

Análise de Parâmetros para Desagregação de Sinais de Consumo de Energia Elétrica

Pierre V. Dantas¹, Kenny V. dos Santos¹, Luiz E. S. e Silva¹, Celso B. Carvalho¹, Waldir S. S. Júnior¹
¹Universidade Federal do Amazonas (UFAM), Manaus-AM

Resumo— Neste artigo, abordamos o problema de desagregação de energia que pode ser tratado através de técnicas por dicionários onde sintetizamos as características mais representativas dos sinais envolvidos para realizar a desagregação. Em nossa proposta, podemos destacar duas contribuições. Na primeira, modificamos o algoritmo *steady-state identification* para lidar com sinais de dimensões diferentes e, em seguida, realizamos uma análise de parâmetros que influenciam na formação dos dicionários e por consequência, produzem diferentes desempenhos de desagregação. Os experimentos foram realizados utilizando-se a base de dados Reference Energy Disaggregation Data Set (REDD). Os resultados demonstram que a proposta produz bom desempenho de desagregação.

Palavras-Chave— desagregação, dicionários, análise de parâmetros.

Abstract— In this article, we address the problem of energy disaggregation that can be handled through dictionaries techniques where we synthesize the most representative characteristics of the signals involved to carry out the disaggregation. In our proposal, we can highlight two contributions. In the first one, we modified the *steady-state identification* algorithm to handle signals of different dimensions and then performed an analysis of parameters that influence the formation of the dictionaries and, consequently, produce different disaggregation performances. The experiments were carried out using the Reference Energy Disaggregation Data Set (REDD) database. The results show that the proposal produces good disaggregation performance.

Keywords— disaggregation, dictionaries, parameter analysis.

I. INTRODUÇÃO

As redes elétricas inteligentes (*smart grids*) vêm recebendo atenção pelas pesquisas realizadas em sistemas elétricos de potência de transmissão, distribuição e consumo alinhadas às subáreas de telecomunicações, processamento de sinais e reconhecimento de padrões [1], [2]. Por exemplo, a identificação do consumo individual de aparelhos domésticos em uma residência é possível utilizando conceitos da análise do sinal do consumo de energia elétrica no domínio do tempo ou da frequência, e ao final, estimando o aparelho por intermédio de modelos pré-definidos, este procedimento é denominado por desagregação de energia.

Pierre V. Dantas, Celso B. Carvalho, Waldir S. S. Júnior, Pós-graduação em Engenharia Elétrica, Universidade Federal do Amazonas (UFAM) Manaus-AM, Brasil, Kenny V. dos Santos, Departamento de Petróleo e Gás, Universidade Federal do Amazonas (UFAM) Manaus-AM, Brasil, Luiz E. S. e Silva, Departamento de Eletricidade, Universidade Federal do Amazonas (UFAM) Manaus-AM, Brasil. E-mails: pierre.dantas@gmail.com, {kennyvinente, ccarvalho_, waldirjr, eduardosales}@ufam.edu.br. Este trabalho foi parcialmente financiado pela FAPEAM.

Na análise da desagregação do consumo elétrico identificamos vantagens para o proprietário e para a concessionária de energia. Do ponto de vista do consumidor, a informação de consumo dos dispositivos individuais tem maior importância quando comparado ao consumo de energia elétrica total [3], pois permite a utilização da energia elétrica de forma mais eficiente gerando redução dos gastos com energia elétrica. Por fim, para a concessionária, a desagregação promove a melhoria do gerenciamento dos sistemas de geração e distribuição, permitindo um planejamento mais eficiente.

A desagregação de sinais pode ser realizada através da análise do consumo de energia no domínio do tempo, domínio da frequência, transformada *Wavelet* [4], redes neurais, representação esparsa ou modelos ocultos de Markov [5]. A extração do sinal a ser desagregado pode ser realizado utilizando técnicas intrusivas e não intrusivas. A primeira técnica utiliza vídeos e gravações para realizar a identificação do tipo do equipamento. Por último, as técnicas não intrusivas dispensam tais ferramentas e utilizam medidores no quadro de distribuição para adquirir os sinais envolvidos no processo de desagregação, em geral, corrente e tensão [6].

