

Análise de Perfis de Consumo Residencial para Implementação da Tarifa Branca

Gustavo Vinicius Santana¹³ André Nunes de Souza¹³ Danilo Sinkiti
Gastaldello²³ Pedro da Costa Junior¹³ André Gifalli¹³ Marco Akio Ikeshoji¹³

Faculdade de Engenharia, Univ. Estadual Paulista - UNESP, Bauru - SP, Brasil¹
Centro Universitário Sagrado Coração - UNISAGRADO, Bauru - SP, Brasil²
Laboratório de Sistemas de Potência e Técnicas Inteligentes – LSISPOTI, Bauru –
SP, Brasil³

gu.santi@gmail.com¹ andre.souza@unesp.br² danilo.gastaldello@usp.br³
costa.jr@unesp.br⁴ andregifalli@gmail.com⁵ ikeshoji@uol.com.br⁶

Abstract: This paper consists of an analytical study of residential load curves to verify the feasibility of adopting the white tariff, which considers the consumption records at fixed time intervals. The idea is to obtain the consumption profiles that would benefit most from adhering to this tariff alternative in the current Brazilian context. The objective is to verify, from the analysis of the characteristic curves of various consumption profiles, whether adherence to the white tariff would bring benefits to users. Ideally, consumers should not radically alter their consumption habits to reduce their electricity costs. On the other hand, the adequate alignment of consumption profiles with tariffs also allows the utility to make better use of installed capacity. The proposed methodology then consists of evaluating synthesized load curves based on statistical data and the definition of consumption schedules pre-established by the concessionaire for the white tariff. Here, the option to adhere to the white rate considers the economic and comfort aspects of the user. In summary, this study proposes a methodology to assess the consumption profile to verify the viability of its adherence to the white tariff, considering little or no change in the use of appliances.

Resumo: Este artigo consiste em um estudo analítico de curvas de carga residenciais, para verificar a viabilidade da adoção da tarifa branca, a qual considera os registros de consumo em intervalos fixos no tempo. A ideia é obter os perfis de consumo que mais se beneficiariam com a adesão a essa alternativa tarifária no atual contexto brasileiro. O objetivo é verificar, a partir da análise das curvas, características de vários perfis de consumo, se a adesão à tarifa branca traria benefícios aos usuários. Idealmente, os consumidores não deveriam alterar radicalmente seus hábitos de consumo para reduzir seus custos com energia elétrica. Por outro lado, o alinhamento mais adequado de perfis de consumo com tarifas também propicia melhor aproveitamento da capacidade instalada por parte da concessionária. A metodologia proposta consiste então em avaliar curvas de carga sintetizadas a partir de dados estatísticos e da definição de cronogramas de consumo pré-estabelecidos pela concessionária para a tarifa branca. Aqui, a opção de aderir à tarifa branca considera os aspectos econômicos e de conforto do usuário. Em resumo, este estudo propõe uma metodologia para avaliar o perfil de consumo para verificar a viabilidade da adesão à tarifa branca, considerando pouca ou nenhuma alteração no uso de eletrodomésticos.

Keywords: : *Clustering; Residential Consumer; Load Curves; White Rate; Consumption Habits.*

Palavras-chave: *Clusterização; Consumidor Residencial; Curvas de Cargas; Tarifa Branca; Hábitos de Consumo;*

1. INTRODUÇÃO

Atualmente, o aumento da demanda associado à saturação na disponibilidade das fontes primárias usuais, tem levado as empresas de energia de energia elétrica investir cada vez mais em estudos e métodos alternativos, com o intuito de garantir a disponibilidade de energia principalmente nos horários de maior carregamento do sistema. Além da opção por fontes de energia renováveis, uma forma de incentivar os consumidores deste seguimento é a adesão de um modelo tarifário mais vantajoso para o consumidor.

