

## CAPÍTULO 8

# Monitoração não intrusiva de cargas elétricas utilizando classificadores de inteligência artificial de ponta: análise de desempenho de redes neurais artificiais e técnicas de aprendizagem profunda

### 8.1 INTRODUÇÃO

A conservação de energia elétrica nos dias de hoje é um desafio que pesquisadores têm tentado superar com a proposição de novos programas de conservação, novas tecnologias ou novos métodos para a minimização do consumo de energia elétrica. Dentro desse panorama, pode-se destacar o setor residencial brasileiro que, no ano de 2017, foi responsável por 28,86% do consumo de energia elétrica total do país (Procel, 2017). Essa é uma crescente preocupação, uma vez que os recursos de energia são limitados e o aumento do consumo do setor elétrico tem impactos diretos e negativos no meio ambiente, por exemplo as emissões de  $\text{CO}_2\text{O}_2$  (Zoha *et al.*, 2012).

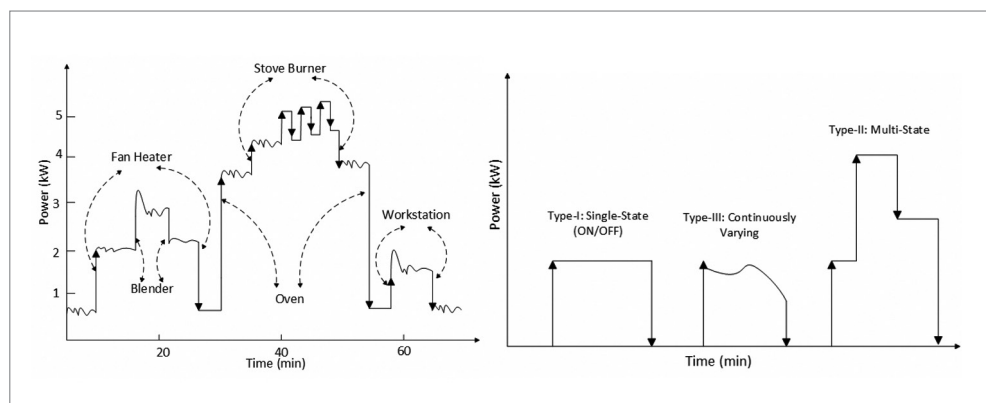
Uma significativa redução no consumo de energia elétrica pode ser obtida por meio de informações detalhadas enviadas aos consumidores sobre o seu próprio consumo. Isso pode ser comprovado pelo material coletado e publicado que levou em consideração mais de 60 estudos que obtiveram como respostas que a máxima

economia de energia elétrica poderia ser alcançada se fossem utilizados mecanismos que disponibilizassem ao consumidor o seu próprio consumo em tempo real, diferente das tradicionais contas mensais de energia elétrica (Ehrhardt-Martinez; Donnelly; Laitner, 2010).

As técnicas existentes que possibilitam esse acompanhamento em tempo real do consumo de energia elétrica são possíveis de serem aplicadas por meio dos denominados medidores inteligentes (*smart meters*), amplamente utilizados para análise de parâmetros elétricos em tempo real. Esses medidores, além de coletarem informações em tempo real, podem enviá-las por meio de tecnologias sem fio para centros de processamento de dados, além de serem capazes de receber informações e processá-las, ou seja, têm tecnologia de comunicação bidirecional (Buchholz, 2014).

Dentre as técnicas para o monitoramento em tempo real do consumo de energia elétrica, duas têm chamado maior atenção de pesquisadores e desenvolvedores: o monitoramento intrusivo de carga (ILM, do inglês *intrusive load monitoring*) e o monitoramento não intrusivo de carga (NILM, do inglês *non-intrusive load monitoring*).

O monitoramento intrusivo de cargas necessita de um número de medidores tal qual a quantidade de cargas a serem monitoradas. A vantagem dessa técnica é ter, sem erros, o consumo individual de cada equipamento elétrico a ser monitorado. Porém, tem como desvantagem o alto custo devido à quantidade de medidores ou pontos de medidas a serem utilizados. Já a técnica de desagregação por monitoramento não intrusivo necessita de somente 1 ponto de medição e, com técnicas de desagregação de cargas, consegue separar e classificar quais cargas estão sendo utilizadas naquele instante. O NILM pode ser realizado uma vez que as cargas elétricas, eletrodomésticos por exemplos, têm o que se denomina assinatura de carga (Zeifman; Roth, 2011). Essa assinatura de carga as difere, como mostra a Figura 8.1.




**Figura 8.1** Desagregação de carga pelo método não intrusivo.

Fonte: Zoha et al., 2012.

Dessa maneira, as cargas são divididas em 4 grupos (Hoyo-Montaña *et al.*, 2016):

- Tipo I: estado único: ligado / desligado. Exemplos: lâmpadas, torradeiras etc.
- Tipo II: multiestados. Exemplos: máquinas de lavar, forno elétrico etc.
- Tipo III: continuamente variante. Exemplos: furadeiras e lâmpadas dimerizáveis.
- Tipo IV: cargas de consumo permanente. Exemplos: televisores em standby, aparelhos de DVD etc.

As cargas tipo I são mais simples de serem detectadas, porém, dependendo da sua potência nominal e do consumo de energia elétrica, pode ser que a técnica aplicada para a desagregação não consiga chegar a uma conclusão de qual equipamento elétrico está sendo utilizado. Devido à característica própria de cada equipamento elétrico (harmônicos de corrente, potência, características de uso, entre outras), pesquisadores têm encontrado dificuldades em desagregar cargas no nível de baixa potência devido às características próximas de funcionamentos que alguns equipamentos possuem, como ilustra a Figura 8.2.