Neste artigo, propomos modificar o método *steady-state identification* (SSI) [6], [7] para contemplar estados estacionários com dimensões variáveis e fixas permitindo uma simplificação do cálculo da dissimilaridade entre estados estacionários. Na sequência, realizamos uma análise de 4 (quatro) parâmetros que influenciam na formação dos dicionários e por consequência, produzem diferentes desempenhos de desagregação. Os parâmetros investigados são analisados pelo procedimento de validação cruzada com conjuntos de treinamento, validação e teste. Os experimentos são realizados utilizando a base de dados REDD [8]. Por fim, o procedimento proposto é comparado à diferentes métodos para desagregação e os resultados demonstram que o método proposto possui desempenho competitivo, sendo que, em alguns casos, supera o desempenho dos demais métodos comparados.

O restante do artigo está organizado da seguinte forma. Na próxima seção é feita uma fundamentação para monitoramento não intrusivo em sinais de energia elétrica. O sistema proposto é mostrado na Seção III, na qual é enfatizada a extração das assinaturas e dos dicionários de consumo total e individual dos dispositivos residenciais, metodologia para identificação de eventos e a desagregação do sinal. Na Seção IV, procedimentos experimentais são apresentados através dos parâmetros que influenciam no desempenho do sistema de desagregação, da

base de dados, métricas utilizadas e o resultados obtidos. Por fim, o artigo é concluído na Seção V.

II. FUNDAMENTOS PARA MONITORAMENTO NÃO INTRUSIVO DE SINAIS DE CONSUMO DE ENERGIA

Nesta seção, apresentaremos os procedimentos para realizar a desagregação de um sinal de consumo de energia elétrica $e(t)$. Uma abordagem pode ser feita considerando que adquirimos este sinal a uma frequência constante $f = 1/T$, obtendo o sinal amostrado $e[\mathbf{n}]$. Assim, ao adquirirmos N amostras do sinal, podemos representá-lo pela sequência:

$$\mathbf{e}[\mathbf{n}] = [e_1, e_2, \dots, e_N] \quad (1)$$

O sinal $e[\mathbf{n}]$ é uma combinação linear dos sinais de consumo de energia elétrica $e_i[\mathbf{n}]$ de L dispositivos, com $i = \{1, 2, \dots, L\}$, e se relacionam da seguinte maneira:

$$\mathbf{e}[\mathbf{n}] = \sum_{i=1}^L e_i[\mathbf{n}] \quad (2)$$

Combinando as Equações (1) e (2) caracterizamos o problema da desagregação de um sinal de consumo de energia. Assim, é necessário utilizarmos alguma abordagem para encontrar a relação que estas equações implicam. Uma possibilidade é utilizar um processo que consiste em duas etapas. Na primeira, é necessário adquirir sincronizadamente os sinais de consumo de energia total $e[\mathbf{n}]$ e dos dispositivos $e_i[\mathbf{n}]$, com $i = \{1, 2, \dots, L\}$. A seguir, detectamos os estados de operação destes sinais e os agrupamos em conjuntos organizados denominados *dicionários* [7]. Para o sinal $e[\mathbf{n}]$, elaboramos um dicionário \mathbf{b} e, para os sinais $e_i[\mathbf{n}]$, elaboramos dicionários \mathbf{b}_i [9]. Observe que a dimensão dos dicionários depende da quantidade de estados de operação detectados em cada sinal. Na segunda etapa, conhecendo apenas $e[\mathbf{n}]$, buscamos assinalar um elemento de cada dicionário \mathbf{b}_i que corresponda ao consumo do dispositivo i . Em outras palavras, procuramos uma combinação de um estado operacional de cada dicionário \mathbf{b}_i , com $i = \{1, 2, \dots, L\}$ que forneça uma estimativa $\hat{e}[\mathbf{n}]$ de $e[\mathbf{n}]$, para cada \mathbf{n} . Matematicamente, representamos este cenário por:

$$\begin{cases} \hat{e}[\mathbf{n}] = \sum_{i=1}^L \hat{e}_i[\mathbf{n}] \\ \hat{e}_i[\mathbf{n}] = \mathbf{c}_i \mathbf{b}_i^\top, \quad \forall i = \{1, 2, \dots, L\} \end{cases} \quad (3)$$