No Brasil, a tarifação é classificada em dois grupos: grupo A e grupo B. No grupo A estão os grandes consumidores industriais, que possuem modelos tarifários diferenciados, que levam em consideração o consumo, a contratação de demanda, ultrapassagem e sazonalidades (como o sistema de bandeiras tarifárias que sinaliza o custo real da energia gerada), e horários de ponta, fora de ponta e intermediário, (Baptista, 2016). Para os consumidores no grupo B existe a alternativa da tarifa branca, que segundo a Resolução Normativa nº 414 (ANEEL, 2010), é uma modalidade aplicada às unidades consumidoras do grupo B, exceto para o subgrupo B4 e para as subclasses baixa renda do

subgrupo B1, sendo caracterizada por tarifas diferenciadas de consumo de energia elétrica de acordo com o horário de utilização. Conforme apontam estudos citados em (Di Santo et al., 2015), esta estratégia de precificação é de fácil utilização e apresenta um impacto moderado na conta de energia, reduzindo até 5% na demanda de pico em uma unidade consumidora.

A diferença entre a tarifa branca e a convencional são suas sinalizações tarifárias, que alteram-se de acordo com o horário da utilização de energia. Os períodos de ponta, intermediário e fora de ponta são homologados pela (ANEEL, 2019) nas revisões tarifárias periódicas de cada distribuidora, que ocorrem em média a cada cinco anos. As distribuidoras do Brasil disponibilizaram essa opção para os consumidores a partir do ano de 2018 que se enquadravam na média anual de consumo mensal, conforme apresentado na Tab.1.

Tabela 1. Cronograma de entrada da Tarifa Branca

Média Anual de Consumo Mensal	Início
500kWh/Mês	janeiro / 2018
250 kWh / Mês	janeiro / 2019
Demais Unidades Consumidoras	janeiro / 2020

^aResolução Normativa nº 414/2010 ANEEL (2010)

No primeiro ano de vigência da tarifa branca, quase quatro milhões de unidades consumidoras poderiam aderir à tarifa branca, porém apenas pouco mais de três mil adotaram a tarifação. Segundo (ANEEL, 2019) em 2019 a opção pela tarifa branca esteve disponível para unidades consumidoras com média anual de consumo mensal superior a 250 kWh/h, sendo cerca de dezesseis milhões de unidades consumidoras com possibilidade de adesão. Embora ainda não exista uma estimativa do número atual de unidades aptas, em 2020 espera-se um aumento da adesão, visto que, não haverá limite de consumo mensal para solicitação da tarifa.

Estudos com o foco em novos métodos de otimização e controle de cargas com relação a demanda de energia elétrica, são normalmente elaborados através de simulações para previsão de consumo. No entanto, para que seja possível a realização de estudos semelhantes, os pesquisadores frequentemente confrontam-se com a falta acesso a dados históricos de carregamento de sistemas reais como indicado em (Broden et al., 2018).

Para (Broden et al., 2018) a utilização e aplicação de algoritmos de classificação e *clustering* (agrupamento) em banco de dados de carga do consumidor com o objetivo de identificar formas ou padrões de carga são cada vez mais frequentes nas pesquisas. O agrupamento é definido como o conjunto de objetos semelhantes. Um determinado grupo de perfis de carga é agrupado em um número de *clusters* de tal forma que os perfis dentro do mesmo *cluster*, sejam semelhantes entre si. Ao mesmo tempo os perfis de carga que são atribuídos à diferentes *clusters* são tão diferentes quanto possível. Neste caso foi utilizado o método heurístico o algoritmo *k-means* (Macqueen, 2019), em que cada *cluster* é representado pelo valor médio dos objetos no *cluster* (Warren Liao, 2005).

Assim, este trabalho propõe a análise de dados de curvas de cargas residenciais sintéticas, que foram propostas e validadas por (Gastaldello, 2017), através de processo de clusterização e utilizando pacotes de análise do (Macqueen, 2019) para avaliar e discutir os agrupamentos realizados, com a proposta de identificação de perfis que podem aderir ou não ao modelo tarifário.

