

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**REDE NEURAL CONVOLUCIONAL APLICADA À
IDENTIFICAÇÃO DE EQUIPAMENTOS RESIDENCIAIS
PARA SISTEMAS DE MONITORAMENTO NÃO-
INTRUSIVO DE CARGA**

DEYVISON DE PAIVA PENHA

DM: 17/2018

UFPA/ITEC/PPGEE
Campus Universitário do Guamá
Belém – Pará – Brasil

2018

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DEYVISON DE PAIVA PENHA

**REDE NEURAL CONVOLUCIONAL APLICADA À
IDENTIFICAÇÃO DE EQUIPAMENTOS RESIDENCIAIS
PARA SISTEMAS DE MONITORAMENTO NÃO-
INTRUSIVO DE CARGA**

DM: 17/2018

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, da Universidade Federal do Pará, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica na Área de Computação Aplicada

UFPA/ITEC/PPGEE
Campus Universitário do Guamá
Belém – Pará – Brasil

2018

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**REDE NEURAL CONVOLUCIONAL APLICADA À IDENTIFICAÇÃO DE
EQUIPAMENTOS RESIDENCIAIS PARA SISTEMAS DE
MONITORAMENTO NÃO-INTRUSIVO DE CARGA**

AUTOR: DEYVISON DE PAIVA PENHA

DISSERTAÇÃO DE MESTRADO SUBMETIDA À
AVALIAÇÃO DA BANCA EXAMINADORA
APROVADA PELO COLEGIADO DO PROGRAMA
DE PÓSGRADUAÇÃO EM ENGENHARIA
ELÉTRICA DA UNIVERSIDADE FEDERAL DO
PARÁ SENDO JULGADA ADEQUADA PARA A
OBTENÇÃO DO GRAU DE MESTRE EM
ENGENHARIA ELÉTRICA NA ÁREA DE
COMPUTAÇÃO APLICADA COM ÊNFASE EM
INTELIGÊNCIA COMPUTACIONAL.

UFPA/ITEC/PPGEE
Campus Universitário do Guamá
Belém – Pará – Brasil

2018

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

- P399r Penha, Deyvison de Paiva
Rede neural convolucional aplicada à identificação de equipamentos residenciais para sistemas de monitoramento não-intrusivo de carga / Deyvison de Paiva Penha. — 2018
55 f. : il. color
- Dissertação (Mestrado) - Programa de Pós-graduação em Engenharia Elétrica (PPGEE), Instituto de Tecnologia, Universidade Federal do Pará, Belém, 2018.
Orientação: Profa. Dra. Adriana Rosa Garcez Castro
1. Redes Neurais Convolucionais. 2. Identificação de Equipamentos Residenciais. 3. Monitoramento Não-Intrusivo de Cargas. 4. NILM. I. Castro, Adriana Rosa Garcez, *orient.* II. Título
-

CDD 621.3

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

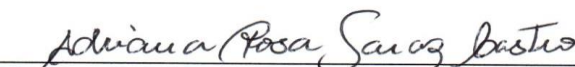
**“REDE NEURAL CONVOLUCIONAL APLICADA À
IDENTIFICAÇÃO DE EQUIPAMENTOS RESIDENCIAIS PARA
MONITORAMENTO NÃO-INTRUSIVO DE CARGA”**

AUTOR: DEYVISON DE PAIVA PENHA

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA.

APROVADA EM: 03/04/2018

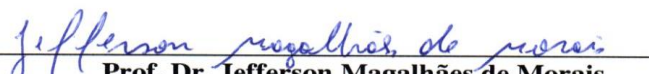
BANCA EXAMINADORA:



Prof.ª Dr.ª Adriana Rosa Garcez Castro
(Orientadora – PPGEE/UFPA)



Prof.ª Dr.ª Maria Emília de Lima Tostes
(Avaliadora Interna – PPGEE/UFPA)



Prof. Dr. Jefferson Magalhães de Moraes
(Avaliador Externo ao Programa – PPGCC/UFPA)

VISTO:

Prof.ª Dr.ª Maria Emília de Lima Tostes
(Coordenadora do PPGEE/ITEC/UFPA)

DEDICATÓRIA

Dedico este trabalho aos meus pais Dilson Penha e Ocione Penha, a minha esposa Yasmin e filha Ana Liz, por toda dedicação e amor necessário para que eu conseguisse alcançar meus sonhos e objetivos. Também agradeço pelo apoio em todos os momentos difíceis e por todo ensinamento que recebi deles.

AGRADECIMENTOS

Sou grato a Deus por tudo quanto Ele tem feito em minha vida e Sua infinita graça.

A minha orientadora Prof. Dra. Adriana Rosa Garcez Castro, pelo constante apoio, incentivo e direcionamento, essenciais para o desenvolvimento deste trabalho.

Aos companheiros do LCT, em especial aos Prof. Dra. Jasmine Priscyla Leite de Araújo e Prof. Dr. Fabrício José Brito Barros, pelo acolhimento, ajuda e apoio necessários para solucionar os problemas e dificuldades encontrados em minha trajetória acadêmica.

