

# IDENTIFICAÇÃO NÃO INTRUSIVA DE CARGAS ELÉTRICAS USANDO A TRANSFORMADA MODWT E REDE NEURAL AUTOENCODER

ROMIK P. DE SOUZA\*, CASSIUS Z. RESENDE\*, DANIEL C. CAVALIERI\*

\**Instituto Federal do Espírito Santo*  
*Rodovia ES-010 – Km 6,5 - Manguinhos\| 29173-087 – Serra – Es*  
*E-mails: polgliane@gmail.com, cassius@ifes.edu.br,*  
*daniel.cavaliere@ifes.edu.br*

**Abstract**— The characterization of electrical loads provides detailed information on the residential use of electricity and it is one of the main steps of nonintrusive load monitoring (NILM). This work proposes a signature for the electric currents of the appliances, through the application of the Maximal Overlap Discrete Wavelet Transform (MODWT). The classification task was performed by autoencoders neural networks and the results show that the proposed algorithm has accuracy above 84% and F1 score above 0.82 applied to real loads considering windows of 50 and 100 milliseconds.

**Keywords**— Autoencoders Neural Networks, Smart Grid, Maximal Overlap Discrete Wavelet Transform.

**Resumo**— A caracterização das cargas elétricas, que oferece informações detalhadas sobre o uso residencial da energia elétrica, é uma das principais etapas do monitoramento não-intrusivo (NILM). Este trabalho propõe uma assinatura para as correntes elétricas dos equipamentos, através da aplicação da transformada MODWT (*Maximal Overlap Discrete Wavelet Transform*). A tarefa de classificação foi executada utilizando-se Redes Neurais Autoencoders e os resultados encontrados demonstraram que o algoritmo proposto possui acurácia acima de 84% e *F1 score* acima de 0,82 para cargas elétricas reais considerando janelas de 50 e 100 milissegundos.

**Palavras-chave**— Rede Neural Autoencoder, *Smart Grid*, *Maximal Overlap Discrete Wavelet Transform*.

## 1 Introdução

A crescente preocupação mundial com o meio ambiente, com o uso adequado dos recursos disponíveis na natureza e com a perspectiva de escassez de recursos minerais, tais como o petróleo e carvão, tem gerado uma preocupação com a descoberta de fontes alternativas de energia e também com o uso consciente da energia elétrica por consumidores residenciais e industriais.

Em relação ao consumo de energia elétrica uma solução adotada por diversos países, incluindo o Brasil, para contornar e solucionar a crescente necessidade de aumento de energia elétrica é a adoção de políticas públicas que estimulem o uso correto desse recurso baseadas no Gerenciamento pelo Lado da Demanda (GLD) para o consumidor de baixa tensão (Torriti, 2012). A premissa básica do GLD é a busca por uma mudança no perfil de consumo de energia do consumidor, a fim de reduzir o uso de energia durante os períodos de pico utilizando incentivos financeiros e conscientização.

Considerando-se que a melhoria do gerenciamento energético de uma unidade residencial está ligada à possibilidade de informações *online* do consumo, fica a questão: como fazer este gerenciamento energético sem impactar em mudanças das instalações elétricas das unidades residenciais?

Uma alternativa a questão anterior são os sistemas de monitoramento de carga não intrusivos (do inglês NILM - *Nonintrusive Load Monitoring*). Esses sistemas consistem na identificação das cargas elétri-

cas de um circuito de maneira não intrusiva, utilizando a medição do sinal elétrico em um único ponto do circuito (Hart, 1992), portanto sem impactar em grandes mudanças nas instalações.

As estratégias de monitoramento não intrusivo têm se desenvolvido nos últimos 25 anos, desde os trabalhos iniciados por Hart (1992), que desenvolveu os primeiros modelos de NILM, utilizando *hardware* de baixa taxa de amostragem e algoritmos que analisavam as mudanças em um espaço bidimensional de assinaturas de potência ativa e reativa (plano  $\Delta P$ - $\Delta Q$ ), até os trabalhos atuais que exploram o reconhecimento de padrões e processamento de sinais digitais de alta frequência de amostragem.

Dentre as técnicas de reconhecimento de padrões para identificação das cargas elétricas em sistemas NILM, citam-se o trabalho de Du (2016) que utiliza trajetórias de tensão-corrente como assinaturas, para a classificação de equipamentos; o trabalho de Figueiredo (2012) que propõe uma nova metodologia para identificar cargas em regime e os trabalhos de Chang (2012); Gillis (2016) que faz uso de Transformada *Wavelet* na extração das características; e Pereira (2017) que utiliza como assinatura para as correntes elétricas dos equipamentos a transformada de Fourier de curta duração (STFT), seguido do método kernel PCA.