2. FUNDAMENTAÇÃO TEÓRICA

Optou-se, nesta pesquisa, pelo método de agrupamento dos dados *Kmeans*. Esse método consiste em um algoritmo que busca encontrar semelhanças entre dados não rotulados de um conjunto de amostras e agrupá-los em *K* diferentes grupos. Segundo (Huang, 1998), o *Kmeans* é um algoritmo que funciona somente com dados numéricos, visto que as variáveis envolvidas são avaliadas por medidas escalares e o agrupamento é feito com base na minimização do custo por meio da mudança média dos *K* centroides dos *clusters* envolvidos. O algoritmo distribui aleatoriamente os *K* grupos no espaço de atributos dos dados e os utiliza como ponto de partida para realizar *n* interações de correção e otimização das posições dos centroides por meio da minimização da soma do erro quadrático entre o centroide e cada amostra. A interrupção das interações ocorre quando o número máximo de interações *n* é alcançado ou quando as posições dos centroides não se alteram de forma significativa entre uma interação e a seguinte (Fränti and Sieranoja, 2019).

O *K-Means Clustering* é um método de otimização localizado que é sensível à seleção da posição inicial a partir do ponto médio do *cluster*. Por isso, adotar a posição inicial no ponto médio de um *cluster* incorreto resultará erros intoleráveis na determinação dos *clusters*. A ferramenta *K-means* não define o número de *cluster* ideal, devido o fato de não obter prontamente.

Conforme (Selim and Ismail, 1984) é provado de forma generalizada a convergência do algoritmo *Kmeans*, sendo investigado e proposto meios para se obter o melhor ponto ou local das soluções ou *clusters*. Também são apresentadas as notações e formulações matemáticas que envolvem os problemas para a generalização, bem como são profundamente investigadas. Para definição do valor adequado de *K* no algoritmo *Kmeans*, segundo (Syakur et al., 2018) e (Setiawan et al., 2018), pode-se utilizar o método *Elbow* para fazer o agrupamento dos dados de acordo com os atributos definidos. Resumidamente, este método usa o percentual da variância dos dados em função dos números de *clusters* *K*, ou seja, o algoritmo testa diferentes valores de *K* e o valor ideal de *K* é obtido quando não há mais aumento expressivo da variância.

A relação entre o aumento de *cluster* e a variância é uma curva decrescente e o local de melhor escolha de *K* é próxima do "cotovelo" (*Elbow*), formado nesta curva. Assim, o melhor número *K* de *cluster* pode ser encontrado através de (1), onde *d(i)* é a distância entre a reta formada pelos pontos do extremos de amostras avaliadas e o ponto correspondente ao *cluster* *K* avaliado. Será eleito o melhor *cluster* aquele que possuir a maior distância *d(i)*, pois este terá a maior variância.

$$d_{(i)} = \frac{|(y_1 - y_0) \cdot x_{(i)} - (x_1 - x_0) y_{(i)} + x_1 y_0 - y_1 x_0|}{\left((y_1 - y_0)^2 + (x_1 - x_0)^2\right)^{1/2}} \quad (1)$$

onde:

- $d_{(i)}$ - i -ésima distância entre a reta e os pontos de análise;
- x_0, x_1, y_0 e y_1 - abscissas e ordenadas dos pontos da reta; e
- $x_{(i)}$ e $y_{(i)}$ - i -ésimo abscissa e ordenada do ponto do *cluster* K avaliado.

Conhecendo-se o K ideal é possível realizar o agrupamento das curvas de carga utilizando o algoritmo *Kmeans* do Matlab®.

3. METODOLOGIA PARA DEFINIÇÃO DE PERFS DE CONSUMIDORES

Para este estudo criou-se um banco de dados inicial composto por 300 curvas de carga sintéticas de consumidores residenciais, com médias de consumo diário. Totalizando noventa e seis pontos cada curva, que equivalem à um tempo médio de quinze em quinze minutos de um dia. O algoritmo empregado para gerar esses dados de medição é proposto por (Gastaldello, 2017) e leva em consideração aspectos familiares, socioeconômicos e culturais, para gerar curvas de cargas de maneira pseudo-aleatória para análises de mudança de hábitos e variação de consumo conforme mudança de características.

