- O número de épocas de treinamento é estimado em $\frac{10Q}{N}$ para a fase inicial e $\frac{40Q}{N}$ para a fase de convergência, sendo Q a quantidade de neurônios no arranjo e N o número de dados iniciais para o treinamento.

D. Agrupamento por K-médias

Esse algoritmo foi desenvolvido por J. B. MacQueen em 1967 e é um método clássico para construção K grupos a partir de uma massa de dados. É caracterizado por ser não hierárquico, ou seja, uma curva de carga pode ser alocada, inicialmente, em um grupo e, posteriormente, em outro de forma que cada curva pertença apenas a um grupo [12].

As informações de entrada para o algoritmo são: a massa de dados e o número de centróides (K), que deve ser definido *a priori* [1, 13, 14]. A partir disso, o algoritmo procura minimizar a distância euclidiana entre cada curva de carga e as curvas centróides, curvas de referência, de forma iterativa.

A grande vantagem desta heurística é a simplicidade e a velocidade com a qual convergem os seus resultados. Entretanto, observa-se que o método é sensível aos *outliers*, que são pontos que não pertencem a nenhum agrupamento. Assim, existem curvas que não deveriam pertencer a nenhum agrupamento, mas que podem distorcer os resultados e diminuir a qualidade das informações obtidas dos clusters. Outra questão que deve ser analisada é a inicialização dos centróides iniciais que pode produzir clusters de má qualidade até mesmo separando clusters naturais [11].

E. Agrupamento por combinação de métodos

Para avaliar e comparar a desempenho dos algoritmos de clusterização existem seis medidores de adequação, a citar: o Índice de Davies-Bouldin, o Erro Quadrático Total ou Função do Erro (J Function), o Mean Index Adequacy (MIA), o Clustering Dispersion Indicator (CDI), o Similarity Matrix Indicator (SMI) e o Ratio of within cluster sum of squares to between cluster variation (WCBCR) [15].

Utilizando o MIA, que mede a compactação dos agrupamentos, e o CDI, que mede a separação entre os agrupamentos, nos algoritmos anteriormente descritos, os melhores resultados desses índices foram observados quando houve a combinação dos métodos do Mapas Auto-organizados de Kohonen e o K-means clássico [16].

Devido ao fato do SOM ter uma boa performance trabalhando com uma grande massa de dados, ele deve ser utilizado inicialmente para reduzir a massa de curvas iniciais a um grupo de unidades vencedoras, os neurônios, que são mostradas em um espaço bidimensional. A partir disso, o K-means é utilizado no agrupamento dos vetores de saída do SOM para a obtenção dos clusters e, posteriormente à realização da média aritmética com esses clusters, a obtenção da curva típica de determinada classe de consumidores [5]. Assim, combinando o SOM e o K-means, de acordo com os índices anteriormente citados, é possível resolver as limitações de cada método e obter uma solução robusta para o tratamento da massa de dados. Podemos utilizar ainda o Índice de Davies-Bouldin e a Função de Erro para a determinação do valor dos K agrupamentos que, normalmente, não é possível conhecer *a priori*.

III. DETERMINAÇÃO DE CURVAS TÍPICAS DE CONSUMIDORES: ESTUDO DE CASO

A massa de dados utilizada para este estudo de caso foi obtida através de uma campanha de medição realizada por uma concessionária do setor elétrico nacional. Os medidores foram instalados no secundário de transformadores de distribuição, na entrada de residências e na saída de alimentadores para registrar tensões, correntes, potências assim como todos os indicadores associados à qualidade de energia elétrica. Para a realização das medições foram utilizados os medidores MedCal NT de uso ao tempo (IP-65), MedCal ST de uso ao tempo (IP-65) ou de uso abrigado, somando ao todo 50 medidores.