Já o trabalho de Monzani (2016) propõe a identificação das principais cargas consumidoras, em uma residência comum usando modo não intrusivo de monitoramento, sendo que para classificação utiliza uma rede neural artificial *perceptron* multicamadas com *backpropagation*, cuja porcentagem de acerto total foi de 57%.

Várias cargas elétricas distintas com assinaturas de correntes bem próximas são um desafio para as técnicas que procuram detectar de maneira robusta e assertiva os eventos de liga-desliga de todos os tipos de carga presentes em um sistema elétrico (Zeifman, 2011). Esse problema é abordado em Pereira (2017), sendo utilizada simulação de cargas elétricas para obtenção dos resultados em um modelo que usa Transformada de Fourier de curta duração (STFT) em conjunto método kernel PCA e também é abordado por Biansoongern (2016), que usa rede neural artificial com sistema embarcado com baixa taxa de amostragem para segregação de cargas elétricas.

É neste contexto que este trabalho está inserido, ou seja, este trabalho tem como objetivo identificar cargas elétricas semelhantes utilizando como metodologia para a extração de características das cargas elétricas a transformada MODWT (*Maximal Overlap Discrete Wavelet Transform*) e posterior aplicação de classificação das cargas usando Redes Neurais Autoencoders. Os resultados apresentados por este são decorrentes da aplicação do novo método em cargas elétricas reais e demonstram que o método desenvolvido é promissor, principalmente por se tratar de um método de classificação e não de separação/desagregação como os trabalhos desenvolvidos por Monzani (2016) e Nardello (2017).

O restante deste artigo é organizado da seguinte forma: a próxima seção realiza uma breve explanação teórica, descreve a metodologia do trabalho e as principais considerações sobre os critérios e parâmetros adotados. Na seção 3 são discutidos os resultados encontrados, com as principais observações referentes aos mesmos e a seção 4 conclui o estudo com propostas de melhorias e aperfeiçoamentos futuros.

## 2 Materiais e Métodos

A metodologia utilizada para este trabalho visa estabelecer um modelo consistente para determinação da assinatura ou característica única do sinal de corrente elétrica, que permita identificar uma carga utilizando um único ponto de medição, ou seja, utilizando o conceito do monitoramento não intrusivo (NILM) conforme apresentado na Figura 1.




Figura 1 - Sistema de monitoramento não intrusivo. Extraído de (Pereira, 2017)

Para aquisição de dados e sensoriamento da corrente foi utilizado um sensor hall LEM LA 50-S, em um sistema de aquisição com frequência de amostragem de 25 kHz.

Nesse esquema é possível estimar a quantidade e natureza das cargas individuais de uma rede elétrica residencial, monitorada por sensores instalados na sua alimentação principal. Através do sinal de corrente das cargas é possível usar métodos de análise e de segregação de características capazes de definir as características únicas de cada equipamento.

Os primeiros modelos para monitoramento não intrusivo foram propostos inicialmente por Hart (1992) e a partir de então constantes estudos foram realizados propondo soluções para resolver o problema de identificação de cargas, sendo que atualmente técnicas de reconhecimento de padrões e processamento de sinais digitais têm sido utilizadas para identificação de cargas elétricas em sistemas NILM, como identificação de cargas em regime (Figueiredo, 2012); o uso de Transformada *Wavelet* (Chang, 2012) (Gillis et al, 2016); e o uso da transformada de Fourier de curta duração (STFT) em conjunto método kernel PCA. (Pereira, 2017).

Neste contexto, o sistema proposto pode ser organizado conforme ilustrado na Figura 2 e explicado nas subseções seguintes.




Figura 2 - Arquitetura geral do sistema

### 2.1 Base de Dados

Para desenvolvimento deste trabalho foram escolhidas cargas reais de equipamentos puramente resistivos e componentes não lineares para os testes, sendo estas:

- CPU: uma fonte de computador, com filtro Valley-Fill, que realiza correção de fator de potência;
- FLUOR: uma lâmpada fluorescente compacta, com um retificador monofásico de ponte completa com capacitor de filtro;
- INC: uma lâmpada incandescente, de característica puramente resistiva;
- SOLDA: um ferro de solda, de característica puramente resistiva;
- FUR: uma furadeira de bancada sem carga, de característica resistiva com distorção;

- NOTE: uma fonte de notebook, com retificador monofásico de ponte completa com capacitor de filtro.