O banco de dados inicial foi separado em três grupos distintos obedecendo o critério tarifário da classe B, comparando a tarifa convencional com a tarifa branca proposta por uma distribuidora localizada no interior de São Paulo, conforme a Tab.2. Os três grupos são: convencional, tarifa branca e limítrofe, onde no convencional estão as curvas que devem manter a modalidade tarifaria do grupo convencional, o grupo tarifa branca devem migrar para este modelo tarifário, e o grupo limítrofe possuem curvas que estão entre os 5% de chance de migrar para tarifa branca ou ficar na convencional. Este grupo foi criado para avaliar o perfil do grupo que com pequenas mudanças de hábito possam optar pela migração para tarifa branca ou então ir para a convencional.

Tabela 2. Comparação da Tarifa Convencional com a Branca

Distribuidora de SP	
Tarifa convencional (valor por kWh)	R\$ 0,548
Intermediário	R\$ 0,618
Ponta	R\$ 0,957

^aANEEL [2010]

Para cada um dos três grupos criados foi realizado o estudo de agrupamento (*kmeans*) com a função de distância padrão (euclidiana ao quadrado), com intuito de avaliar os perfis criados em cada um dos grupos. Para definir o melhor número K de *cluster* de cada grupo foi utilizado o método *Elbow*, avaliando a somatória dos erros quadráticos de cada ponto em relação o centroide, variando entre 1 a 20 *clusters*. Com o número K definido foi realizada a divisão dos grupos em K *clusters* e feita a análise qualitativa do

resultado alcançado. A Fig.1 apresenta um fluxograma da proposta metodológica adotada. Os cálculos de distância, os agrupamentos e as análises de dados utilizados neste artigo foram realizados no Matlab®, os gráficos foram gerados com auxílio de linguagem de programação *Python* através da biblioteca *matplotlib*, e os resultados são apresentados na Figura1.




Figura 1. Fluxograma da metodologia.

4. RESULTADOS E DISCUSSÃO

O banco de dados inicial foi avaliado de acordo com a tarifação da classe B, comparando o valor previsto no modelo convencional versus modelo de tarifa branca, e dividido em três grupos:

- Grupo Convencional: total de 144 curvas, representando 48% dos dados;
- Grupo da tarifa branca: total de 57 curvas, representando 19% dos dados; e
- Grupo Limítrofe: total de 99 curvas, representando 33% dos dados.

Para cada grupo foi gerado um gráfico do método *Elbow*, o que possibilitou a definição de um número de *clusters* ideal para cada grupo. Com a somatória dos erros quadráticos e a equação de distância entre os pontos e a reta, foi possível determinar o número ideal de *cluster* de cada grupo. Para os três casos o valor encontrado foi $k_{conv} = k_{branca} = k_{limítrofe} = 5$. Com o K definido, foi realizada a clusterização de cada grupo. Os gráficos da Fig.2 apresentam os *clusters* formados em cada grupo, conforme Tab.3. Observa-se nas curvas que o "cotovelo" está entre os *cluster* 2 a 6, com o cálculo da distância de cada *cluster*, ou seja, a reta determina o valor de $k = 5$.

Tabela 3. Distribuição dos *Clusters* por Grupo

	Convencional		Tarifa Branca		Limítrofe	
	qtde.	%	qtde.	%	qtde.	%
cluster 1	7	5	11	19	32	32
cluster 2	23	16	6	11	5	5
cluster 3	6	4	23	40	19	19
cluster 4	86	60	2	4	41	41
cluster 5	22	15	15	26	2	2
Total	144	100	57	100	99	100

^a Elaborado pelo autor




Figura 2. Método *elbow* (a) Convencional (b) Branca (c) limitrofe.

Posteriormente, ilustra-se na Fig.3, a clusterização do grupo convencional, bem como os centroides de cada *cluster*. Conforme esperado os centroides dos *clusters* do grupo convencional apresentam picos de consumo no horário de ponta da modalidade tarifária branca estudada (entre 18-21h, pontos 72 a 84), inviabilizando a adesão.