**Figura 8.2** Características de potência nominal de diversos eletrodomésticos.

Fonte: elaborada pelo autor.

Dentre as técnicas utilizadas para a desagregação não intrusiva de cargas elétricas, podem ser citadas:

- Algoritmos genéticos.
- Redes neurais artificiais.

- Decomposição da forma de onda por série de Fourier.
- Valores de pico e RMS de tensão e corrente.
- Transformada rápida de Fourier.

Apesar dos avanços recentes (Zoha *et al.*, 2012), há uma série de problemas em aberto nesse campo. Para superar as limitações, este capítulo propõe um estudo comparativo de diversas ferramentas de inteligência artificial de ponta para a desagregação não intrusiva de cargas, a fim de se obter a melhor dentre as analisadas. Um comparativo dos melhores resultados encontrados com pesquisas atuais também é feito.

Dessa maneira, este capítulo tem como contribuições:

- A utilização do sinal de corrente elétrica do sistema em análise.
- Uma metodologia para identificar equipamentos elétricos residenciais por meio dos sinais de corrente e potência ativa.
- Um comparativo entre 3 técnicas de inteligência artificial de ponta para a classificação na desagregação de cargas elétricas residenciais pelo método de monitoramento não intrusivo.
- A apresentação de uma arquitetura de rede neural convolucional que resulta em maiores taxas de acurácia comparada a trabalhos já publicados.


## 8.2 CLASSIFICADORES

### 8.2.1 Rede neural densa

Para construir uma rede neural, é preciso conectar vários neurônios entre si, formando uma espécie de grafo. A forma como essas conexões são feitas determina o que é conhecido como arquitetura da rede.

Uma rede neural é composta de camadas, e cada camada é um conjunto de neurônios distribuídos em uma determinada ordem dentro da rede; cada camada pode ter uma quantidade diferente de neurônios. Em geral, considera-se como a primeira camada os dados de entrada, a última como a camada de saída e se existirem camadas intermediárias, entre a primeira e última, são denominadas camadas ocultas.

Nesta pesquisa, foi utilizada a arquitetura de rede conhecida como *multilayer perceptron* (MLP). Nesse tipo de rede, todos os neurônios de uma camada estão conectados com os neurônios da camada seguinte, como mostra a Figura 8.3.



**Figura 8.3** Exemplo de uma rede neural MLP.

Fonte: elaborada pelo autor.

Na Figura 8.3,  $x_k$  representa os dados de entrada,  $y_c$  os dados de saída e  $a_M$  os neurônios das camadas ocultas.

Essa arquitetura pode ser resumida de acordo com as seguintes camadas que a constituem:

- Uma camada de entrada contendo os 137 coeficientes positivos dos harmônicos da corrente. O sinal de corrente antes da transformada era representado por 275 valores.
- Três camadas densas ocultas ordenadas, cada uma com 128, 64 e 32 neurônios.
- Uma camada densa de saída, com 187 e 64 neurônios de saída para os circuitos geral Main 1 e 2, respectivamente.
- Camadas *dropout* entre cada camada densa, cuja função é reduzir o *overfitting* do modelo.

De maneira a se obter os melhores resultados para a classificação proposta por meio da rede neural densa, lançou-se mão da transformada discreta de Fourier, para que fossem extraídas características dos sinais de correntes utilizados e estas fossem usadas no treinamento da rede.

### 8.2.2 Rede LSTM (*long short-term memory network*)

A tradicional rede neural recorrente (RNN) tem dificuldade em aprender dependências de longo prazo. Para solucionar esse problema, a LSTM foi projetada. A rede neural LSTM consiste em unidades de LSTM as quais contêm três *gates* especiais, projetados para controlar o fluxo de informação dentro de cada bloco de memória

(Hochreiter; Schmidhuber, 1997). A estrutura da LSTM, denominada célula, pode ser vista na Figura 8.4.

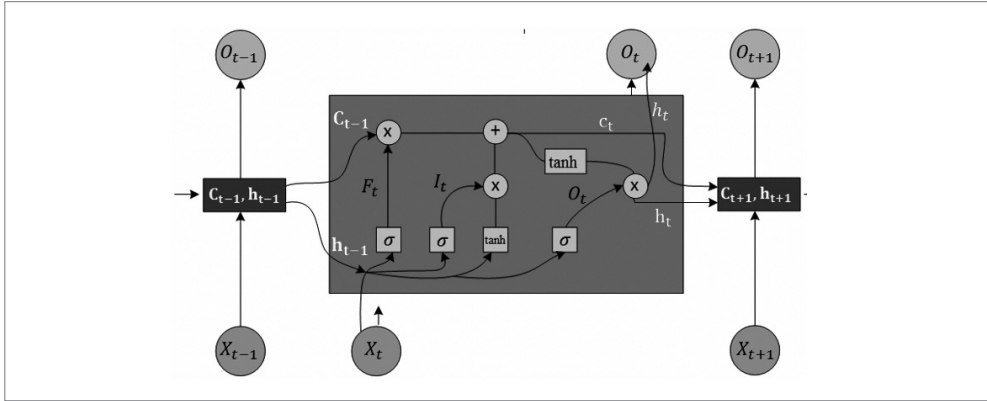


Figura 8.4 Estrutura da rede LSTM.

Fonte: elaborada pelo autor.

O primeiro *gate* é chamado de *forget gate*,  $F_t$ , o qual fornece um peso para o estado de esquecimento e tem a função de decidir o quanto de memória prévia pode ser jogada fora da célula de estado. Pode ser calculado da seguinte maneira:

$$F_t = \sigma(W_F \times [h_{t-1}, X_t] + b_F) \quad (8.1)$$

onde  $\sigma(\cdot)$  é uma função elemento-*wise* não linear; usualmente chamada de função de ativação,  $W_F$  e  $b_F$  são os pesos e bias da matriz do *forget gate*, respectivamente;  $h_{t-1}$  é a saída da camada escondida no último momento e;  $X_t$  é a entrada no momento atual.