Devido a questões logísticas e buscando uma compatibilização entre o número de consumidores a serem avaliados e a quantidade de equipamentos disponíveis para a

campanha de medição, optou-se pela realização de medições pelo período 7 dias de duração, buscando assim a obtenção do ciclo semanal de carregamento de cada consumidor. Ao longo deste intervalo, os equipamentos disponibilizam valores médios a cada 10 minutos e foi obtido um total de 1008 mostras que foram reduzidas, manualmente, escolhendo o melhor dia para representar esses 7 dias medidos. A primeira medição se iniciou às 0:00 e a última, de número 144, terminou às 23:50 passaram normalização da potência ativa com a equação:

$$P_{normal} = \frac{P_{medido}}{P_{base}} [pu]$$

Onde P_{norm} é a potência normalizada em função da maior potência observada ao longo do período de medição, P_{medido} é a potência ativa a cada integralização de 10 minutos e P_{base} é a maior potência observada ao longo do período de medição.

Alguns fatores podem influenciar nas curvas de carga dos consumidores, dentre eles o período do ano em que foram feitas as medições, a região do país e a curva escolhida para ser a representativa, visto que podemos ter uma para os dias da semana e outra para os finais de semana. Em função disso, neste estudo de caso, uma atenção especial é dada somente na curva fornecida pela concessionária de energia e na sua utilização para a determinação da curva típica do conjunto, visto que não foram fornecidos muitos dados da campanha de medição.

A. Obtenção das curvas típicas de consumidores através de métodos iterativos

A metodologia adotada consiste na combinação dos métodos SOM e K-means, fazendo uso ainda do Índice de Davies-Bouldin e a Função de Erro. Vale ressaltar que o primeiro método responderá pela redução inicial da massa de dados, enquanto o segundo fará o agrupamento das curvas em clusters. Enquanto isso, o Índice de Davies-Bouldin e a Função de Erro auxiliarão na determinação do número ideal de agrupamentos.

Muito embora os fundamentos teóricos das metodologias utilizadas estejam disponíveis em diversos trabalhos de pós-graduação e artigos científicos, permitindo assim a reprodução das mesmas através de qualquer linguagem de programação, por alguns motivos técnicos optou-se pela utilização dos recursos disponibilizados na “*som_toolbox*” pré-existente no programa MatLab. Nesta *toolbox*, encontram-se os recursos necessários para a reprodução dos métodos de Mapas Auto-Organizáveis (SOM) e K-means que foram adaptados para a determinação das curvas típicas de carga.

Para ilustrar o processo, pode-se observar na Figura 6 a massa de dados inicial dos 81 consumidores residenciais de baixa tensão, denominados por CLB.

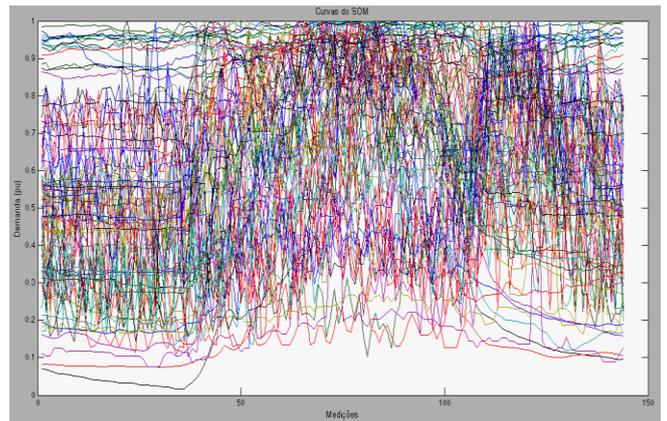


Fig. 6. Massa de dados inicial.

B. Análise dos Resultados

A partir de uma rotina desenvolvida no MatLab utilizando a “*somtoolbox*” com as técnicas do SOM na redução do número de curvas, do Índice de Davies-Bouldin e da Função do Erro para determinação do número ótimo de clusters e, por fim, do algoritmo das K-médias. Observe as curvas obtidas do SOM e a U-Mat da mesma na Figura 7.