Figura 3. Curvas de cargas para tarifa convencional (linha fina) e Centroide (linha grossa), obtida após o método *Kmeans* para os 5 tipos de agrupamentos.

Ao avaliar cada um dos *clusters*, percebe-se que uma das diferenças está atrelada a potência consumida, onde o *cluster 1* possui picos próximos a 20 kW, o *cluster 4* não chega aos 10 kW, e os demais estão próximos a 14 kW de pico.

Outra característica que difere os *clusters* está relacionado ao consumo de madrugada, os *clusters 1, 2 e 5* se destacam mais neste período, podendo significar o uso de climatizadores de ambiente. Estes perfis traçados representam bem o consumo da região Sudeste, apresentando um consumo maior no período noturno, caracterizando bastante o trabalhador diurno, ou seja, o consumidor que fica fora durante o dia.

A Tab.4 apresenta a composição percentual de cada uma dos centroides do grupo convencional, nos horários de ponta, fora de ponta e intermediário, e também a relação entre o custo convencional e o custo de tarifa branca.

Com o auxílio da Tab.4, nota-se que os centroides do grupo convencional são bastante semelhantes, em consonância com as imagens discutidas anteriormente. A proporção de consumo no horário de ponta fica entre 28 e 36%, que é

suficiente para não valer a pena a adesão do novo modelo tarifário, visto que o custo no horário de ponta é mais que o dobro do horário ponta. A Tab.4, permite afirmar o quanto cada *cluster* está próximo ou afastado do grupo limitrofe, através da relação entre custo convencional e custo tarifa branca. Quanto menor o valor, mais distante este *cluster* está da zona limitrofe. Assim, é possível concluir que o *cluster 3* é o mais diferenciado, ou seja, só ocorreria com muitas mudanças de hábito. A Fig.4 é apresentada a clusterização do grupo da tarifa branca.

Tabela 4. Composição percentual de horários - grupo convencional

	Fora %	Intermediário %	Ponta %	Conv / Branca
C1	52,59	16,88	30,53	0,8816
C2	53,95	15,53	30,52	0,8854
C3	44,05	19,83	36,12	0,8344
C4	49,94	13,43	36,63	0,8466
C5	61,08	10,11	28,81	0,9139




Figura 4. Média dos *clusters* grupo convencional.

Observa-se nos *clusters* uma variação de potência máxima, assim como no grupo convencional. No entanto, os perfis de cada *cluster* são distintos entre si. O *cluster 1*, por exemplo, possui um alto consumo de madrugada e um pico menor no café da manhã, e no horário de ponta um consumo intermediário. Já no *cluster 2* tem um consumo maior durante a manhã e depois do jantar, o *cluster 3* tem um perfil constante durante todo o dia, com picos de madrugada, enquanto que o *cluster 4* tem um consumo maior de tarde e um pico no horário de ponta. E por fim, o *cluster 5* com consumo de manhã e de tarde, bastante significativo. A Tab.5 apresenta a composição percentual de cada uma dos centroides do grupo da tarifa branca.

Tabela 5. Composição percentual de horários - grupo da tarifa branca

	Fora %	Intermediário %	Ponta %	Conv / Branca
C1	80,69	7,03	12,28	1,0824
C2	81,67	6,77	11,56	1,0916
C3	82,74	6,5	10,76	1,102
C4	75,23	14,92	9,85	1,0778
C5	83,17	4,83	12	1,0946

Visualmente as curvas de carga dos *clusters* possuem características distintas, no entanto, as tabelas 4, 5, e 6 fornecem a informação de um padrão horário de ponta, variando entre 10 e 12 %, já no horário intermediário a variação é maior, de aproximadamente 5 a 15%. Neste

sentido é possível determinar qual perfil é melhor para a adesão da tarifa branca, que neste caso é o *cluster 3* que possui a maior relação entre custo convencional e o custo de tarifa branca com 1,102, ou seja, o convencional é 10,2% mais caro que a branca. Já o pior é o *cluster 4* que aceita a mudança com uma margem de 7,78%, e que uma mudança de hábito pode fazer o modelo tarifário branca não valer mais a pena.