Uma importante característica do método proposto é o fato de que a base de dados de treinamento ser gerado a partir dos sinais de corrente individuais das seis cargas. O sinal de corrente para cada carga é medido, conforme a Figura 1 e, após esse procedimento, os sinais de corrente de cada carga são combinados computacionalmente entre si, formando a base de dados de treinamento.

A base de testes é formada realizando-se a medição das correntes reais do circuito contendo as cargas ligadas simultaneamente, sendo efetuadas todas as combinações de cargas reais possíveis, em um total de 63 classes oriundas da combinação das cargas reais.

A base gerada permitiu aplicação de algoritmo proposto para extração de características capazes de identificar cada elemento presente na rede elétrica. A Figura 3 apresenta uma visão geral sobre os procedimentos de treinamento/teste utilizados neste trabalho e a Figura 4 mostra um exemplo de combinação computacional de uma carga puramente resistiva e outra carga com componentes não lineares.

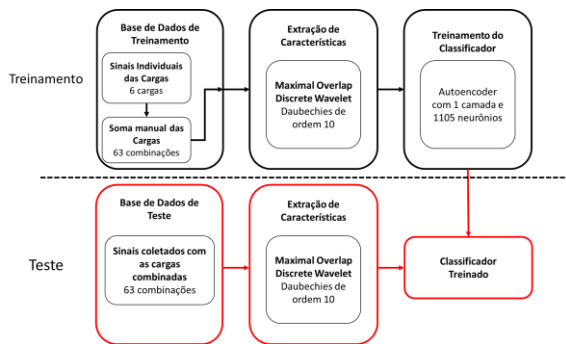


Figura 3 - Visão geral do treinamento/teste realizado neste trabalho

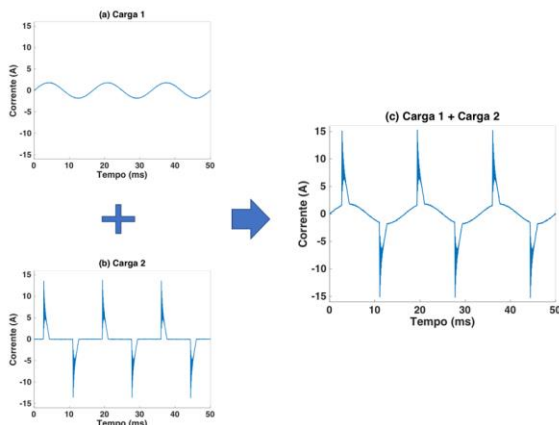


Figura 4 - Exemplo de cargas combinadas computacionalmente. (a) Carga puramente resistiva; (b) Carga não linear; (c) Soma das cargas

Assim, o conjunto de treinamento e testes foi dividido da seguinte forma: para o treinamento, cargas somadas computacionalmente, sendo geradas janelas de 3 e 6 ciclos sem sobreposição (50 e 100 milisse-

gundos), gerando 1260 e 630 amostras, respectivamente; para o teste, aquisição das cargas somadas fisicamente, considerando janelas com 3 e 6 ciclos de rede sem sobreposição, gerando o mesmo número de amostras de treinamento. É importante destacar que esse método de treinamento facilita a inclusão de novas cargas para classificação.

## 2.2 Extração de Características

A seleção de características tem sido objeto de debate para reconhecimento de padrões envolvendo sinais provenientes de cargas elétricas. Estudos compararam muitos recursos baseados em domínios de tempo e frequência (Kim, 2017; Hamid, 2017; Rossier, 2017). Em todos os casos, as características devem ser informativas e não redundantes, facilitando as etapas subsequentes de aprendizado e generalização, levando a separar ao máximo as classes desejadas. Na prática, a extração de características envolve também a redução da quantidade de recursos necessária para descrever um grande conjunto de dados, como em Pereira (2017).

A Transformada *Wavelet* Discreta (DWT) é uma transformação usada para analisar as propriedades temporais e espectrais de sinais não estacionários (Tzanetakis, 2001). Além disso, o DWT pode ser visto como um banco de filtros com espaçamento de oitavas entre os filtros, ou seja, cada sub-banda contém metade das amostras da sub-banda vizinha de frequência mais alta. De outra maneira, o sinal é analisado usando partições progressivas de bandas espectrais de resolução de escala em cada nível de decomposição. Isso é conseguido através da filtragem sucessiva de filtro passa-alta e filtro passa-baixa do sinal de tempo e da amostragem por sub-amostragem, (Tzanetakis, 2001).