O próximo passo consiste em calcular o valor de entrada do *gate*  $I_t$ , o qual decide o quanto de informação nova será armazenada na célula estado. Esse passo tem duas partes: na primeira, a camada sigmoide do *gate* filtra alguma informação de  $h_{t-1}$ ,  $X_t$  e  $C_{t-1}$ , depois uma camada *tanh* cria o valor dos novos valores candidatos  $S_t$ :

$$i_t = \sigma(W_i \times [h_{t-1}, X_t] + b_i) \quad (8.2)$$

$$S_t = \tanh(W_s \times [h_{t-1}, X_t] + b_s) \quad (8.3)$$

onde  $W_i$ ,  $W_s$ ,  $b_i$  e  $b_s$  são os correspondentes pesos e bias.

Assim, a célula estado  $C_t$  pode ser calculada como:

$$C_t = F_t \cdot C_{t-1} + i_t \cdot S_t \quad (8.4)$$

Finalmente, o *gate* de saída  $O_t$  é calculado para controlar o quanto de informação irá fluir para fora da célula (8.5). Depois, normaliza os valores da célula estado entre -1 e 1, por meio da camada tanh, e depois multiplica pela camada sigmoide de saída. A saída é definida como (8.6):

$$O_t = \sigma \left( W_i \times [h_{t-1}, X_t] + b_i \right) \quad (8.5)$$

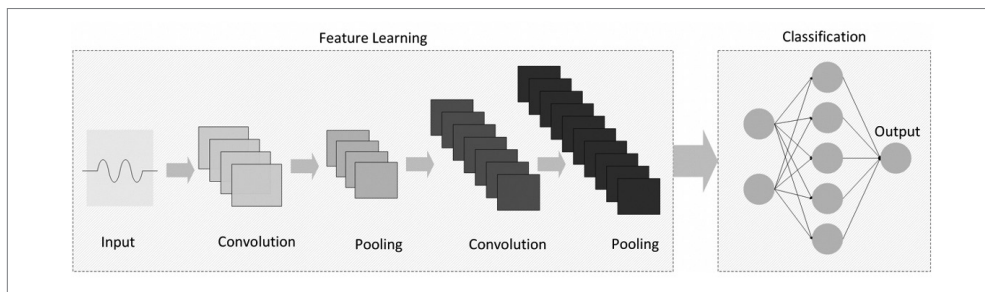
$$h_t = O_t \cdot \tanh(C_t) \quad (8.6)$$

### 8.2.3 Rede neural convolucional (ConvNet)

Redes neurais convolucionais (ConvNet,) são muito similares a redes neurais convencionais, assim como a rede MLP. São constituídas de neurônios que possuem pesos (ou parâmetros) que “aprendem”. Cada neurônio recebe entradas e realiza um produto escalar, seguido opcionalmente por uma função de ativação não linear.

De modo particular, as camadas de uma ConvNet possuem neurônios organizados em três dimensões: largura, altura e profundidade (nesse caso, a profundidade refere-se à terceira dimensão de um volume de ativação, e não à profundidade da arquitetura da rede, determinada pelo número de camadas ocultas).

Uma rede com arquitetura convolucional é constituída de uma sequência de camadas, e cada camada transforma um volume de ativação em outro por meio de uma função diferenciável. As três principais camadas utilizadas na construção de uma arquitetura convolucional são: camada convolucional, camada de *pooling* e camada densa. A Figura 8.5 mostra um exemplo de arquitetura convolucional.



**Figura 8.5** Exemplo de arquitetura convolucional.

Fonte: elaborada pelo autor.

A função de cada camada utilizada na arquitetura pode ser assim resumida:

- Camadas convolucionais: extraem as melhores características do sinal de corrente de maneira automatizada, sem a necessidade de realizar, por exemplo, a filtragem do sinal. A primeira camada possui 275, pois é a dimensão dos dados que representam a forma de onda da corrente.
- Camadas *pooling*: dimensionam e mapeiam os dados após a convolução, reduzindo a dimensão dos dados destacando informações importantes.
- Camadas *batch normalization*: melhoram a velocidade, o desempenho e a estabilidade de arquiteturas profundas (i.e., arquiteturas que possuem muitas camadas ocultas) durante o treinamento da rede. Possuem ainda a função de reduzir o *overfitting* nos dados de treinamento.
- Camada de saída densa: atribui uma classe ao sinal de entrada e depende do número de classes. Para os sinais de Main 1 e Main 2, são, respectivamente, 187 e 64 classes.

Para esse estudo, a arquitetura da ConvNet utilizada é mostrada na Figura 8.6.




Figura 8.6 Arquitetura convolucional base.

Fonte: elaborada pelo autor.

### 8.3 BASE DE DADOS

Os dados utilizados no treinamento, validação e teste dos modelos pertencem a base de dados *reference energy disaggregation dataset* (REDD) (Kolter; Johnson, 2011). Essa base contém informações de consumo no nível de uma casa inteira e de circuito/aparelho. Na versão da base utilizada nessa pesquisa, existem informações referentes a seis casas. Para cada uma, foram armazenados os dados de potência aparente (VA) no nível de circuito geral da casa, amostrados em uma taxa de 1 Hz, e no nível de



circuito/aparelho a uma taxa de 0,33 Hz. Cada casa possui dois circuitos gerais, denominados Main 1 e Main 2. No entanto, para duas dessas seis casas, também foram capturados os sinais de tensão e corrente em nível do circuito geral da casa, ambos amostrados em uma taxa de 15 kHz.