Agradeço aos meus pais e esposa por sempre me apoiar e fazer o possível e o impossível para que eu tivesse uma boa formação e alcançasse meus objetivos. Além disso me ensinaram a ser determinado e perseverante.

Ao Programa de Pós-Graduação em Engenharia Elétrica, PPGEE, pela oportunidade de realização de trabalhos em minha área de pesquisa.

À CAPES pela provisão da bolsa de mestrado.

Agradeço a todas as pessoas que acreditaram em mim.

“Confie no Senhor de todo o seu coração e não se apoie em seu próprio entendimento; reconheça o Senhor em todos os seus caminhos, e ele endireitará as suas veredas. Não seja sábio aos seus próprios olhos; tema ao Senhor e evite o mal. ” Provérbios 3:5-7

SUMÁRIO

1	INTRODUÇÃO	1
	1.1 DESCRIÇÃO GERAL DO PROBLEMA	1
	1.2 OBJETIVO GERAL	4
	1.3 OBJETIVOS ESPECÍFICOS	4
	1.4 ORGANIZAÇÃO DO TRABALHO	4
2	MONITORAMENTO NÃO INTRUSIVO DE CARGA	6
	2.1 INTRODUÇÃO	6
	2.2 ETAPAS DE UM SISTEMA NILM.....	7
	2.2.1 AQUISIÇÃO DE SINAL	7
	2.2.2 DETECÇÃO DE EVENTOS.....	9
	2.2.3 EXTRAÇÃO DE CARACTERÍSTICA	11
	2.2.4 IDENTIFICAÇÃO DOS EQUIPAMENTOS.....	13
	2.2.5 MÉTRICAS DE AVALIAÇÃO DE DESEMPENHO DE SISTEMAS NILM	14
3	REDES NEURAS CONVOLUCIONAIS	16
	3.1 INTRODUÇÃO	16
	3.2 REDE NEURAL CONVOLUCIONAL	17
	3.3 TREINAMENTO DE REDES NEURAS CONVOLUCIONAIS	23
	3.4 ESTADO DA ARTE DE REDES NEURAS PROFUNDAS APLICADAS AOS SISTEMAS NILM	24
4	SISTEMA PROPOSTO DE IDENTIFICAÇÃO DE EQUIPAMENTOS BASEADO EM CNN ...	28
	4.1 INTRODUÇÃO.....	28
	4.2 BANCO DE DADOS REED	30
	4.3 TREINAMENTO DA CNN	35
	4.4 RESULTADOS	41
5	CONCLUSÃO	46
	5.1 TRABALHOS PUBLICADOS.....	47
	5.2 TRABALHO FUTURO	47
	REFERÊNCIAS	48

LISTA DE ILUSTRAÇÕES

Figura 1 Consumo em 2016 Fonte EPE	2
Figura 2 Sistema de eletricidade residencial com Sistema NILM integrado	7
Figura 3 Exemplo de Carga agregada (Figueiredo, 2011).	8
Figura 4 Detecção de Eventos através de janelamentos (Batra et al., 2015).	11
Figura 5 Ilustração da arquitetura de uma CNN. (Vargas, 2016)	17
Figura 6 Extração de característica – Detecção de bordas.	18
Figura 7 Exemplo da utilização de um padding	19
Figura 8 Representação gráfica da funcionalidade do ReLU. (Hijazi, 2015)	20
Figura 9 Max-Pooling com um filtro de tamanho 2x2 e tamanho do passo (Stride) igual a 2. (Hijazi, 2015)	21
Figura 10 Processamento de uma camada totalmente conectada. (Hijazi, 2015)	22
Figura 11 Sistema de identificação de equipamentos baseado em CNN	29
Figura 12 Exemplo de carga medida do equipamento geladeira no decorrer de um 1h .	32
Figura 13 Exemplo de carga medida do equipamento micro-ondas no decorrer de um 1h.	32
Figura 14 Exemplo de carga medida do equipamento fogão no decorrer de um 1h.	33
Figura 15 Exemplo de carga medida do equipamento forno no decorrer de um 1h.	33
Figura 16 Exemplo de carga medida do equipamento lava-louças no decorrer de um 1h.	33

Figura 17 Exemplo de carga medida do equipamento ar-condicionado no decorrer de um 1h.....	34
Figura 18 Exemplo de carga medida do equipamento lava-louças no decorrer de um 1h.	34
Figura 19 Arquitetura da CNN	39
Figura 20 Treinamento da rede CNN Utilizando Validação Cruzada	40
Figura 21 Matriz de confusão para os dados de Teste.	42
Figura 22 Comparativo entre equipamento geladeira e lava-louça.....	43
Figura 23 Comparativo entre micro-ondas, fogão e forno	44