Como descrito por Khalighi (2011), o MODWT pode ser visto como uma transformada DWT no qual a operação de subamostragem de um filtro de saída é omitida. Em consequência disso a propriedade de ortogonalidade dos conjuntos de coeficientes é perdida, mas a soma dos componentes obtidos reconstrói o sinal original. O MODWT é invariante ao deslocamento e não gera mudanças de fase nos componentes de detalhe e aproximação. O estimador de variância *wavelet* MODWT também é preferido porque demonstrou ser assintoticamente mais eficiente do que um estimador baseado no DWT (Khalighi, 2011; Guerrier, 2013).

Neste trabalho, utilizou-se uma MODWT da família *wavelet* Daubechies de ordem 10 (db10), o que gerou ao final 12 sub-bandas. Posteriormente, um conjunto espectrogramas foi extraído de cada sub-banda MODWT, ou seja, para cada uma das 63 classes analisadas, o sinal de corrente foi separado em *frames* e em cada janela foi aplicada a MODWT, percorrendo-se assim em todo o sinal coletado. O espectrograma gerado em cada *frame* foi armazenado em vetor para posterior uso na fase de treinamento.




Figura 5 - Metodologia de extração de características. Testes empíricos mostraram que os espectrogramas das sub-bandas 3, 5, 6, 9 e 10 apresentaram os melhores resultados para a classificação das cargas considerando-se janelas de 3 e 6 ciclos de rede (50 e 100 milissegundos)

Neste contexto, após alguns testes empíricos verificou-se que os melhores resultados experimentais foram obtidos utilizando-se os espectrogramas das sub-bandas 3, 5, 6, 9 e 10 para janelas de 3 e 6 ciclos. A Figura 5 apresenta a extração de características realizada e destaca-se que estudos já estão sendo realizados para determinar o porquê dessas bandas apresentarem os melhores resultados.

### 2.3 Classificação

Um dos principais objetivos deste trabalho foi verificar se a inclusão das características baseadas em MODWT pode aumentar o desempenho do sistema de classificação, bem como o comportamento com a adoção de Rede Neural Autoencoder para lidar com o processo de classificação. É importante destacar que todos os algoritmos foram implementados usando o MATLAB© e os resultados serão apresentados na seção 3 Resultados e Discussão.

Uma Rede Neural Autoencoder é um algoritmo de aprendizado não supervisionado que aplica a retropropagação, definindo os valores de destino como iguais às entradas. Em outras palavras, ele está tentando aprender uma aproximação para a função identidade, portanto, a saída de destino da rede é a própria entrada da rede. A função identidade parece uma função particularmente trivial de se tentar aprender; mas, colocando restrições na rede, como limitando o número de unidades ocultas, podemos descobrir uma estrutura interessante sobre os dados (Bengio, 2009). Se houver uma camada oculta linear e o critério de erro quadrático médio for usado para treinar a rede, o autoencoder se comportará como a Análise de Componentes Principais (PCA). No entanto, se a camada oculta não for linear, o autoencoder se comportará de maneira diferente do PCA, com a capacidade de capturar aspectos multimodais da distribuição de entrada (Bengio, 2009).

Um problema sério com relação a essa abordagem é que, se não houver outra restrição, um autoencoder com entrada  $n$ -dimensional e uma codificação de dimensão de pelo menos  $n$  poderia potencialmente aprender a função de identidade, ou seja, apenas copiar a entrada (Bengio, 2009). O argumento acima se baseia em um número de unidades ocultas pequeno. Surpreendentemente, quando o número de unidades ocultas é grande, ainda pode-se descobrir estrutu-

ras interessantes, impondo outras restrições à rede. Em particular, se impusermos uma restrição de dispersão (*sparsity*) nas unidades ocultas, o codificador automático ainda descobrirá uma estrutura interessante nos dados. Experimentos relatados em (Bengio, 2006) sugerem que, na prática, quando treinados com gradiente descendente estocástico, redes autoencoder não lineares com mais unidades ocultas do que entradas produzem representações úteis. Portanto, após alguns testes empíricos, a melhor estrutura neste trabalho foi obtida usando uma camada oculta com 1105 unidades de neurônios artificiais e função de transferência log-sigmoide. Além disso, os parâmetros  $L_2$ -weight regularization, *sparsity regularization* e *sparsity proportion* foram fixados em 0,004, 8 e 0,15, respectivamente.