Para a realização deste trabalho, foram utilizados os dados referentes às correntes dos equipamentos elétricos. Assim, utilizaram-se apenas informações de uma das duas casas, a casa número três, pois esta possuía maior quantidade de dados. Assim como para a potência, existem sinais de corrente para o Main 1 e para o Main 2.

Esses dados são amostrados a uma taxa de 15 KHz, então, como explicado por Kolter e Johnson (2011), utiliza-se uma compressão nos dados, no qual são armazenadas as formas de ondas, e dados que indicam o seu *time stamps*.

Conforme explicado no Capítulo 3, *time stamp* é um tipo de dado DATE capaz de armazenar informações de ano, mês, dia, hora, minuto e segundo. Desse modo, os arquivos *current1.dat* e *current2.dat* com as medições agregadas dos circuitos gerais (Mains) 1 e 2, possuem linhas cada uma com as seguintes informações:

- Um valor decimal de *time stamp* que permite parte fracionária.
- Um número inteiro, contador da duração de ciclos da forma de onda.
- 275 valores reais, indicando o valor da forma de onda (em ampères), que estão igualmente espaçados dentro do ciclo.

A Figura 8.7 apresenta o formato dos dados de medição de corrente disponíveis na base REDD.

```
1297340206.597013 135.000000 0.000000 3.623859 7.254136 10.949398 ...
1297340208.844086 722.000000 0.000000 3.638527 7.249567 10.929027 ...
```

**Figura 8.7** Exemplo de dados contidos em arquivo do REDD.

Fonte: Kolter; Johnson, 2011.

### 8.3.1 Pré-processamento dos dado

A aquisição de dados e a montagem de um banco com essas informações é uma tarefa complexa e que pode despendar muito tempo; por isso, optou-se pela utilização de uma base já existente (REDD). Contudo, ainda assim foi necessário realizar um pré-processamento para que os dados pudessem de fato ser utilizados no treinamento dos classificadores.

Os valores de potência aparente e corrente de cada circuito medido não podem ser somadas diretamente, uma vez que cada circuito possui um fator de potência di-

ferente. Porém, as potências ativas ( $W$ ) nominais dos equipamentos elétricos podem ser somadas diretamente, obtendo-se, assim, o nível de demanda ativa do circuito geral de acordo com esse somatório.

Foi nessa etapa do trabalho que foi feita a rotulação dos sinais de corrente obtidos pela medição dos circuitos gerais da casa, com base no período de operação de cada aparelho utilizando os respectivos sinais de potência ativa. De modo simplificado, essa etapa consistiu em atribuir um número inteiro para um determinado sinal de corrente, baseando-se na combinação de aparelhos ativos durante o período em que o sinal foi medido, de tal modo que, para cada combinação de aparelho encontrado na base, exista um número inteiro único que identifique essa combinação.

Essa etapa foi subdividida em 4 partes:


- Identificação de aparelhos conectados aos circuitos.
- Identificação do período ativo dos aparelhos.
- Numeração das combinações.
- Rotulação dos sinais.

Essas etapas são explicadas detalhadamente na Seção 8.4, a seguir.

## 8.4 METODOLOGIA PROPOSTA PARA A IDENTIFICAÇÃO DE EQUIPAMENTOS ELÉTRICOS LIGADOS UTILIZANDO CORRENTE ELÉTRICA

Como explicado anteriormente, a casa utilizada possui dois arquivos com as medições de potência dos circuitos gerais (Main 1 e Main 2) com taxa de amostragem igual a 1 Hz e 20 arquivos contendo as medições individuais de potência de cada aparelho, cada um amostrado a uma taxa de 1,3 Hz. No entanto, nenhuma informação sobre quais aparelhos estão ligados nos circuitos Main 1 ou 2 é fornecida.

Para obter tal informação, foi necessário realizar todas as combinações de somas de potência ativa nominal possíveis utilizando os vinte sinais individuais e comparando-os aos dois sinais contidos nos circuitos Main 1 e 2. A combinação com o menor erro da diferença quadrática média entre determinada combinação e o sinal do circuito geral a ser determinado indica os aparelhos existentes nesse circuito. A Figura 8.8 mostra o gráfico gerado a partir da soma dos sinais identificados com o sinal de potência real medido do circuito Main 2.



**Figura 8.8** Identificação dos aparelhos em Main 2.

Fonte: elaborada pelo autor.

Como pode ser visualizado na Figura 8.8, as combinações estimadas não coincidem exatamente com os sinais reais. Isso se explica pelo fato de que, para as combinações, foram utilizados valores nominais de potência ativa dos equipamentos, porém, o banco de dados disponibiliza os valores de potência aparente. Uma vez que para cargas ou circuitos com fatores de potência diferentes de 1 a potência aparente nominal sempre será maior que a potência ativa nominal (para o caso de fatores de potência predominantemente indutivos), existe essa pequena diferença. Porém, essa diferença não é ruim para este caso, uma vez que as demandas de potência ativa e aparente possuem os mesmos perfis para as mesmas cargas, como mostra a Figura 8.8. O que se busca nessa etapa é somente identificar quais aparelhos estão ligados em determinado instante de tempo.

Resumindo esse processo:

- Realizou-se a subamostragem dos sinais de potência dos Main 1 e 2 para que fosse possível obter o mesmo número de amostras entre a potência aparente nominal total e a corrente nominal geral.
- Para cada circuito geral (Main), calculou-se o erro médio quadrático das combinações por (8.7).

$$\text{Min}_k \{ (P_k - \text{Main}_i) \}^{1/2} \quad (8.7)$$

onde

- $k$  é um vetor de 20 posições que indica a presença dos respectivos aparelhos de cada circuito.
- $P_k$  é a potência ativa total (kW) de todos os aparelhos selecionados aleatoriamente para o cálculo.
- $Main_i$  é a potência aparente total (kVA) do circuito geral analisado.