LISTA DE TABELAS

Tabela 1 Tipos de equipamentos elétricos	10
Tabela 2 Equipamentos do banco de dados REED	31
Tabela 3 Divisão dos dados	35
Tabela 4 Arquitetura 1 com taxa de aprendizado igual a 0,01.....	36
Tabela 5 Arquitetura 2 com taxa de aprendizado igual a 0,01.....	36
Tabela 6 Arquitetura 3 com taxa de aprendizado igual a 0,3.....	37
Tabela 7 Arquitetura 4 com taxa de aprendizado igual a 0,3.....	37
Tabela 8 Arquitetura 5 com taxa de aprendizado igual a 0,01.....	37
Tabela 9 Arquitetura 6 com taxa de aprendizado igual a 0,05.....	38
Tabela 10 Arquitetura 7 com taxa de aprendizado igual a 0,01.....	38
Tabela 11 Desempenho das arquiteturas em relação a Acurácia	38
Tabela 12 Resultado para os dados de Teste.....	41
Tabela 13 Comparação entre Sistemas apresentados na literatura.....	45

LISTA DE ABREVIATURAS E SIGLAS

- Ar: Ar-condicionado
- CNN: Redes Neurais Convolucionais
- DWT: Wavelet Discreta
- EPE: Empresa de Pesquisa Energética
- F: F-score
- Fr: Forno
- FHMM: Factorial Hidden Markov Model
- FN: Falso negativo
- FP: Falso positivo
- GE: Geladeira
- GRU: GatedRecurrent Unit
- k-NN: k-nearest neighbors
- Ls: Lavadora/secadora
- LSTM: Long Short Term Unidades
- LI: Máquina de lavar louça
- MAE: Mean absolute error
- Mi: Micro-ondas
- MLP: Perceptron de Múltiplas Camadas
- NILM: Non- Intrusive Load Monitoring
- Prec: Precisão
- REDD: Reference Energy Disaggregation Data set
- ReLU: Rectified Linear Unit

RMS: Root mean square

Sens: Sensitividade

STFT: Transformação de Fourier de curta duração

SVM: Support Vector Machine

TN: True negative

TP: True positive

RESUMO

Este trabalho apresenta a proposta de uma nova metodologia para identificação de equipamentos residenciais em sistemas de Monitoramento Não-Intrusivo de cargas. O sistema é baseado em uma Rede Neural Convolucional para classificação dos equipamentos, que utilizam, diretamente como entradas para o sistema, os dados do sinal transitório de potência de 7 equipamentos obtidos no momento em que estes são ligados em uma residência. A metodologia foi desenvolvida usando dados de um banco de dados público (REED) que apresenta dados coletados a uma baixa frequência (1 Hz). Os resultados obtidos na base de dados de testes apresentam acurácia superior a 90%, indicando que o sistema proposto é capaz de realizar a tarefa de identificação, além disso os resultados apresentados são considerados satisfatórios quando comparados com os resultados já apresentados na literatura para o problema em questão.

Palavras-chaves: Redes Neurais Convolucionais, Identificação de Equipamentos Residenciais, Monitoramento Não-Intrusivo de Cargas, NILM.

ABSTRACT

This research presents the proposal of a new methodology for the identification of residential equipment in non-intrusive load monitoring systems. The system is based on a Convolutional Neural Network to classify residential equipment, which uses directly as inputs to the system, the transient power signal data of 7 equipment obtained at the moment they are connected in a residence. The methodology was developed using data from a public database (REED) that presents data collected at a low frequency (1 Hz). The results obtained in the test database show an accuracy of more than 90%, indicating that the proposed system is capable of performing the task of identification. In addition, the results presented are considered satisfactory when compared with the results already presented in the literature for the problem in question.

Keywords: Convolutional Neural Networks, Identification of Residential Equipment, Non-intrusive Load Monitoring, NILM.

1 INTRODUÇÃO

1.1 Descrição geral do problema

A redução e racionalização do consumo de energia elétrica vêm cada vez mais se tornando prioridades, não só para os consumidores residenciais, mas também para as concessionárias de energia e governo, devido ao crescimento exponencial da demanda por energia. Considerando esta preocupação, que é mundial, diversas pesquisas têm surgido na literatura com o esforço para desenvolver soluções tecnológicas que resolvam esse problema (Zoha et al., 2012). Estima-se que na União Europeia, o setor residencial representa 30% do consumo de eletricidade, enquanto nos USA é responsável por mais de um terço de todo o uso de eletricidade no país, além disso prevê-se que as demandas mundiais de energia dobrarão até o final de 2030 com implicações negativas para o meio ambiente (por exemplo, emissões de CO₂).

Segundo a Empresa de Pesquisa Energética (EPE) que é uma empresa pública vinculada ao Ministério de Minas e Energia, no Brasil, no ano de 2016 o setor residencial correspondeu a 29% do consumo de energia no país, como pode ser visto na Figura 1. Segundo esse balanço da EPE, os consumidores residenciais representam 85,9% do número de consumidores em todo o território nacional. Dessa forma, o desenvolvimento de soluções tecnológicas voltadas a um consumo mais eficiente nesse segmento podem trazer um impacto positivo na eficiência energética do país.