Para fins de comparação com a metodologia adotada, foi utilizada a abordagem de (Pereira, 2017), baseada na aplicação do *kernel*-PCA e do algoritmo kNN. Os resultados obtidos e as respectivas análises serão apresentadas na próxima seção.

## 3 Resultados e Discussão.

O desempenho do algoritmo proposto foi avaliado usando o conjunto de dados obtido da combinação de 6 cargas reais, como explicado na Seção 2.1. Nos experimentos, adotou-se uma decomposição MODWT com Daubechies de 10ª ordem. Uma rede autoencoder com uma camada oculta, 1105 neurônios e uma função de transferência log-sigmoide foi utilizada na fase de classificação. A rede neural autoencoder foi treinada com o uso de gradiente descendente estocástico, com 200 épocas e com  $L_2$ -weight regularization, *sparsity regularization* e *sparsity proportion* fixados em 0,004, 8 e 0,15, respectivamente. Todos os resultados experimentais foram gerados usando o MATLAB© rodando em um notebook i7-7700 com NVIDIA GeForce GTX 1060, 16 Gb de RAM e um SSD de 512 Gb.

Um total de 63 sinais de corrente medidos durante 1 segundo foram utilizados para teste, sendo o sinal de corrente de cada combinação separado em janelas de 3 e 6 ciclos de rede, 50 e 100 milissegundos, respectivamente. Dentro desses 63 sinais de corrente, os sinais de corrente das cargas isoladas foram combinados a parte para se gerar o banco de dados de treinamento, como descrito na seção 2.1.

A família *wavelet* utilizada foi a Daubechies de ordem 10 (db10), que geralmente é utilizada quando se busca um maior refinamento dos dados. Essa família apresentou melhor resultado, obtendo um acerto médio de 84,55% para 3 e 6 ciclos de rede. Por exemplo, aplicando o mesmo método proposto, mas substituindo a família *wavelet* para a Haar, foi obtido um resultado médio de classificação de 55%, o que demonstra a importância da escolha correta da função *wavelet* para o resultado da classificação.

A Tabela 1 apresenta os resultados médios (acurácia) para cada uma das cargas utilizando abordagem proposta neste trabalho e a proposta por (Pereira, 2017). O método proposto por Pereira (2017) utiliza de extração das características e definição das assinaturas para cargas elétricas por meio da aplicação da Transformada de Fourier de Tempo Curto (do inglês, *Short Time Fourier Transform - STFT*) em conjunto com o *kernel* PCA. Além disso, foi utilizado o classificador kNN (com  $k = 5$ ) para validar a capacidade de separação das informações. Os melhores resultados para cada ciclo estão destacados em negrito.

Tabela 1. Acerto médio obtido pelo método proposto em comparação com a metodologia desenvolvida por (Pereira, 2017)

Número de Ciclos de Rede	3		6	
	Taxa de Acerto (%)	Tempo de Treinamento (Seg.)	Taxa de Acerto (%)	Tempo de Treinamento (Seg.)
Kernel PCA	73,73	2,16	81,05	0,63
MODWT + Autoencoder	<b>84,55</b>	109,78	<b>84,55</b>	147,97

É possível observar na Tabela 1 que o método proposto obteve bom resultado para janelas com 3 ciclos de rede sem sobreposição e que a metodologia adotada conseguiu manter a taxa de acerto médio superior a 84%, o que confirma a hipótese de que um desempenho uniformemente bom é obtido por um classificador mais complexo, à medida que a complexidade dos dados de treinamento/teste também aumenta (Almotiri, 2017).

É interessante notar também da Tabela 1 o tempo de treinamento de cada algoritmo, onde o método *Kernel* PCA apresentou resultados bem mais baixos que o proposto neste trabalho. Ainda dentro deste contexto, é importante destacar que o tempo gasto para o treinamento aumentou para o algoritmo proposto quando considerado 6 ciclos, que possui um conjunto de dados menor (630 amostras) do que 3 ciclos de rede (1260 amostras). Isso pode ser explicado pelo fato de que com mais amostras o erro do algoritmo proposto convergiu mais rápido. Já para o algoritmo proposto por (Pereira, 2017), é possível notar o oposto, ou seja, quanto mais amostras, maior o tempo de treinamento.