Ao final dessa etapa, a Tabela 8.1 pôde ser construída para sumarizar as informações referente aos circuitos individuais dos aparelhos. É importante esclarecer que a nomenclatura dos circuitos apresentados na Tabela é a mesma contida nos arquivos da base REDD da casa número 3.

**Tabela 8.1** Informações referentes dos aparelhos identificados em cada circuito geral

Equipamento	Nome do circuito	Main	Equipamento	Nome do circuito	Main
2	Outlets_Unknown_2	1	12	Washer_Dryer_2	1
3	Lighting_1	2	13	Lighting_3	1
4	Electronics_1	1	14	Microwave	1
5	Refrigerator	2	15	Lighting_4	2
6	Disposal	1	16	Smoke detector	1
7	Dish_Washer_1	2	17	Lighting_5	2
8	Furnance	1	18	Bathroom	1
9	Lighting_2	2	19	Kitchen_Devices_1	1
10	Outlets_Unknown_3	1	20	Kitchen_Devices_2	1

Fonte: elaborada pelo autor.

### 8.4.1 Interpolação dos sinais individuais

Após determinar o circuito geral a que cada aparelho pertencia, foi necessário realizar a interpolação dos sinais individuais de potência para que fosse estimada a potência de cada aparelho nos *time stamps* que foram retirados na subamostragem dos sinais Main 1 e 2. Isso foi necessário por causa da diferença da frequência de amostragem entre os sinais de potência e corrente. Isso permitiu que houvesse mais amostras que pudessem ser utilizadas na rotulação das formas de onda das correntes.

Essa etapa consistiu na identificação dos *time stamps* em que cada aparelho estava ligado, com o intuito de não se fazer uma rotulação incorreta, identificando, por exemplo, um ruído como sinal ativo de um aparelho. Esse processo foi realizado da seguinte maneira:

1. Para cada sinal de potência, foi realizada a detecção das transições de borda do sinal (i.e., os *time stamps* no qual o sinal realiza a mudança do seu estado de operação) utilizando o algoritmo proposto por Duarte (2017).
2. Para cada sinal de potência, gerou-se um vetor com o mesmo tamanho, porém contendo apenas 0's e 1's, indicando se o aparelho estava ligado em determinado tempo.
3. Por fim, foram produzidos dois arquivos (um para cada Main), contendo uma matriz de tamanho  $i \times j$ , em que  $i$  indica quantidade de aparelhos conectados ao circuito geral e  $j$ , o número total de amostras, ou seja, essa matriz indica os *time stamps* nos quais os aparelhos de um determinado Main estão ligados.

#### 8.4.2 Numeração das combinações

As matrizes obtidas foram utilizadas para gerar um número inteiro de acordo com a combinação de aparelhos ligados em um determinado instante. Por exemplo, supondo que a atividade anterior tenha gerado a seguinte matriz  $p$ , para o circuito Main 1:

$$p = \begin{pmatrix} 1 & 1 & 1 & 0 \\ 0 & 1 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \end{pmatrix}$$

Cada elemento  $p_{i,j}$  indica se o  $i$ -ésimo aparelho estava ligado (1) ou desligado (0), no  $j$ -ésimo *time stamp*. A numeração é gerada de acordo com a conversão de uma coluna  $j$ , onde a combinação dos números presentes representa um binário, para o seu respectivo valor decimal. Por exemplo, a primeira coluna possui o aparelho 1 e 4 ligados. Essa informação é representada de forma binária por  $1001_2$ . Assim, o código atribuído a essa combinação de aparelhos é 9, de modo que a matriz  $p$  pode ser reduzida a um vetor  $i$  contendo números inteiros no intervalo  $[0, 2^K - 1]$ , onde  $K$  é a quantidade de aparelhos ligados em determinado circuito. Dessa maneira, para a matriz  $a$ , tem-se o seguinte vetor  $i$ :

$$i = [9, 12, 12, 3]$$

Para que esse vetor fosse utilizado para treinar os classificadores, ele foi recodificado para que os códigos atribuídos fossem normalizados entre a quantidade de combinações não repetidas encontradas, nesse caso, 3. Para este caso específico, utiliza-se um vetor máscara ( $m$ ) para se obter, em ordem crescente, a sequência das

combinações de 0 a 2, ou seja, 3 combinações. Assim, o vetor  $i$ , em um primeiro passo, é ordenado de forma crescente, seus códigos repetidos retirados e depois inserido no vetor máscara, obtendo-se  $m = [3, 9, 12]$ . No vetor máscara, é possível observar que os códigos 3, 9 e 12 ocupam as posições 0, 1 e 2, respectivamente. Assim, comparando as posições ocupadas pelos códigos no vetor  $m$  com as do vetor  $i$ , obtém-se o vetor auxiliar  $i_m = [1, 2, 2, 0]$ .

Ao final dessa etapa, o vetor  $i_m$  é gerado juntamente com o vetor de *time stamps*  $t_p$  correspondente, para posteriormente ser utilizado para rotular as formas de onda da corrente de determinado circuito geral Main.

### 8.4.3 Rotulação dos sinais de corrente

A última etapa, a rotulação dos sinais de corrente, consiste em identificar, de acordo com as combinações do passo anterior, os respectivos aparelhos ligados que solicitam determinada corrente do circuito geral.