Podemos usar algumas metodologias para calcularmos a acurácia (desempenho) da desagregação e verificarmos a precisão das estimativas $\hat{e}[\mathbf{n}]$ [7]. Ilustramos este cenário na Figura 2.

A desagregação de um sinal de consumo de energia $e[\mathbf{n}]$ nos permite obter estimativas $\hat{e}_i[\mathbf{n}]$ do consumo de energia dos dispositivos $e_i[\mathbf{n}]$ também. Para isso, utilizamos conhecimento prévio, representado pelos dicionários, não sendo mais necessário adquirirmos as medições de consumo de energia de $e_i[\mathbf{n}]$. Ilustramos esta situação na Figura 2.

A solução $\mathbf{c} = \{\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_L\}$ da Equação (3) pode não ser única. Podemos encontrar diversas instâncias de \mathbf{c} que representem apropriadamente os consumos de energia dos dispositivos $e_i[\mathbf{n}]$. Para avaliarmos o desempenho das estimativas, precisaríamos conhecer os sinais $e_i[\mathbf{n}]$ e compará-los com as estimativas $\hat{e}_i[\mathbf{n}]$. Para aprimorar a desagregação, podemos aplicar premissas ou restrições ao processo, com o objetivo de apontar a obtenção de \mathbf{c} para as soluções mais prováveis na prática [10], [6], [9]. Isso requer conhecimento empírico sobre a natureza de um sinal de consumo de energia.

Podemos realizar a estimação mediante técnicas de otimização [5] e reconhecimento de padrões [7]. No primeiro caso, podemos usar algoritmos de otimização de funções como as de erro médio quadrático, distância euclidiana, similaridade de cosseno e programação linear inteira [11]. No segundo caso, podemos usar algoritmos de classificação *k-nearest neighbors* (KNN) [12], *multiclass adaboost*, *support vector machine* (SVM) [13] e *hidden Markov models* (HMMs) [14].

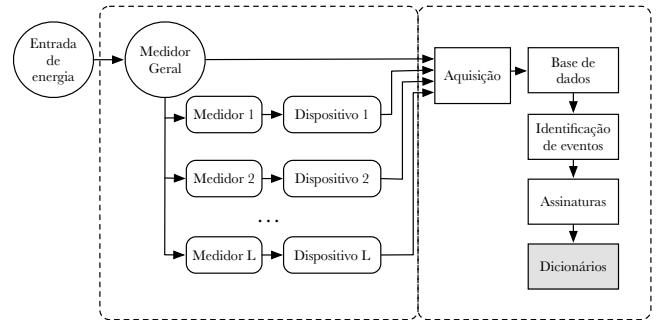


Fig. 1. Processo de extração de dicionários de sinal de consumo de energia.

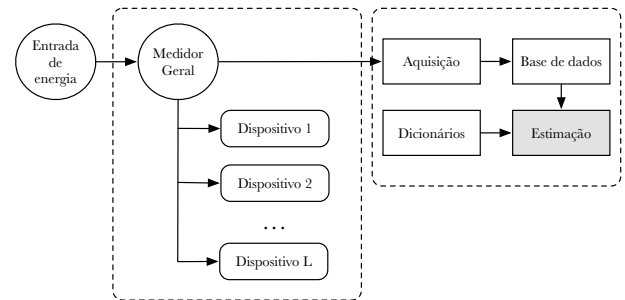


Fig. 2. Processo de desagregação de um sinal de consumo de energia.