A Fig.5 apresenta a clusterização do grupo limítrofe.




Figura 5. Média dos *clusters* grupo limítrofe.

Este grupo também possui perfis bem distintos, seja por valor de consumo, quanto ao hábito de uso. No entanto, em todos os *clusters* é possível identificar um consumo representativo no horário de ponta, ou seja, quando Composição Percentual e Grupo Limítrofe, o maior pico não está no horário de pico, este é o segundo maior patamar, esta característica é importante para distinguir este grupo.

A Tab.6 apresenta a composição percentual de cada uma dos centroides do grupo limítrofe.

Tabela 6. Composição percentual de horários - grupo limítrofe

	Fora %	Intermediário %	Ponta %	Conv / Branca
C1	70,31	9,89	19,8	0,9936
C2	72,08	9,82	18,1	1,0104
C3	72,77	8,4	18,83	1,0081
C4	71,39	8,34	20,27	0,9944
C5	66,15	15	18,85	0,9852

Assim como no grupo da tarifa branca, no grupo limítrofe, apesar das curvas apresentarem comportamentos diferentes, a Tab.6 nos mostra um certo padrão de distribuição percentual, no horário de ponta por exemplo, a variação é de 18 a 20%. A Tab.6 nos permite concluir que os consumidores reunidos nos *clusters 1, 4, e 5* estariam aptos a aderir à tarifa branca com uma pequena mudança de hábito. Analisando os *clusters 1 e 2* item a item, observa-se que a variação está no percentual de ponta e fora de ponta, assim, se houver um deslocamento de carga entre estes períodos, por exemplo, um banho ser tomado depois das 22h ou antes das 17h, poderiam fazer este consumidor tornar-se adepto a adesão da tarifa branca. A relação de custo convencional e custo tarifa branca, neste caso, mostra que o *cluster 4* é mais adepto a mudar da tarifa convencional para branca, com uma pequena mudança de hábito. Da mesma forma, para os consumidores do *cluster 3*, valeria a pena uma pequena mudança de hábito para retornar da tarifa branca para a tarifa convencional.

Por fim, a Fig.6 apresenta a média dos *clusters* de cada um dos três grupos (convencional, branca e limítrofe) e a respectiva faixa do modelo tarifário de tarifa branca.




Figura 6. Média dos *clusters* e as faixas do modelo de tarifa branca.

Fica nítido que o perfil convencional (azul) é caracterizado pelo maior consumo na ponta e o perfil branca (amarela) com consumo maior durante o dia e a madrugada, já o perfil limítrofe está entre estes dois perfis.

CONCLUSÕES

Analisando o cenário energético atual e o o consumo de energia elétrica residencial, as empresas de energia elétrica estão propondo soluções que contribuam para atendimento ao crescimento da demanda de energia. Assim é de extrema importância a exploração e elaboração de novos métodos que visão contribuir com este cenário. No Brasil umas das frentes que as empresas de energia elétrica busca para melhorar o problema de maior carregamento do sistema, é através do sistema tarifário, propondo medidas que causam impacto econômico para os consumidores.

Sendo assim, neste artigo foi realizado um estudo analítico das curvas de cargas sintéticas, de vários perfis de consumidores residenciais, e posteriormente separado em 3 grupos distintos, seguindo os critérios tarifário da classe B, comparando a tarifa branca e convencional. Para cada grupo criado, foi aplicado o estudo de agrupamento *K-means*, e em seguida o método *elbow* para definição do número ideal de clusters para cada grupo. Assim foi possível destacar as medias dos clusters.

Como resultado após simulações realizadas neste estudo, foi possível destacar-se que o perfil de consumidores convencional se caracteriza pelo maior consumo no horário de ponta e o perfil branca com um consumo maior durante o dia e madrugada, e por último o perfil limítrofe, ficando

entre os dois perfis. Neste sentido com um pequeno deslocamento de carga o consumidor poderá ser apto a migrar para a tarifa branca.