No entanto, os *time stamps* dos dados de corrente,  $t_c$ , são diferentes dos dados de potência total,  $t_p$ , tendo os dados de corrente uma amostra a cada 9 ms e os de potência, a cada 1 s.

Dessa maneira, a estratégia utilizada para a identificação das combinações dos equipamentos elétricos armazenados em  $i_m$  e  $t_p$  no sinal de corrente nominal total dos Mains foi a seguinte:

- Buscar e encontrar em  $t_c$ , de ambos os Mains, o valor abaixo e mais próximo de *time stamp* referente ao *time stamp*  $t_p$  em que o sinal de corrente se encaixa no intervalo próximo ao do sinal de potência.
- Encontrada a combinação provável em 1, verificar se a soma das potências da combinação entre os equipamentos selecionados é igual à potência do Main em questão.
- Rotular a corrente com o código da combinação atribuído em  $i_m$ .

Para exemplificar melhor o passo 1, recorre-se à Figura 8.9, que traz 2 eixos de ordenadas e 2 eixos das abcissas. Os eixos das ordenadas se referem às grandezas elétricas e os eixos das abcissas, aos *time stamps* para cada grandeza. Dois *zooms* são fornecidos para a melhor visualização dos dados manipulados. Percebe-se que, no zoom superior, o seu primeiro *time stamp* ocorre em 3,5. Esse gráfico corresponde à amostragem de corrente. No zoom inferior, observa-se que o primeiro *time stamp* ocorre em 4. Esse gráfico corresponde à potência aparente do circuito geral.




Figura 8.9 Relação de amostragem entre os dados de corrente e potência aparente.

Fonte: elaborada pelo autor.

Ao analisarmos o gráfico como um todo, excluindo-se os *zooms*, vemos que, por mais que o *time stamp* da corrente comece antes que o da potência, essa corrente se encaixa no próximo intervalo da mudança de estado da potência. Assim, rotula-se essa corrente de acordo com os passos descritos anteriormente, relacionando-a a esse sinal de potência nesse *time stamp*.

Para uma melhor compreensão da metodologia proposta, a Figura 8.10 mostra o fluxograma do processo explicado nesta seção. As etapas dos fluxogramas pertencentes a cada parte da metodologia estão indicadas, bem como qual sinal é manipulado em cada uma delas.

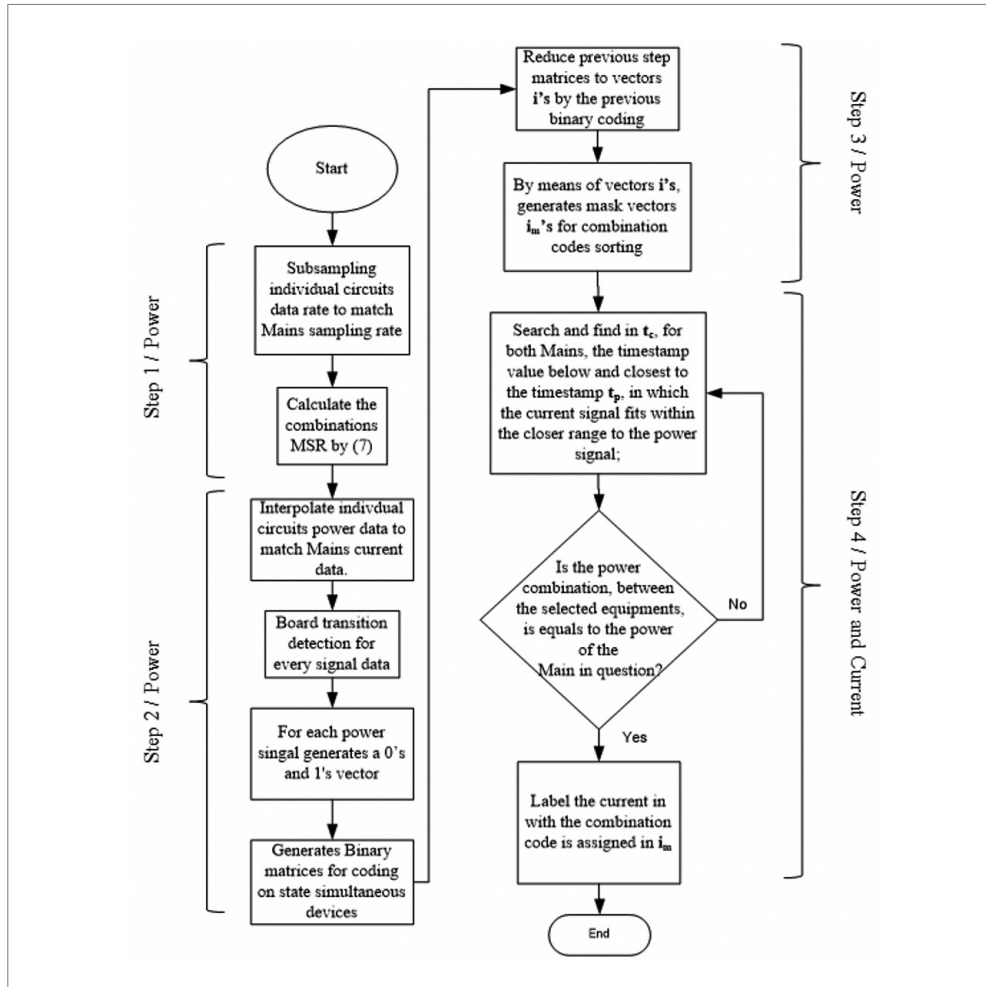


Figura 8.10 Fluxograma da metodologia de rotulação proposta.

Fonte: elaborada pelo autor.