III. PROCEDIMENTO PROPOSTO PARA MONITORAMENTO NÃO INTRUSIVO DE SINAIS DE CONSUMO DE ENERGIA

Nesta seção, apresentamos a metodologia utilizada para análise de parâmetros que influenciam na desagregação de um sinal de consumo de energia elétrica. Em síntese, a abordagem foi realizada em duas etapas: primeiramente, extraímos os dicionários do sinal de consumo total e o sinal de consumo dos dispositivos que compõem o sistema. Para isso, identificamos os estados estacionários dos sinais através de uma variação do método *steady-state identification* (SSI) [6], [7] que contempla

uma normalização e um redimensionamento dos sinais. Em seguida, obtemos os dicionários dos sinais e utilizamos o algoritmo *dissimilarity-based sparse subset selection* (DS3) [15] para esta finalidade.

A. Detecção de Eventos

Para detectarmos eventos nos sinais de energia, consideramos dois parâmetros, ε e s_{min} , que correspondem à amplitude máxima entre amostras de um estado estacionário e a quantidade mínima de amostras para estabelecer um estado estacionário, respectivamente, conforme ilustrado na Figura 3.

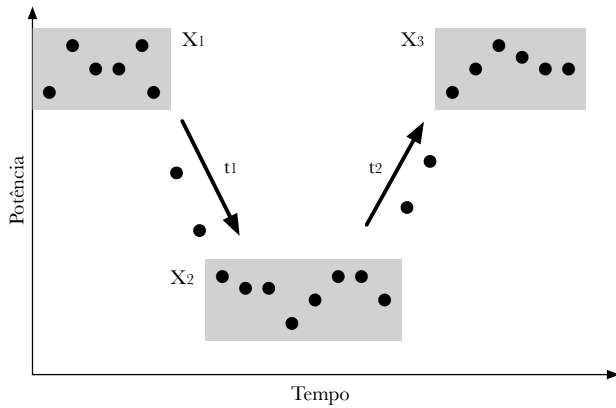


Fig. 3. Identificação de estados estacionários $\{X_1, X_2, X_3\}$ em um sinal de consumo de energia em função de $\varepsilon = 4$ e $s_{min} = 3$, com as transições $\{t_1, t_2\}$

No método *steady-state identification* (SSI), atribuímos a primeira amostra do sinal de consumo de energia a um estado estacionário e continuamos atribuindo as amostras subsequentes a este estado estacionário enquanto os parâmetros ε e s_{min} são atendidos, simultaneamente. Quando ε ou s_{min} não for mais atendido, consideramos o término de estado estacionário atual e iniciamos o procedimento novamente para um estado estacionário subsequente [6], [7]. Neste método, geralmente obtemos estados estacionários de dimensões diferentes e isso dificulta cálculos de similaridade entre eles.

A primeira contribuição desse trabalho foi a modificação do método SSI. Para isso, padronizamos os estados estacionários a uma mesma dimensão, usando o conceito de *powerlets* [9], originando o método *steady-state identification - similar dimension* (SSI-SD) que simplifica o cálculo da similaridade entre estados estacionários. Neste caso, definimos uma janela deslizante de tamanho equivalente a w amostras e a aplicamos ao sinal de consumo de energia. A cada passo de deslocamento da janela, analisamos se as amostras contidas atendem simultaneamente aos critérios de ε e s_{min} . As amostras são consideradas um estado estacionário se atendem aos critérios citados e, em caso negativo, são ignoradas.

Com este processo, obtemos estados estacionários de dimensões iguais e a extração dos dicionários por técnicas que usam métricas de similaridade entre conjuntos torna-se simples [9], [15].

B. Assinaturas e Dicionários

Uma assinatura de um sinal de consumo de energia elétrica $e[n]$ é interpretada como uma sequência de pelo menos dois estados estacionários consecutivos que ocorrem com frequência no sinal [6]. Em nossa proposta, representamos uma assinatura dos sinais de consumo de energia $e[n]$ e $e_i[n]$, por dois estados estacionários que ocorrem em sequência nestes sinais. Agrupamos as assinaturas de $e[n]$ e $e_i[n]$ nas matrizes \mathbf{S} e \mathbf{S}_i , com $i = \{1, 2, \dots, L\}$, respectivamente, onde cada linha corresponde a uma assinatura.