Figura 1 Consumo em 2016 Fonte EPE

O fornecimento de informações sobre o consumo de eletricidade é uma maneira eficaz de induzir um comportamento mais eficiente em relação ao consumo de energia nas residências familiares (Klemenjak, 2016; Makonin, 2013). Em particular, esta informação mostra-se adequada quando é detalhada e fornecida ao consumidor, em tempo hábil, contendo informações sobre o consumo de aparelhos individuais na residência (Klemenjak, 2016; Makonin, 2013).

Os serviços públicos, cada vez mais obrigados (e motivados) pelos decisórios políticos a ajudar seus clientes a economizar eletricidade, estão altamente interessados em fornecer respostas de consumo específico do aparelho como um serviço para seus clientes (por exemplo, sob a forma de recomendações de economia automáticas). Os dados necessários para fornecer esse acompanhamento poderiam ser obtidos através de sensores que monitorariam o consumo de eletrodomésticos na casa. Porém, a implantação de uma infraestrutura em que cada equipamento está associado a um sensor dentro de uma residência acaba se tornando dispendiosa e pesada.

Considerando então a crescente preocupação em relação ao consumo residencial de energia, preocupação esta que é mundial, pesquisas na área de Monitoramento Não Intrusivo de Carga, do inglês Non- Intrusive Load Monitoring

(NILM), vêm se destacando. As pesquisas nesta área tiveram início em 1992 com a apresentação do trabalho de George W. Hart (1992) e desde então muitos trabalhos vêm sendo apresentados, focando as diversas etapas de um sistema NILM.

Um sistema NILM possui como principal objetivo exatamente aferir a carga agregada de uma residência através de um único sensor, colocado no medidor central fora da residência. A partir da carga agregada, medida durante um período de tempo, pode-se, através de softwares específicos, realizar a identificação dos equipamentos elétricos em funcionamento e obter o consumo individual dos mesmos, além de se obter o horário de funcionamento de cada equipamento (Hart, 1992). Estas informações podem então ser utilizadas pelos consumidores para tomarem atitudes que visem à redução e racionalização de seu consumo, garantido assim uma maior eficiência energética.

Atualmente as Redes Neurais Profundas vêm recebendo cada vez mais atenção pela comunidade acadêmica e isto se deve principalmente pelos recentes resultados, com melhorias significativas, na área de visão computacional, reconhecimento de imagens e processamento de sinais. Além dos resultados promissores para problemas envolvendo a aplicação de dados 2-D, alguns autores vêm desenvolvendo pesquisas na área de aplicação das redes neurais profundas em problemas com dados 1-D, tais como dados de séries temporais (Wang, 2015; Zheng et al., 2014; Lecun et al., 1995; Lee et al., 2009; Långkvist, 2014; Zheng et al., 2016). Devido a este avanço na área, alguns pesquisadores têm procurado aplicar as Redes Neurais Profundas para problemas de identificação de equipamentos em sistemas NILM. Alguns trabalhos têm sido apresentados utilizando Long Short Term Memory (LSTM), Rede Neural Auto-encoder e Rede Neural Convolutiva (do inglês

Convolutional Neural Network - CNN) (Kelly, 2015; Nascimento, 2016; HE W., 2016; Leen et al., 2018), com resultados bastante satisfatórios.

1.2 Objetivo geral

Considerando a vantagem das redes CNN para problemas de classificação e os bons resultados já apresentados na literatura envolvendo estas redes para o problema NILM, este trabalho tem como objetivo principal apresentar os resultados obtidos de uma nova metodologia desenvolvida, baseada em Redes Neurais Convolucionais, para identificação de equipamentos em sistemas de monitoramento não-intrusivo de cargas.

1.3 Objetivos específicos

Considerando o objetivo geral, esta proposta tem como objetivos específicos:

- Utilizar a base de dados pública *Reference Energy Disaggregation Data set* (REDD) para desenvolvimento e teste do sistema proposto de identificação de equipamentos.
- Desenvolvimento de um algoritmo para extração de transitórios de potência de cada equipamento a partir da carga agregada medida e disponibilizada na base de dados REDD.
- Desenvolvimento do sistema de identificação a partir das medidas de transitório de potência dos equipamentos, que servirão de entrada para a Rede neural Convolucional.

1.4 Organização do trabalho

Além deste capítulo introdutório, esta proposta está estruturada como segue:

Capítulo 2 - Apresenta uma visão geral sobre o monitoramento não intrusivo de carga, cenário atual sobre medição inteligente no Brasil, estado-da-arte sobre técnicas para monitoramento e identificação de equipamentos para NILM.

Capítulo 3 - Apresenta uma visão geral sobre Redes Neurais Convolucionais e suas principais características e habilidades. Apresenta também o estado-da-arte referente às técnicas de redes neurais profundas aplicadas ao monitoramento não intrusivo de carga.

Capítulo 4 - Apresenta a metodologia proposta para reconhecimento de equipamentos utilizando redes neurais Convolucionais, além de apresentar os resultados já alcançados.

Capítulo 5 - Apresenta as conclusões e considerações finais.