Para trabalhos futuros recomenda-se a aplicação deste método de agrupamento com novos dados reais de consumidores residenciais, visto que a análise otimizada de um conjunto elevado de dados de curvas de cargas, se mostrou eficaz neste artigo.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

REFERÊNCIAS

- ANEEL (2010). AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL RESOLUÇÃO NORMATIVA Nº 414, DE 9 DE SETEMBRO DE 2010. URL <http://www2.aneel.gov.br/cedoc/bren2010414.pdf>.
- ANEEL (2019). Tarifa branca é nova opção para quem tem consumo acima de 250 KWh/mês - Sala de Imprensa - ANEEL. URL https://www.aneel.gov.br/web/guest/sala-de-imprensa-exibicao-2/-/asset_publisher/zXQREz8EV1Z6/content/id/17820220.
- Baptista, D.F. (2016). Estrutura da tarifa branca de Energia Elétrica no Brasil : Análise crítica e proposição metodológica. 129.
- Broden, D.A., Paridari, K., and Nordstrom, L. (2018). Matlab applications to generate synthetic electricity load profiles of office buildings and detached houses. *2017 IEEE Innovative Smart Grid Technologies - Asia: Smart Grid for Smart Community, ISGT-Asia 2017*, 1–6. doi:10.1109/ISGT-Asia.2017.8378371.
- Di Santo, K.G., Kanashiro, E., Di Santo, S.G., and Saidel, M.A. (2015). A review on smart grids and experiences in Brazil. *Renewable and Sustainable Energy Reviews*, 52, 1072–1082. doi:10.1016/j.rser.2015.07.182.
- Fränti, P. and Sieranoja, S. (2019). How much can k-means be improved by using better initialization and repeats? *Pattern Recognition*, 93, 95–112. doi:10.1016/j.patcog.2019.04.014.
- Gastaldello, D.S. (2017). Desenvolvimento de metodologia para revisão da demanda de energia elétrica residencial considerando aspectos socioeconômicos e ferramentas computacionais inteligentes. URL <https://kopernio.com/viewer?doi=10.11606/T.3.2017.tde-04082017-151342&rout=2>.
- Huang, Z. (1998). Extensions to the k-Means Algorithm for Clustering Large Data Sets with Categorical Values. Technical report.
- Macqueen, J. (2019). SOME METHODS FOR CLASSIFICATION AND ANALYSIS OF MULTIVARIATE OBSERVATIONS.
- Selim, S.Z. and Ismail, M.A. (1984). K-Means-Type Algorithms: A Generalized Convergence Theorem and Characterization of Local Optimality. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-6(1), 81–87. doi:10.1109/TPAMI.1984.4767478.
- Setiawan, A., Susanto, B., Mahatma -, T., Latipa Sari, H., Suranti, D., Natalia Zulita, L., Syakur, M.A., Khotimah, B.K., S Rochman, E.M., and Satoto, B.D. (2018). Integration K-Means Clustering Method and Elbow Method For Identification of The Best Customer Profile Cluster Related content Inflation data clustering of some cities in Indonesia IMPLEMENTATION OF K-MEANS CLUSTERING METHOD FOR ELECTRONIC LEARNING MODEL Integration K-Means Clustering Method and Elbow Method For Identification of The Best Customer Profile Cluster. doi:10.1088/1757-899X/336/1/012017.
- Syakur, M.A., Khotimah, B.K., Rochman, E.M., and Satoto, B.D. (2018). Integration K-Means Clustering Method and Elbow Method for Identification of the Best Customer Profile Cluster. In *IOP Conference Series: Materials Science and Engineering*, volume 336. Institute of Physics Publishing. doi:10.1088/1757-899X/336/1/012017.
- Warren Liao, T. (2005). Clustering of time series data - A survey. *Pattern Recognition*, 38(11), 1857–1874. doi:10.1016/j.patcog.2005.01.025.