Para obtermos uma representação sintetizada das matrizes de assinaturas, ou seja, um dicionário, utilizamos um método de sintetização de conjuntos denominado *dissimilarity-based sparse subset selection* (DS3) [15] que tem a matriz normalizada de dissimilaridade \mathbf{Z} como entrada. Neste caso, como desejamos extrair dicionários das matrizes de assinaturas \mathbf{S} e \mathbf{S}_i , elaboramos inicialmente a *matriz de dissimilaridade* \mathbf{D} , da seguinte maneira:

$$\mathbf{D} = \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1m} \\ d_{21} & d_{22} & \cdots & d_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ d_{m1} & d_{m2} & \cdots & d_{mm} \end{bmatrix} \quad (4)$$

Na Equação (4), cada termo d_{ij} é calculado como a dissimilaridade entre a assinatura s_i e s_j da matriz \mathbf{S} , que contém m assinaturas, e é dado por:

$$d_{ij} = |s_i - s_j|, \quad \forall \{i, j\} \in \{1, 2, \dots, m\} \quad (5)$$

Por fim, elaboramos a *matriz de dissimilaridade normalizada* \mathbf{Z} , da seguinte forma:

$$\mathbf{Z} = \frac{1}{\max(\mathbf{D})} \mathbf{D} \quad (6)$$

Ao final deste processo, o algoritmo retorna elementos de \mathbf{S} e \mathbf{S}_i que são representativos do conjunto, ou seja, \mathbf{b} e \mathbf{b}_i , respectivamente. Assim, podemos processar a desagregação mais facilmente com o uso dos dicionários.

C. Desagregação do Sinal

A desagregação do sinal de consumo de energia elétrica $e[n]$ é realizada por dois procedimentos, conforme detalhamos a seguir. O primeiro, consiste em elaborarmos uma combinação dos elementos dos dicionários \mathbf{b}_i , com $i = \{1, 2, \dots, L\}$, gerando todas as possíveis soluções para a desagregação. A soma de cada combinação, corresponde a uma estimativa $\hat{e}[n]$. Observe que uma mesma estimativa pode ser formada por diferentes combinações de elementos de \mathbf{b}_i . O segundo procedimento consiste em tomarmos uma amostra de $e[n]$ e procurarmos a correspondência nos valores estimados na primeira etapa do procedimento, encontrando uma solução para a desagregação.

IV. PROCEDIMENTOS EXPERIMENTAIS

Nesta seção, apresentamos os experimentos realizados. Os procedimentos propostos na Seção III, foram utilizados considerando-se os cenários expostos nas Figuras 1 e 2. Consideramos o cenário da Figura 1 como um procedimento de *treinamento* e, o cenário da Figura 2 como um procedimento de *teste*, em um contexto de modelagem. Para a fase de treinamento, implementamos os procedimentos para detecção de eventos e assinaturas e construção do dicionário descrito nas Seções III-A e III-B. Para a fase de teste, implementamos o procedimento de desagregação dos sinais de energia descrito na Seção III-C. As implementações foram feitas utilizando-se a linguagem MATLAB e os algoritmos foram executados em *cluster* de computadores.

A. Parâmetros que Influenciam no Desempenho do Sistema de Desagregação

Neste artigo, investigamos a influência de 4 (quatro) parâmetros, sendo esta a segunda contribuição deste trabalho, conforme as variações especificadas abaixo, que modificam a desagregação: ε , s_{min} , α , λ . Os dois últimos parâmetros citados, são parâmetros de ajuste do algoritmo DS3 [15]. Ao modificar estes parâmetros, modificamos a extração dos dicionários. O total de combinações dos parâmetros foi igual a 864. A estratégia utilizada para investigar a influência dos parâmetros foi a validação cruzada [16] com *4-folds* com conjuntos de treinamento, validação e teste. Em síntese, estes parâmetros descrevem:

- ε : amplitude máxima entre amostras de um estado estacionário. Variação = $[3m]$ com $m = \{1, 2, \dots, 12\}$;
- s_{min} : quantidade mínima de amostras de um estado estacionário. Variação = $[2n+1]$ com $n = \{1, 2, \dots, 12\}$;
- λ : parâmetro de regularização do DS3 [15]. Variação = $[0.10, 0.05]$;
- α : parâmetro de correção do DS3 [15]. Variação = $[0.010, 0.005, 0.001]$.