2 MONITORAMENTO NÃO INTRUSIVO DE CARGA

2.1 Introdução

O Monitoramento não-intrusivo de carga (NILM) é um método de monitoramento de energia elétrica que visa estimar o consumo dos aparelhos em uma residência de uma forma não intrusiva, sendo o monitoramento realizado através de um único dispositivo de medição, comumente conectado ao quadro geral de uma residência ou logo após o medidor da concessionária de energia, onde é possível fazer uma análise aprofundada dos dados medidos, como a forma de onda da corrente, tensão e potência dos aparelhos que estão conectados ao circuito elétrico na residência (Hart, 1992). Assim, o monitoramento não intrusivo de equipamentos fornece um método de extração de informação das cargas individuais de cada equipamento de uma forma muito conveniente e eficaz se comparadas com os meios tradicionais de colocar sensores em cada um dos equipamentos de forma individual (método intrusivo) (Shaw et al., 2008).

A partir da carga agregada, medida durante um período de tempo, pode-se, aplicando determinadas técnicas, realizar a identificação dos equipamentos elétricos em funcionamento e obter o consumo individual dos mesmos, além de se obter o horário de funcionamento de cada equipamento (Faustine et al., 2017). Estas informações podem ser utilizadas pelos consumidores residenciais para tomarem atitudes que visem à redução e racionalização de seu consumo, garantido assim uma maior eficiência energética. Além desta principal funcionalidade dos sistemas NILM, destacam-se também: possibilidade de identificação de comportamento fora do padrão das cargas; possibilidade de detecção de falhas e furtos de energia; possibilidade do uso da informação da carga desagregada pelas concessionárias de energia elétrica, que poderão promover auxílio aos seus clientes no processo de identificação de desperdício durante o

horário de ponta, auxiliando assim para redução de consumo durante esses períodos e oferecendo para isso incentivo aos consumidores (Batra et al., 2015).

2.2 Etapas de um Sistema NILM

Os sistemas NILM se baseiam em quatro etapas principais: aquisição do sinal, detecção de eventos, extração de características e identificação dos equipamentos.

A Figura 2 apresenta o esquema com as 4 etapas principais de um sistema NILM.

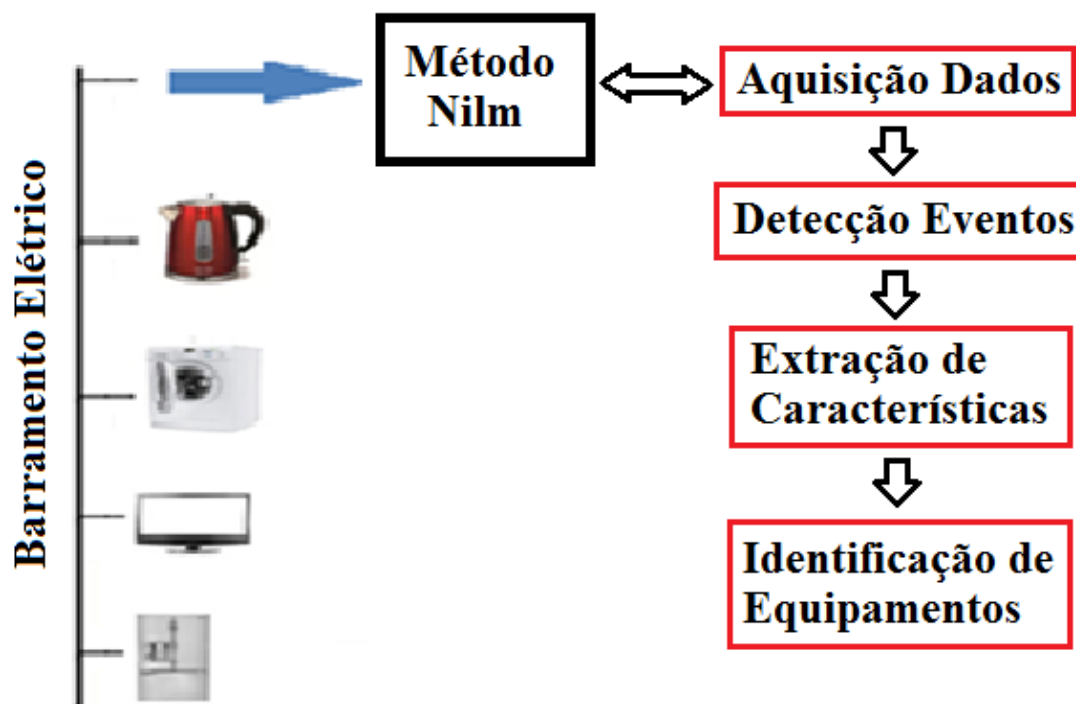


Figura 2 Sistema de eletricidade residencial com Sistema NILM integrado

2.2.1 Aquisição de Sinal

Esta é a primeira etapa de qualquer sistema NILM e envolve a aquisição da carga agregada a uma taxa adequada de medição para que os padrões distintos de carga possam ser identificados. Um exemplo de carga agregada medida em uma residência pode ser visto na Figura 3.