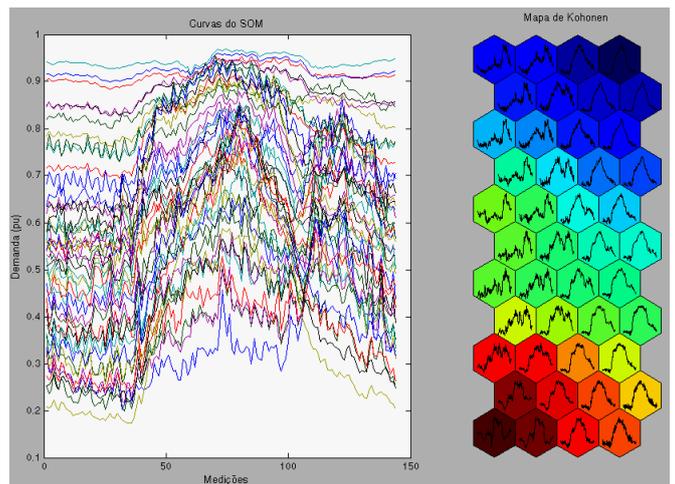


Fig. 7. Curvas do SOM e o Mapa de Kohonen.

Já a figura 8 mostra o resultado do Índice de Davies-Bouldin e da Função do Erro.

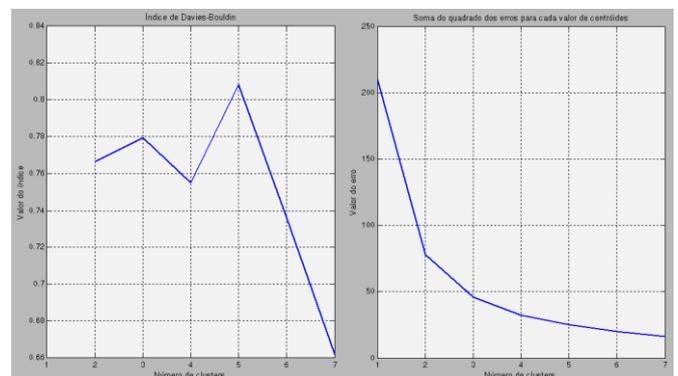


Fig. 8. Índice de Davies-Bouldin e a Função do Erro.

Desses gráficos e utilizando as heurísticas discutidas anteriormente, observa-se que o número ideal de clusters é 7. Assim, das 7 curvas que representam esses clusters a curva típica pode, sem grandes prejuízos, ser obtida fazendo a média aritmética das curvas dos centróides do Kmeans [8]. Isso é feito com $\frac{\sum_{i=1}^N i - \text{ésima medição}}{N}$, onde N é o número máximo de clusters. Portanto, a curva típica de carga dos 81 consumidores baixa tensão da campanha de medição obtidos da média aritmética dos 7 centróides segue na figura 9 abaixo.

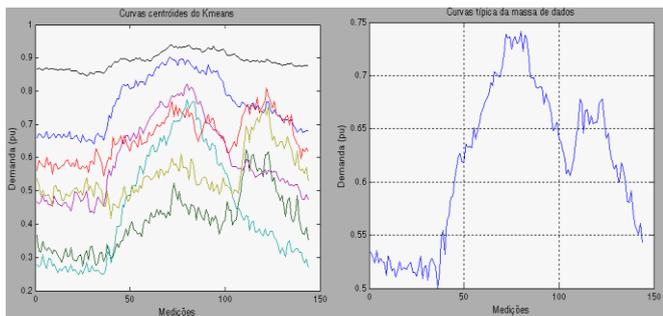


Fig. 9. – Curva típica dos consumidores baixa tensão

IV. CONCLUSÕES

Neste artigo foram apresentados resumidamente os procedimentos para obtenção da tipologia de curvas de carga de um estudo de caso de consumidores residenciais de uma concessionária do país. Essa curva típica obtida é fundamental no estudo da tarifação dos serviços de distribuição de energia elétrica.

Pela curva típica de carga obtida, observa-se que consumidores da distribuidora tendem a aumentar o seu consumo, principalmente, em dois momentos do dia, a citar por volta das 8 da manhã e a partir das 5 horas da tarde. Isso é compatível com o que se esperava a classe residencial de consumidores, pois é o horário que a maioria da população mais utiliza a energia em suas casas. Observa-se ainda que do menor valor de demanda, durante a madrugada, até o horário com maior utilização que ocorre por volta de meio dia, há o aumento de cerca de 50% no consumo de energia passando de 0,5 para quase 0,75 pu.