B. Base de Dados

Para os procedimentos experimentais apresentados neste artigo, utilizamos uma base de dados pública de consumo de energia elétrica, o *Reference Energy Disaggregation Data Set* (REDD) [8] composta por medidas de consumo de energia elétrica de 10 residências e 268 cargas com período de duração de 119 dias. Em nossos experimentos, consideramos as medições para a residência número 2 (dois). Os métodos *Simple Mean* [9], FHMM [3] e *Powerlets* [9] utilizam a mesma base de dados e a mesma residência.

C. Métricas de Avaliação de Desempenho Utilizadas

As métricas de avaliação que usamos para avaliar o desempenho da desagregação foram:

- Acurácia: diferença entre o sinal de consumo de energia total $e[\mathbf{n}]$ e o somatório dos sinais de consumo de energia estimado $\hat{e}_i[\mathbf{n}]$ dos L dispositivos em um intervalo de

tempo $t = \{1, 2, \dots, T\}$ [3], [6], [7], dada pela Equação (7).

$$\text{Acurácia} = 1 - \frac{\sum_{t=1}^T \sum_{i=1}^L |e[\mathbf{n}] - \hat{e}_i[\mathbf{n}]|}{2 \sum_{t=1}^T \hat{e}[\mathbf{n}]} \quad (7)$$

- Erro médio quadrático (e): a diferença entre o sinal de consumo de energia medido de cada dispositivo $e_i[\mathbf{n}]$ e o estimado $\hat{e}_i[\mathbf{n}]$ [10], em um dado intervalo de tempo T , dada pela Equação (8).

$$e_i = \left[\frac{1}{T} \sum_{t=1}^T (e_i[\mathbf{n}] - \hat{e}_i[\mathbf{n}])^2 \right]^{\frac{1}{2}} \quad (8)$$

D. Resultados

Na Figura 4, apresentamos o gráfico com a acurácia obtida, segundo a Equação (7), em função das combinações dos parâmetros ε , s_{min} , α , λ considerados. Na acurácia, temos os resultados para treinamento, validação e teste. A ordenação é feita pela acurácia no treinamento. Perceba que podemos visualizar a variação do desempenho do sistema de acordo com a mudança da combinação dos parâmetros. A acurácia obtida, considerando os valores para validação, foi de 87,3%. Na Tabela I, apresentamos os valores para o erro médio quadrático por dispositivo (e_i), conforme Equação (8). Para os dispositivos (1), (3), (5) e (9), o erro é extremamente baixo, assim, nestes casos, o desempenho é considerado alto. Para os outros dispositivos o erro é elevado. Na Tabela II, apresentamos uma comparação com outros métodos. Para estes casos, a estratégia utilizada supera os métodos comparados. A diferença para o resultado mais próximo é de 8.3 pontos percentuais. Deste modo, podemos verificar que o método proposto é eficaz quando comparados a métodos equivalentes.

TABELA I

RESULTADOS PARA O ERRO MÉDIO QUADRÁTICO POR DISPOSITIVO (e_i).

Dispositivo	e_i (%)
(1) Dispositivos da cozinha	7.37
(2) Iluminação	37.77
(3) Fogão	8.09
(4) Microondas	19.21
(5) Lavadora de roupas	0.77
(6) Dispositivos da cozinha	37.54
(7) Geladeira	43.60
(8) Lava-louças	42.34
(9) Sem uso	3.82

TABELA II

COMPARAÇÃO ENTRE DIFERENTES MÉTODOS PARA DESAGREGAÇÃO.