Figura 3 Exemplo de Carga agregada (Figueiredo, 2011).

Os dados agregados podem ser obtidos a partir de medições de um sensor único instalado no painel de entrada de energia das residências monitoradas, sendo este painel geralmente localizado fora da residência. Os medidores podem ser de alta frequência ou baixa frequência. Quando a taxa de amostragem está em uma faixa de 10MHz a 100MHz temos um medidor de alta frequência, sendo geralmente medidores customizados e caros devido ao hardware sofisticado. Os medidores que trabalham com uma baixa taxa de amostragem, inferior a 1 HZ, são caracterizados como medidores de baixa frequência (Zoha et al., 2012).

Considerando a implantação de Redes Inteligentes (*Smart Grids*), a instalação em massa dos Medidores Inteligentes (*Smart Meters*) pode ser uma grande incentivadora das pesquisas na área de sistemas NILM. Os medidores inteligentes podem fornecer informações de consumo e demanda de energia elétrica em intervalos programáveis com resolução de até uma medição por segundo, o que é suficiente para identificar o consumo desagregado de muitos equipamentos em uma instalação, dependendo do algoritmo de identificação usado e das características do sinal extraídas e usadas para este processo de identificação.

Existem alguns exemplos ao redor do mundo que mostram o desenvolvimento de projetos voltados a implantação de *Smart Cities*. Em Padova, Itália, a Universidade de Padova, em colaboração com o município da cidade, iniciou um

projeto chamado Padova *Smart City*, que é um exemplo de cooperação privada e pública para a execução de uma cidade inteligente. De acordo com este projeto, vários tipos de sensores são colocados em postes de iluminação que estão conectados à Internet através de uma rede sem fio a fim de coletar dados ambientais, como o nível de CO₂, a temperatura, a umidade do ar, as vibrações, o ruído e iluminação pública. Embora este seja um projeto, ele inclui uma experiência prática de cidade inteligente (Cenedese et al., 2014).

No Brasil, a adesão ao *smart grid* caminha em passos mais lentos devido aos altos custos de implementação. Concessionárias como a Light e AES Eletropaulo, por exemplo, já possuem projetos na área. No entanto, tudo ainda ocorre em baixa escala. Isso ocorre devido a política governamental ou das distribuidoras de energia estarem focadas, principalmente, no combate ao furto e na inadimplência (Leite, 2013). Existem alguns projetos pilotos acontecendo no Brasil que podem contribuir para a criação de uma política adequada a implantação massiva desta nova tecnologia, cita-se o exemplo da Cidade de Búzios, no Rio de Janeiro (Vilaca et al., 2014).

2.2.2 Detecção de Eventos

Na fase de detecção de eventos o sistema NILM detecta o estado das operações do aparelho a partir do sinal agregado. As mudanças ON/OFF nos níveis de potência são denominadas de transitório e o intervalo entre estas mudanças representam um evento. Essa etapa envolve um processo complexo por causa de diferentes tipos de aparelhos que se encontram em uma residência, além dos diferentes status em que podem estar. A Tabela 1 apresenta os diferentes tipos de equipamento em uma residência.

Com base nas diferentes estratégias de detecção de eventos, as abordagens NILM atuais podem ser classificadas em: baseadas em eventos e baseadas em estado (Faustine et al., 2017).

Tabela 1 Tipos de equipamentos elétricos

Nome	Descrição
Aparelhos de consumo permanente	Como exemplo, temos alarmes de incêndio e alguns equipamentos dedicados às comunicações, sendo que estes aparelhos funcionam 24 horas por dia, cinco dias por semana, sendo potência ativa e reativa aproximadamente constantes.
Aparelhos com funcionamento On (Ligado) /Off (desligado)	Considerarem-se equipamentos de utilização esporádica tal como torradeiras ou lâmpadas.
Máquinas de estados finitos	Nesta categoria são incluídos os equipamentos que passam por um número definido de estados de transição e em que o seu ciclo de funcionamento é repetido frequentemente ao longo de um período de tempo. Como exemplos desta categoria podem enunciar-se as máquinas de lavar e secar roupa, ou máquina de lavar louça.
Aparelhos de consumo continuamente variável	São os equipamentos de utilização aleatória, sem padrão definido de uso. Furadeiras são exemplos nesta categoria.

As abordagens baseadas em eventos focam as bordas de transição do estado geradas pelos aparelhos e usam o algoritmo de detecção de mudanças para identificar o início e o fim de um evento (Karim, 2013; Yung, 2013). A tarefa do algoritmo de detecção de mudanças é detectar mudanças em dados de carga agregados de séries temporais devido a um ou mais dispositivos sendo ligados / desligados ou alterando seu

estado. Uma revisão dos algoritmos de detecção de eventos usados na literatura NILM é apresentada em (K. D. Anderson, 2012).