Ao final desse processo, obtiveram-se as entradas X como sendo as formas de onda da corrente, e os seus respectivos rótulos r, indicando a classe de cada entrada, possibilitando, assim, a aplicação dos classificadores. A quantidade de amostras rotuladas e o número de combinações dos aparelhos em cada circuito Main é sumari- zado na Tabela 8.2.



**Tabela 8.2** Informações referentes a quantidade de sinais de corrente rotulados

Descrição	Main 1	Main 2
Número de aparelhos conectados	12	8
Número de combinações dos aparelhos	187	64
Formas de onda de corrente rotuladas	858.420	853.040

Fonte: elaborada pelo autor.

## 8.5 RESULTADOS E DISCUSSÕES

Nesta seção, são discutidos as métricas para a análise dos resultados e os resultados obtidos.

### 8.5.1 Métricas para o NILM

Para que seja feita a avaliação da estratégia utilizada para o NILM, algumas métricas são comumente utilizadas por pesquisadores. Nesta pesquisa, foram consideradas quatro dessas métricas para que se fossem avaliados os classificadores utilizados aqui. As métricas são *Recall* (8.8), *Precision* (8.9), *Accuracy* (8.10) e *F1-Score* (8.11) (Liu *et al.*, 2019):

$$Recall(R) = \frac{TP}{TP + FN} \quad (8.8)$$

$$Precision(P) = \frac{TP}{TP + FP} \quad (8.9)$$

$$Accuracy(ACC.) = \frac{TP + FN}{P + N} \quad (8.10)$$

$$F1-Score = \frac{2 \times P \times R}{P + R} \quad (8.11)$$

onde *Recall* é a taxa de positivos verdadeiros ou sensibilidade; TP significa *true-positives* (previu corretamente que o equipamento estava ligado); FP são os falso-positivos (previu equipamento ligado, mas estava desligado); FN são os falsos-negativos (equipamentos ligados, mas previstos como desligados). *Precision* se refere aos valores positivos previstos. *Accuracy* é a proporção de resultados reais em todos os casos. *F1-Score* é a média harmônica entre *precision* e *recall*.

### 8.5.2 Análise comparativa

Primeiramente, 858.420 exemplos para o Main 1 e 853.040 exemplos para o Main 2 foram gerados. Na realização do treinamento, utilizou-se o método de validação cruzada 10-*fold*. Para o treinamento, 22,5% dos dados foram aleatoriamente selecionados para a validação, 67,5% para o treinamento e 10% para o teste. A Tabela 8.3 resume esses dados. A Tabela 8.4 traz as estruturas dos modelos utilizados resumidamente.

**Tabela 8.3** Dados usados nesta pesquisa

	Main 1	Main 2
Conjunto para treinamento	579.433	575.802
Conjunto para validação	193.145	191.934
Conjunto para teste	85.842	85.304

Fonte: elaborada pelo autor.

**Tabela 8.4** Estrutura dos classificadores para NILM


Nome da rede	Número de camadas (sem incluir BN e camadas dropout)	Tipo
MLP	Camadas: 2 Camada densa: 4 Função de ativação: ReLu	ANN
LSTM	Camada LSTM: 3 Número da unidade: 32 Função de ativação: tanh	RNN
ConvNet	Camada 1D convencional: 6 Camada densa: 3 Função de ativação: ReLu	CNN

Fonte: elaborada pelo autor.

Os testes foram feitos em um PC com um processador Intel®Core™i7, 3,40 GHz X 4, 16GB de RAM e placa de vídeo®NVIDIA GEFORCE GTX1080 8G GPU. Os valores de acurácia e perdas para o treinamento e para a validação são mostrados nas Figuras 8.11 e 8.12, respectivamente.


Em cada época, a acurácia dos modelos no conjunto de validação será detectada quando esta for melhorada. Assim, os modelos com os melhores desempenhos no conjunto de validação e treino são selecionados como o modelo final. Os modelos finais e suas propriedades são mostrados nas Tabelas 8.5 e 8.6.

Os desempenhos médios por Main são mostrados nas Tabelas 8.7 e 8.8. A Tabela 8.9 mostra o desempenho médio geral para a casa 3. Em todas as tabelas, os melhores resultados estão em negrito.



**Figura 8.11** Valores de acurácia e perda durante o treinamento.

Fonte: elaborada pelo autor.



**Figura 8.12** Valores de acurácia e perda durante a validação.

Fonte: elaborada pelo autor.

Tabela 8.5 Modelos treinados e seus desempenhos

Tipo de RNA	Maior perda no conjunto de treinamento		Melhor acurácia no conjunto de teste		Época	
	Main 1	Main 2	Main 1	Main 2	Main 1	Main 2
ConvNet	0,144	0,054	0,944	0,984	144	140
LSTM	0,526	0,235	0,834	0,940	142	138
MLP	0,263	0,086	0,913	0,970	149	149

Fonte: elaborada pelo autor.

Tabela 8.6 Modelos treinados e seus desempenhos

Tipo de RNA	Tempo de treinamento		Número de parâmetros		Tamanho do modelo	
	Main 1	Main 2	Main 1	Main 2	Main 1	Main 2
ConvNet	330 min	310 min	121.819	105.952	1,5 MB	1,4 MB
LSTM	1.590 min	1.560 min	19.227	15.168	271,8 kB	222,7 kB
MLP	55 min	48 min	34.171	30.112	443 kB	394,5 kB

Fonte: elaborada pelo autor.

Tabela 8.7 Desempenho médio para o Main 1

Main 1 – Média				
RNA	R	P	ACC	F1-Score
ConvNet	96,37%	96,55%	99,40%	96,46%
LSTM	76,51%	85,57%	96,67%	79,69%
MLP	94,58%	95,18%	99,18%	94,87%

Fonte: elaborada pelo autor.