Método	Acurácia (%)
<i>Simple Mean</i> [9]	39.00
FHMM [3]	59.60
<i>Powerlets</i> [9]	79.00
SSI-DF (PROPOSTO)	87.30

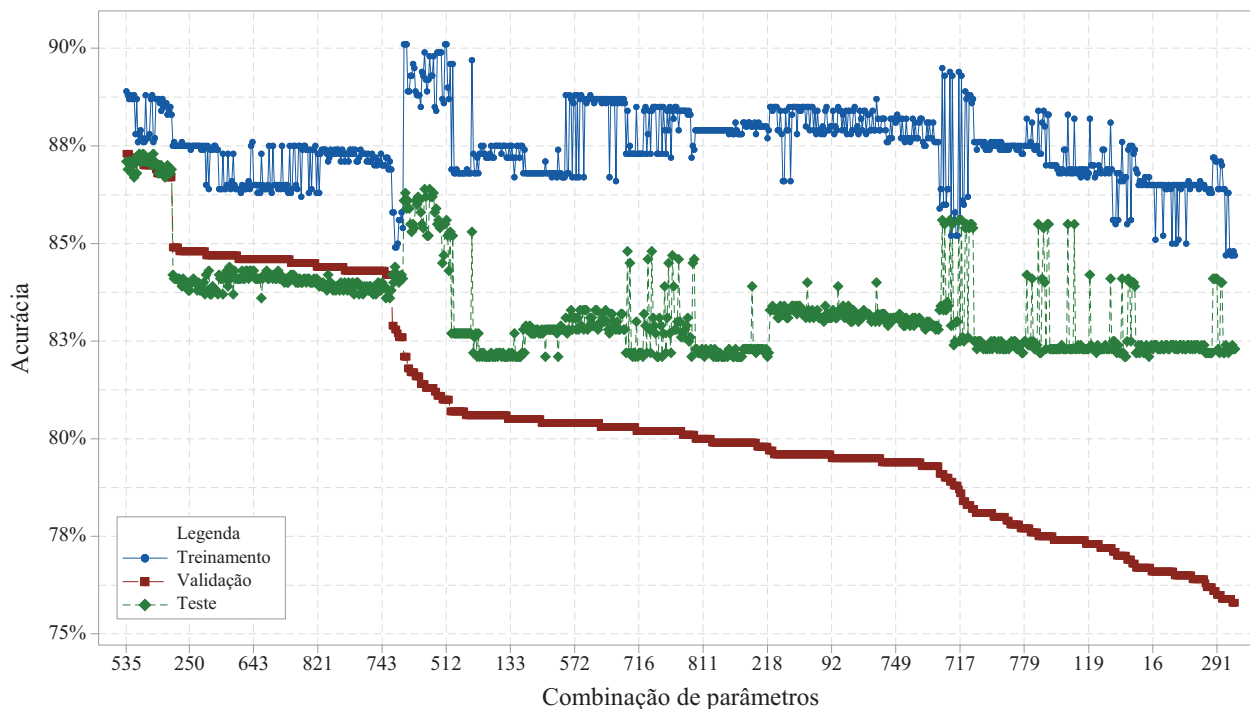


Fig. 4. Acurácia para cada combinação de parâmetros que influenciam no desempenho do sistema de desagregação.

V. CONCLUSÕES

Neste artigo, abordamos o problema de desagregação de sinais de energia elétrica que constitui uma etapa importante em um cenário de redes elétricas inteligentes. Duas contribuições foram propostas: na primeira, modificamos o algoritmo *steady-state identification* (SSI) para contemplar extração de estados estacionários com dimensões similares, originando o método *steady-state identification similar dimension* (SSI-SD) e, a seguir, realizamos uma análise de parâmetros que influenciam na formação dos dicionários e que, conseqüentemente, influenciam o desempenho da desagregação. Os experimentos foram realizados utilizando a base de dados *Reference Energy Disaggregation Data Set* (REDD) [8] e demonstram que a proposta produz um desempenho satisfatório para um conjunto de dispositivos e um bom desempenho na estimação do sinal consumido quando comparado com outras técnicas.