Ainda dentro do contexto de resultados, é interessante analisar também a sensibilidade e a precisão por cada classe (do inglês, *Sensitivity* ou *Recall* e *Precision*, respectivamente) do algoritmo proposto. De maneira geral, a sensibilidade é a capacidade de identificar corretamente as classes que são positivas dentro do conjunto total de classes classificadas como positivas (verdadeiro positivo mais falso positivo). Já a precisão está relacionada com a porcentagem de exemplos classificados como positivos que são realmente positivos. Assim, as Tabelas 2 e 3 descrevem os resultados de sensibilidade e precisão do algoritmo, respectivamente, para cada classe analisada considerando-se 3 ciclos de rede. Já a Figura 6 apresenta as legendas de cada classe para as Tabelas 2 e 3.

Tabela 2. Sensibilidade obtida pelo algoritmo proposto para cada classe considerando-se janelas de 3 ciclos de rede (50 milissegundos) sem sobreposição

Classe	Taxa (%)	Classe	Taxa (%)	Classe	Taxa (%)
1	100	22	90	43	65
2	100	23	90	44	20
3	100	24	85	45	70
4	100	25	60	46	40
5	100	26	100	47	50
6	100	27	65	48	100
7	100	28	90	49	100
8	100	29	5	50	60
9	100	30	100	51	55
10	20	31	5	52	100
11	100	32	100	53	100
12	100	33	95	54	90
13	100	34	100	55	50
14	100	35	100	56	100
15	100	36	100	57	100
16	100	37	100	58	100
17	100	38	100	59	5
18	85	39	100	60	45
19	90	40	90	61	100
20	100	41	90	62	100
21	100	42	100	63	100

Os resultados da taxa de sensibilidade para cada classe, descrito na Tabela 2, demonstram que o algoritmo proposto foi capaz de separar corretamente quase todas as cargas, incluindo algumas que possuem uma alta correlação, tal como a classe 34 e a classe 36. Nota-se também que o classificador falhou em classificar as classes 29, 31 e 59 sendo confundidas principalmente com as classes 27, 50, e 60 que possuem cargas semelhantes do ponto de vista de características elétricas. Nesse sentido, é interessante destacar que em quase todos os casos citados a única diferença entre as classes confundidas foi a presença do ferro de solda e da lâmpada incandescente, ambas cargas resistivas com assinatura harmônica muito semelhantes.

Analisando-se agora a precisão do algoritmo proposto para cada classe na Tabela 3, nota-se que o classificador apresentou uma taxa de acerto de 100%, 100% e 50% para as classes 29, 31 e 59, que apresen-

taram os piores resultados de sensibilidade. Neste caso, podemos concluir então que o classificador proposto possui muitos falsos negativos para as classes mencionadas, corroborando com a hipótese de que cargas com assinatura harmônica muito semelhantes, como as cargas resistivas, afetam a performance do algoritmo.

Tabela 3. Precisão obtida pelo algoritmo proposto para cada classe considerando-se janelas de 3 ciclos de rede (50 milissegundos) sem sobreposição

Classe	Taxa (%)	Classe	Taxa (%)	Classe	Taxa (%)
1	100	22	90	43	68
2	100	23	100	44	33
3	100	24	100	45	67
4	100	25	100	46	33
5	56	26	100	47	100
6	100	27	45	48	100
7	100	28	100	49	100
8	100	29	100	50	52
9	100	30	91	51	61
10	67	31	100	52	100
11	87	32	100	53	100
12	100	33	95	54	60
13	100	34	100	55	53
14	100	35	95	56	69
15	100	36	100	57	100
16	100	37	100	58	62
17	91	38	100	59	50
18	100	39	100	60	36
19	69	40	78	61	95
20	100	41	72	62	69
21	100	42	100	63	80