Tabela 8.8 Desempenho médio para o Main 2

Main 2 – Média				
RNA	R	P	ACC	F1-Score
ConvNet	98,24%	98,32%	99,78%	98,28%
LSTM	81,27%	88,33%	98,14%	84,33%
MLP	97,69%	97,54%	99,63%	97,58%

Fonte: elaborada pelo autor.

Tabela 8.9 Desempenho geral para a casa 3

Média geral				
RNA	R	P	ACC	F1-Score
ConvNet	97,30%	97,43%	99,59%	97,37%
LSTM	78,89%	86,95%	97,40%	82,01%
MLP	96,13%	96,36%	99,40%	96,22%

Fonte: elaborada pelo autor.

Pode se observar que os indicadores do Main 1 foram piores comparados aos do Main 2 para todos os classificadores testados. Isso pode ser explicado pela baixa quantidade de dados de alguns circuitos para os treinamentos dos classificadores, que tiveram dificuldades em aprender e reconhecer esses dispositivos durante os testes e validações. Já para o circuito Main 2, a menor quantidade de equipamentos a serem identificados e a maior quantidade de informações deles foram pontos facilitadores para que os classificadores pudessem obter melhores índices de desempenho.

Dentre todos os classificadores, pode-se observar que a LSTM obteve os piores resultados de desempenho. A ConvNet foi a rede neural com os melhores desempenhos. Apesar da rede neural MLP obter desempenho muito próximo a da ConvNet, sua desvantagem se encontra na necessidade do uso de técnicas de extração de características dos sinais analisados previamente, para somente depois poder se treinar a rede MLP. Isso não ocorre na ConvNet, uma vez que, em sua própria estrutura, essas características são extraídas de maneira a melhorar o desempenho da rede. Apesar disso, por sua estrutura mais simples, a rede MLP obteve o menor tempo para o treinamento do que as demais.

Pode-se concluir, então, que dentre as técnicas analisadas para a classificação no NILM, a rede neural convolucional ConvNet foi a que obteve os melhores índices de desempenho e se apresenta com uma ótima escolha para o NILM.

### 8.5.3 Análise comparativa com outros estudos

Como pôde ser visto pela Tabela 8.10, a rede convolucional ConvNet apresenta melhores desempenhos do que outros métodos publicados recentemente. Essa comparação é feita somente com pesquisas que investigaram o NILM para a casa 3 do banco de dados REDD. As pequenas diferenças que podem ser encontradas se devem, por exemplo, ao fato de alguns autores utilizarem apenas valores referentes a somente um dia, três dias ou apenas alguns dos equipamentos encontrados nos bancos de dados, enquanto os classificadores testados aqui utilizaram todos os equipamentos. Porém, pode-se observar que a acurácia da ConvNet foi superior a todos os casos encontrados na literatura. Além do mais, se analisarmos apenas os equipamentos pertencentes ao circuito Main 2, os indicadores de desempenho são superiores a todos os encontrados em outras pesquisas.

**Tabela 8.10** Comparação com outros estudos

	Classificador	Parâmetro manipulado	Técnica de extração de características	R (%)	P (%)	ACC (%)	F1-Score (%)
Liu <i>et al.</i> (2019)	FMCA	Power	Significance Threshold	95,58	97,74	97,90	97,83
Tabatabaei; Dick; Xu (2017)	MLCA	Power	Wavelet Transform	–	–	–	95,90
Kong <i>et al.</i> (2018)	HMM	Power	Iterative k-means	–	–	83,5	–
Bhotto; Makonin; Bajic (2016)	Aided Linear Integer Programming	Power	None	–	–	96,00	–
ConvNet geral	CNN	Current	Auto	97,30	97,43	99,59	97,37
ConvNet Main 2	CNN	Current	Auto	98,24	98,22	99,78	98,28

\*FMCA: Fuzzy multi-clustering algorithm; MLCA: multi-label classification algorithm; HMM: hidden Markov chains; CNN: convolutional neural network.

Fonte: elaborada pelo autor.

Além do mais, a seleção automática das características feita pela CNN pode melhorar a acurácia da classificação no NILM, uma vez que a CNN extrai as características mais críticas das diferentes combinações de equipamentos analisados.

Por fim, fica evidente que o uso de sinais de corrente elétrica aos de potência carregam maiores características dos sinais e este fato, evidentemente, foi crucial para a melhora no desempenho do classificador quando comparado a estudos passados.

## 8.6 CONCLUSÃO

Este estudo teve por objetivo a desagregação de cargas elétricas pelo método não intrusivo de monitoramento de cargas. Para isso, propôs-se utilizar dados de corrente elétrica em vez de potência para o treinamento e aprendizado dos classificadores, utilizando-se uma metodologia de rotulação. Três técnicas de classificação utilizando inteligência artificial de ponta foram testados: uma rede MLP, uma ConvNet e uma rede recorrente do tipo LSTM.

Os resultados mostram que a ConvNet foi mais apta a ser utilizada para casos de NILM, uma vez que possui em sua estrutura filtros que se adaptam para extrair automaticamente as características de sinais. Além disso, os sinais de corrente elétrica se mostraram mais indicados para esse tipo de classificação, uma vez que carregam mais características dos equipamentos elétricos do que sinais de potência.

Por fim, comparou-se a técnica testada que obteve os melhores indicadores estatísticos com outras técnicas publicadas em pesquisas anteriores, e a ConvNet foi, comprovadamente, o melhor modelo de classificador encontrado, cuja metodologia de rotulação proposta tem grande potencial para ser utilizada não só neste caso, mas em qualquer outro caso em que seja necessário rotular sinais diferentes, mas pertencentes à mesma fonte.