Portanto, a metodologia proposta neste trabalho ferramenta eficaz para as distribuidoras de energia elétrica conhecer o perfil de consumo de seus clientes. Isso foi possível utilizando dois algoritmos da data mining para reduzir a massa inicial de dados com o SOM e, posteriormente, agrupar os dados restantes com o Kmeans.

REFERÊNCIAS

[1] M. H. Zuchini, “Aplicação de Mapas Auto-organizáveis em Mineração de Dados e Recuperação de Informação”, Dissertação de Mestrado, Faculdade de Engenharia Elétrica e de Computação (FEEC), Unicamp, Campinas/ SP, 2003.
 [2] S. V. Verdú, M. O. García, C. Senabre, A. G. Marín, F. J. Franco, “Classification, Filtering, and Identification of Electrical Customer Load Patterns Through the Use of

Self-Organizing Maps”, *IEEE Transactions on Power Systems*, vol. 21, n° 4, Nov. 2006.
 [3] U. Fayyad, G. Piatetsky-Shapiro, P. Smyth, *Advances in Knowledge Discovery and Data Mining*, 1ª Edição, American Association for Artificial Intelligence/ MIT Press, 1996.
 [4] H. do N. Alves, *Sistemas de Energia Elétrica*, Apostila da disciplina Sistemas de Energia Elétrica, Departamento de Eletroeletrônica, CEFET-MA, São Luis/ MA.
 [5] E. R. Alves, “Mineração de Dados Baseada em Inteligência Computacional: uma Aplicação à Determinação da Tipologia de Curvas de Carga”, Dissertação de Mestrado, UFPA, Belém/ PA, 2011.
 [6] A. R. Gonçalves, *Redes neurais*, disponível em <http://www.dca.fee.unicamp.br/~andrerick/arquivos/pdfs/redes_neurais.pdf>, acesso em 13 mai. 2013
 [7] S. P. Zambiasi, *O neurônio artificial*. Acedido em 13 de Maio de 2013 em: http://www.gsigma.ufsc.br/~popov/aulas/rna/neuronio_artificial/index.html
 [8] G. M. de F. Paula, “Curvas típicas de carga para o planejamento operacional do sistema de distribuição”, Dissertação de Mestrado, Universidade de São Paulo, São Paulo/ SP, 2006.
 [9] T. Kohonen. *The Self-Organizing Map (SOM)*. Acedido em 17 de Dezembro de 2012 em: <http://www.cis.hut.fi/projects/somtoolbox/theory/somalgorithm.shtml>.
 [10] R. J. Sassi, “Uma Arquitetura Híbrida para Descoberta de Conhecimento em Base de Dados: Teoria dos Rough Sets e Redes Neurais Artificiais Mapas Auto-Organizáveis”, Dissertação de Doutorado, Universidade de São Paulo, São Paulo/ SP, 2006.
 [11] M. Sperandio. “Classificação de Conjuntos de Consumidores de Energia Elétrica Via Mapas Auto-Organizáveis e Estatística Multivariada”, Dissertação de Mestrado, Universidade Federal de Santa Catarina, Santa Catarina/ SC, 2004
 [12] M. M. F. Gemignani. “Proposição e análise comparativa de métodos alternativos de seleção e classificação de curvas de carga para definição de tipologias de estudos tarifários”, Dissertação de Mestrado, Universidade de São Paulo, São Paulo/ SP, 2009.
 [13] R. Linden, *Técnicas de Agrupamento*, Revista de Sistemas de Informação FSMA, Rio de Janeiro, p.18-36, 2009.
 [14] L. C. Pinheiro, Método de representação espacial de clustering, Dissertação de Mestrado, Departamento de Informática, Universidade Federal do Paraná, Curitiba/ PR, 2006.
 [15] G. J. Tseroukas, I. K. Hatzilau, J. M. Prousalis, “A new pattern recognition methodology for classification of load profiles for ships electric consumers”, *Journal of Marine Engineering and Technology*, n°. A14, 2009.
 [16] V. Figueiredo; F. Rodrigues; Z. Vale; J. B. Gouveia. “An Electric Energy Consumer Characterization Framework Based on Data Mining Techniques”, *IEEE Transactions On Power Systems*, vol. 20, no. 2, Maio de 2005.