Classe	Carga	Classe	Carga
1	CPU	33	FLUOR, INC, FUR
2	FLUOR	34	FLUOR, INC, NOTE
3	INC	35	FLUOR, SOLDA, FUR
4	SOLDA	36	FLUOR, SOLDA, NOTE
5	FUR	37	FLUOR, FUR, NOTE
6	NOTE	38	INC, SOLDA, FUR
7	CPU, FLUOR	39	INC, SOLDA, NOTE
8	CPU, INC	40	INC, FUR, NOTE
9	CPU, SOLDA	41	SOLDA, FUR, NOTE
10	CPU, FUR	42	CPU, FLUOR, INC, SOLDA
11	CPU, NOTE	43	CPU, FLUOR, INC, FUR
12	FLUOR, INC	44	CPU, FLUOR, INC, NOTE
13	FLUOR, SOLDA	45	CPU, FLUOR, SOLDA, FUR
14	FLUOR, FUR	46	CPU, FLUOR, SOLDA, NOTE
15	FLUOR, NOTE	47	CPU, FLUOR, FUR, NOTE
16	INC, SOLDA	48	CPU, INC, SOLDA, FUR
17	INC, FUR	49	CPU, INC, SOLDA, NOTE
18	INC, NOTE	50	CPU, INC, FUR, NOTE
19	SOLDA, FUR	51	CPU, SOLDA, FUR, NOTE
20	SOLDA, NOTE	52	FLUOR, INC, SOLDA, FUR
21	FUR, NOTE	53	FLUOR, INC, SOLDA, NOTE
22	CPU, FLUOR, INC	54	FLUOR, INC, FUR, NOTE
23	CPU, FLUOR, SOLDA	55	FLUOR, SOLDA, FUR, NOTE
24	CPU, FLUOR, FUR	56	INC, SOLDA, FUR, NOTE
25	CPU, FLUOR, NOTE	57	CPU, FLUOR, INC, SOLDA, FUR
26	CPU, INC, SOLDA	58	CPU, FLUOR, INC, SOLDA, NOTE
27	CPU, INC, FUR	59	CPU, FLUOR, INC, FUR, NOTE
28	CPU, INC, NOTE	60	CPU, FLUOR, SOLDA, FUR, NOTE
29	CPU, SOLDA, FUR	61	CPU, INC, SOLDA, FUR, NOTE
30	CPU, SOLDA, NOTE	62	FLUOR, INC, SOLDA, FUR, NOTE
31	CPU, FUR, NOTE	63	CPU, FLUOR, INC, SOLDA, FUR, NOTE
32	FLUOR, INC, SOLDA	64	--

Figura 6 - Legenda para as classes das Tabelas 2 e 3.

É importante destacar também que, geralmente, a precisão e a sensibilidade não são discutidas isoladamente.

Em vez disso, ou os valores de uma medida são comparados a um nível fixo na outra medida ou ambas são combinadas em uma única medida. Exemplos de medidas que são uma combinação de precisão e sensibilidade são os *F-measure* ou *F-score* (a média harmônica ponderada de precisão e sensibilidade). Assim, a Tabela 4 apresenta o *F1 score* médio do algoritmo proposto considerando-se 3 e 6 ciclos de rede e comparando-se com a metodologia desenvolvida por (Pereira, 2017).

Tabela 4. *F1 score* médio obtido pelo método proposto em comparação com a metodologia desenvolvida por (Pereira, 2017)

Metodologia	3 Ciclos	6 Ciclos
Kernel PCA	0,7236	0,7928
MODWT + Autoencoder	<b>0,8280</b>	<b>0,8288</b>

Novamente, analisando-se a Tabela 4 é possível notar que o algoritmo proposto apresentou melhores resultados que o trabalho proposto por (Pereira, 2017).

#### 4 Considerações Finais

Este artigo propõe e valida um novo método para identificação de cargas elétricas de maneira não intrusiva utilizando-se a transformada MODWT em conjunto com Rede Neural Artificial Autoencoder. Os resultados obtidos por esse método apresentaram acurácias médias de 84,55% e *F1 score* de 0,8280 e 0,8288 na classificação de cargas considerando 3 e 6 ciclos de rede, respectivamente, mostrando que o método é eficiente para cumprir o seu objetivo proposto. Além disso, o resultado é superior ao apresentado por trabalhos correlatos. Ressalta-se ainda que a classificação por rede neural Autoencoder demanda grande necessidade de processamento para o treinamento, entretanto, uma vez a rede treinada ela é efetiva e eficiente para a classificação das cargas utilizadas na rede residencial, sendo o tempo de treinamento das cargas de 109,78 e 147,97 segundos para 3 e 6 ciclos, respectivamente. Esses resultados e características permitem afirmar que a linha proposta neste trabalho é promissora para a área de *Smart Grid*.

Finalmente, para futuros trabalhos pretende-se verificar o motivo das sub-bandas 3, 5, 6, 9 e 10 apresentarem os melhores resultados empíricos e também o uso de outros tipos de algoritmos de *Deep Learning*, como as Redes Neurais Convolucionais, como métodos de classificação.

#### Referências Bibliográficas

Almotiri, J., Elleithy, K., Elleithy, A., (2017). Comparison of autoencoder and Principal Component Analysis followed by neural network for e-learning using handwritten recognition.