AGRADECIMENTOS

Esta pesquisa foi financiada com recursos da Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM).

REFERÊNCIAS

- [1] J. Froehlich, E. Larson, S. Gupta, G. Cohn, M. S. Reynolds, and S. N. Patel, "Disaggregated end-use energy sensing for the smart grid," *IEEE Pervasive Computing*, vol. 10, no. 1, pp. 28–39, 2011.
- [2] D. M. FALCÃO, "Integração de tecnologias para viabilização da smart grid," in *Anais do Simpósio Brasileiro de Sistemas Elétricos*, Belém, PA, 2010, pp. 18–21.
- [3] J. Z. Kolter and M. J. Johnson, "REDD: A public data set for energy disaggregation research," *Proc. Int. Workshop on Data Mining Applications in Sustainability*, vol. 25, pp. 59–62, 2011.
- [4] W. Chan, A. T. So, and L. Lai, "Harmonics load signature recognition by wavelets transforms," in *Proc. Int. Conf. on Electric Utility Deregulation and Restructuring and Power Technologies*, 2000, pp. 666–671.
- [5] J. Z. Kolter and T. Jaakkola, "Approximate inference in additive factorial hmms with application to energy disaggregation," in *Proc. Int. Conf. on Artificial Intelligence and Statistics*, N. D. Lawrence and M. A. Girolami, Eds., vol. 22, 2012, pp. 1472–1482.
- [6] G. W. Hart, "Nonintrusive appliance load monitoring," *Proceedings of the IEEE*, vol. 80, no. 12, pp. 1870–1891, 1992.
- [7] M. B. Figueiredo, "Contributions to electrical energy disaggregation in a smart home," Ph.D. dissertation, 2013. [Online]. Available: <http://hdl.handle.net/10316/24256>
- [8] J. Z. Kolter and M. J. Johnson, "Reference energy disaggregation data set (REDD)," <http://redd.csail.mit.edu>, acessado em abril de 2017.
- [9] E. Elhamifar and S. Sastry, "Energy disaggregation via learning powerlets and sparse coding," in *Proc. Int. Conf. on Artificial Intelligence*. AAAI Press, 2015, pp. 629–635.
- [10] J. Z. Kolter, S. Batra, and A. Y. Ng, "Energy disaggregation via discriminative sparse coding," in *Advances in Neural Information Processing Systems*, J. Lafferty, C. Williams, J. Shawe-taylor, R. Zemel, and A. Culotta, Eds., 2010, pp. 1153–1161.
- [11] K. Suzuki, S. Inagaki, T. Suzuki, H. Nakamura, and K. Ito, "Nonintrusive appliance load monitoring based on integer programming," in *Proc. Int. Conf. on Instrumentation, Control and Information*, 2008, pp. 2742–2747.
- [12] M. E. Berges, E. Goldman, H. S. Matthews, and L. Soibelman, "Enhancing electricity audits in residential buildings with nonintrusive load monitoring," *Journal of Industrial Ecology*, vol. 14, no. 5, pp. 844–858, 2010.
- [13] Y. X. Lai, C. F. Lai, Y. M. Huang, and H. C. Chao, "Multi-appliance recognition system with hybrid SVM/GMM classifier in ubiquitous smart home," *Information Sciences*, vol. 230, pp. 39–55, 2013.
- [14] T. Zia, D. Bruckner, and A. Zaidi, "A hidden markov model based procedure for identifying household electric loads," in *Proc. Int. Conf. on Industrial Electronics Society*, 2011, pp. 3218–3223.
- [15] E. Elhamifar, G. Sapiro, and S. S. Sastry, "Dissimilarity-based sparse subset selection," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014.
- [16] R. Kohavi, "A study of cross-validation and bootstrap for accuracy estimation and model selection," in *Proc. Int. Joint Conf. on Artificial Intelligence*, Montréal, Canada, August 1996, pp. 1137–1143.