Uma das primeiras metodologias desenvolvidas para detecção de eventos foi apresentada em (Provost, 1998), sendo que esta metodologia se baseia em uma janela de análise que varre toda a carga agregada medida, sendo possível identificar a ocorrência de um evento quando a diferença entre a média final (média da margem direita) e a média inicial (média da margem esquerda) da janela alcançar um determinado valor limiar previamente estabelecido, conforme pode ser observado na Figura 4.




Figura 4 Detecção de Eventos através de janelamentos (Batra et al., 2015).

2.2.3 Extração de característica

Com os eventos detectados, ocorre então a extração de características ou assinaturas elétricas. As assinaturas elétricas representam um conjunto de características da tensão, corrente ou potência para um determinado equipamento, e podem ser divididas em macroscópicas e microscópicas. As características macroscópicas (baixa frequência) devem ser obtidas a partir de um período de amostragem de até uma amostra por ciclo (1 Hz). As baixas frequências aplicam-se em vários métodos, podendo ser utilizada para aquisição da potência ativa, potência reativa e valores eficazes da

tensão e corrente (Carvalho, 2013). As características microscópicas (alta frequência) devem ser obtidas utilizando um período de amostragem acima de uma amostra por ciclo (1 Hz)

As características extraídas podem ser enquadradas em duas principais categorias: de estado estacionário e de estado transiente. A potência real e reativa são as características de estado estacionário mais utilizadas em sistemas NILM. Em trabalhos como em (Najmeddine et al., 2008) e (Kato, 2009), tem-se que a potência real é utilizada para desagregar os aparelhos, tendo resultados com ótima precisão. No entanto, como desvantagem tem-se a facilidade destes métodos em se obter erro de identificação quando existem aparelhos com consumo de potência real semelhante. Nos trabalhos (COLE A., ALBICKI A., 2000) e (SUZUKI K., 2008) várias assinaturas foram usadas para superar as limitações de se utilizar apenas a potência real e reativa. Em (COLE A., ALBICKI A., 2000) os autores utilizaram a potência real, potência reativa, potência aparente, corrente RMS e fator de potência como um conjunto de assinaturas para a identificação de algumas cargas de iluminação no laboratório. A análise harmônica, por outro lado, também vem sendo utilizada para identificação de equipamentos e a desagregação de carga. Diversos trabalhos de investigação, como em (Li J, 2012), (Lee et al., 2004) e (Lam H.Y., 2007), foram realizados utilizando as características harmônicas das cargas. Outros trabalhos podem ser encontrados em (Patel et al., 2007; Kelly, 2015) em que diferem em suas abordagens na utilização de filtros e Deep Learning respectivamente.

O comportamento transiente da maioria dos aparelhos elétricos é distinto, por conseguinte, esta característica se faz adequada para a identificação de carga (Parson, 2016). Um estudo relativo ao uso de assinatura transitória foi feito em (Lee K.D. et al., 2005). A identificação de carga foi analisada utilizando o tempo de resposta transitória e

energia transitória através da transformação Wavelet Discreta (DWT) e transformação de Fourier de curta duração (STFT). Em (Cole A., Albicki A., 2000) os autores usaram os picos de potência da fase de transitório para detectar equipamentos. Essa abordagem oferece bom desempenho para desagregação de carga, mas é específica por equipamento, exigindo que os transientes sejam repetitivos e exigindo alta taxa de amostragem. No trabalho em (Dong, H., 2013) o autor aponta algumas desvantagens de se utilizar somente os eventos de transitório de ligação para modelar uma carga, pois cargas resistivas não possuem transitório de ligação significativo. Os modelos baseados em transitórios de ligação não conseguem identificar todo o processo das cargas, pois se concentram apenas no momento de ligação e necessitam de dados coletados em alta frequência, o que gera a necessidade de alteração do hardware dos medidores existentes, o que aumenta em muito os custos do processo NILM, especialmente em residências.

2.2.4 Identificação dos equipamentos

Nesta etapa, a assinatura extraída dos aparelhos é analisada para classificar os estados específicos de um aparelho e estimar o consumo de energia correspondente. Os algoritmos de aprendizado são usados para aprender os parâmetros do modelo enquanto os algoritmos de inferência são empregados para inferir os estados do aparelho através dos dados de energia agregados e estimar o consumo de energia correspondente. Os algoritmos de aprendizagem em NILM podem ser supervisionados ou não supervisionados (Faustine et al., 2017).

As técnicas NILM supervisionadas requerem uma fase de treinamento em que tanto os dados agregados quanto o consumo individual de aparelhos podem ser utilizados. Nesse caso, para a aprendizagem de um modelo capaz de identificar corretamente os equipamentos os dados dos aparelhos medidos ou as observações

devem ser rotulados. O processo de coleta desses dados é custoso, demorado e limita a escalabilidade dos sistemas NILM (Li J, 2012). Vários trabalhos existentes se concentraram em técnicas de aprendizagem supervisionada, como Support Vector Machine (SVM) (Lee et al., 2004; Lam H.Y., 2007), K – Vizinho mais Próximo (k-NN) (Wong, 2013) e algumas formas de HMM (Zico Kolter e Tommi, 2012; Stephen, 2015).