- IEEE, pp. 1–5.  
<https://doi.org/10.1109/LISAT.2017.8001963>
- Bengio, Y., (2009). Learning Deep Architectures for AI. *Foundations and Trends® in Machine Learning* 2, 1–127.  
<https://doi.org/10.1561/22000000006>
- Bengio, Y., Lamblin, P., Popovici, D., and Hugo Larochelle, H., (2006). Greedy layer-wise training of deep networks. In *Proceedings of the 19th International Conference on Neural Information Processing Systems (NIPS'06)*, B. Schölkopf, J. C. Platt, and T. Hoffman (Eds.). MIT Press, Cambridge, MA, USA, 153-160.
- Biansoongnern, S., Plangklang, B (2016). Nonintrusive Load Monitoring (NILM) Using an Artificial Neural Network in Embedded System with Low Sampling Rate. In: *13th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*.  
<https://doi.org/10.1109/ECTICon.2016.7561398>
- Chang, H. H., Chen, K. L., Tsai, Y. P., & Lee, W. J. (2012). A new measurement method for power signatures of nonintrusive demand monitoring and load identification. *IEEE Transactions on Industry Applications*, 48(2), 764-771.
- Du, L., He, D., Harley, R. G., & Habetler, T. G. (2016). Electric load classification by binary voltage–current trajectory mapping. *IEEE Transactions on Smart Grid*, 7(1), 358-365.
- Figueiredo, M., De Almeida, A., e Ribeiro, B. (2012). Home electrical signal disaggregation for non-intrusive load monitoring (NILM) systems. *Neurocomputing*, 96, 66-73.
- Gillis, J. M., Alshareef, S. M., & Morsi, W. G. (2016). Nonintrusive load monitoring using wavelet design and machine learning. *IEEE Transactions on Smart Grid*, 7(1), 320-328.
- Guerrier, S., Skaloud, J., Stebler, Y., Victoria-Feser, M., (2013). Wavelet-Variance-Based Estimation for Composite Stochastic Processes. *Journal of the American Statistical Association*.
- Hamid, O., Barbarosou, M., Papageorgas, P., Prekas, K., Salame, C.-T., (2017). Automatic recognition of electric loads analyzing the characteristic parameters of the consumed electric power through a Non-Intrusive Monitoring methodology. *Energy Procedia* 119, 742–751.  
<https://doi.org/10.1016/j.egypro.2017.07.137>
- Hart, G. W. (1992) Nonintrusive Appliance Load Monitoring, *Proceedings of the IEEE*, Vol. 80, pp. 1870-1891.
- Khalighi, S., Sousa, T., Oliveira, D. Pires, G., Nunes, U., (2011). Efficient feature selection for sleep staging based on maximal overlap discrete wavelet transform and SVM. In: *ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY 2011*.
- Kim, J., Le, T.-T.-H., Kim, H., (2017). Nonintrusive Load Monitoring Based on Advanced Deep Learning and Novel Signature. *Computational Intelligence and Neuroscience* 2017, 1–22.  
<https://doi.org/10.1155/2017/4216281>
- Monzani, R., (2016). Monitoramento não invasivo e identificação do consumo de energia individual de cargas residenciais. (Tese de Doutorado). Unicamp, Campinas, Brasil.
- Nardello, M., Rossi, M., Brunelli, D. (2017). A Low-cost Smart Sensor for Non Intrusive Load Monitoring Applications. *IEEE 26th International Symposium on Industrial Electronics (ISIE)*.  
<https://doi.org/10.1109/ISIE.2017.8001444>
- Pereira, E. L., Cavalieri, D. C., Resende, C. Z. (2017). Método De identificação de Cargas Elétricas Utilizando as Técnicas Short-Time Fourier e Kernel Pca.
- Rossier, F., Lang, P., Hennebert, J., (2017). Near Real-Time Appliance Recognition Using Low Frequency Monitoring and Active Learning Methods. *Energy Procedia* 122, 691–696.  
<https://doi.org/10.1016/j.egypro.2017.07.371>
- Torriti, Jacopo (2012). Price-based demand side management: Assessing the impacts of time-of-use tariffs on residential electricity demand and peak shifting in Northern Italy. *Energy*, v. 44, n. 1, p. 576-583.
- Tzanetakis, G., Essl, G., Cook, P., (2001). Audio Analysis using the Discrete Wavelet Transform. *Proceedings of the Conference in Acoustics and Music Theory Applications*. pp. 318-323.
- Zeifman, M., & Roth, K. (2011). Nonintrusive appliance load monitoring: Review and outlook. *IEEE transactions on Consumer Electronics*, 57(1).