Ao contrário do modelo supervisionado, as técnicas não supervisionadas não requerem pré-treinamento para rotulação dos dados e, portanto, se tornam adequadas para aplicação NILM em tempo real. As abordagens NILM não supervisionadas não requerem dados individuais do aparelho, os parâmetros dos modelos são captados apenas usando a carga agregada, sem a intervenção do usuário (Kelly, 2015). Porém, nessa técnica, assim como no método supervisionado, para se chegar a etapa de identificação de equipamentos, acaba sendo um processo custoso e que demanda um grande esforço computacional.

2.2.5 Métricas de Avaliação de desempenho de sistemas NILM

Para avaliação do desempenho de sistemas NILM, algumas métricas de avaliação vêm sendo geralmente utilizadas no contexto de sistemas NILM, sendo elas:

Matriz de confusão: Permite uma medida efetiva do modelo de classificação, apresentando o número de classificações corretas versus as classificações preditas para cada classe, sobre um conjunto de exemplos (Provost, 1998). A diagonal principal apresenta para cada classe o número de classificação corretas e a porcentagem que este número representa dentro do número completo de dados da classe.

Acurácia: apresenta a porcentagem de amostras positivas e negativas classificadas corretamente sobre a soma de amostras positivas e negativas. Sendo verdadeiro positivo (True positive – TP) o número de vezes em que um equipamento é classificado corretamente como ON; verdadeiro negativo (True negative – TN) o número de vezes em que um equipamento é classificado corretamente como OFF; Falso positivo (FP) o número de vezes em que um equipamento é classificado incorretamente como ON e Falso negativo (FN) o número de vezes em que um equipamento é classificado incorretamente como OFF. A acurácia pode ser calculada como:

$$\text{Acurácia} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (1)$$

Sensitividade: indica a porcentagem de amostras positivas classificadas corretamente sobre o total de amostras positivas e pode ser calculada como:

$$\text{Sensitividade} = \frac{\text{TP}}{\text{TP} + \text{FN}} = \frac{\text{TP}}{\text{Positive}} \quad (2)$$

Precisão: indica a porcentagem de amostras positivas classificadas corretamente sobre o total de amostras classificadas como positivas e pode ser calculada como:

$$\text{Precisão} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3)$$

F-score: É uma média ponderada de precisão e sensibilidade e pode ser calculada como:

$$\text{F – score} = \frac{2 * (\text{Precisão} * \text{Sensitividade})}{(\text{Precisão} + \text{Sensitividade})} \quad (4)$$

3 REDES NEURAIIS CONVOLUCIONAIS

3.1 Introdução

O aprendizado profundo (Deep Learning) é um tipo de aprendizado automático, sendo uma subárea de Aprendizagem de Máquina que investiga técnicas para simular o comportamento do cérebro humano em tarefas como reconhecimento visual, reconhecimento de fala e processamento de linguagem natural. O termo "profundo" refere-se ao número de camadas intermediárias na rede: quanto mais camadas, mais profunda a rede. As redes neurais tradicionais contêm geralmente 2 ou 3 camadas, enquanto as redes profundas podem ter centenas. (Lecun et al., 2015)

No que diz respeito as aplicações envolvendo tarefas de classificação, esta área tem se beneficiado significativamente com o advento das Redes Neurais Convolucionais (CNN). No geral, os métodos apresentados na literatura para classificação de sinais baseiam-se no uso de recursos específicos para extração de características dos sinais a serem classificados para que estas sirvam de entrada para o sistema classificador. A grande vantagem da rede CNN para o problema de classificação diz respeito à capacidade que esta possui de aprender estas características por ela mesma, eliminado assim a necessidade de uma fase anterior de extração.

Devido as vantagens do uso das redes CNN para o problema de classificação, esta foi a rede neural profunda escolhida para desenvolvimento do sistema proposto e para um bom entendimento do sistema desenvolvido, a seguir, serão apresentados os fundamentos teóricos sobre esta rede.

3.2 Rede Neural Convolucional

Uma Rede Neural Convolucional (CNN) pode ser considerada como uma variante da rede neural *Perceptron* de Múltiplas Camadas (MLP). Em vez de usar camadas ocultas totalmente conectadas, como a MLP, a arquitetura de uma CNN se baseia na alternância de camadas de convolução – camada que dá o nome a rede; e camadas de *pooling*. Cada camada possuirá um conjunto de filtros, também conhecido como *kernel*, que serão responsáveis por extrair características locais (*local features*) de uma entrada. Com isso, diversos mapas de convolução e *pooling* podem ser criados, contendo diversas características específicas como: bordas, intensidade de cor, contornos e formas. Cada mapa de características possuirá um conjunto de pesos compartilhado, que diminui a complexidade computacional da rede (Vargas, 2016). Por último, temos a camada responsável pelo processo de classificação, que possui a camada totalmente conectada, que conecta todos os neurônios da camada anterior a ela aos neurônios de saída, conforme ilustra a Figura 5.

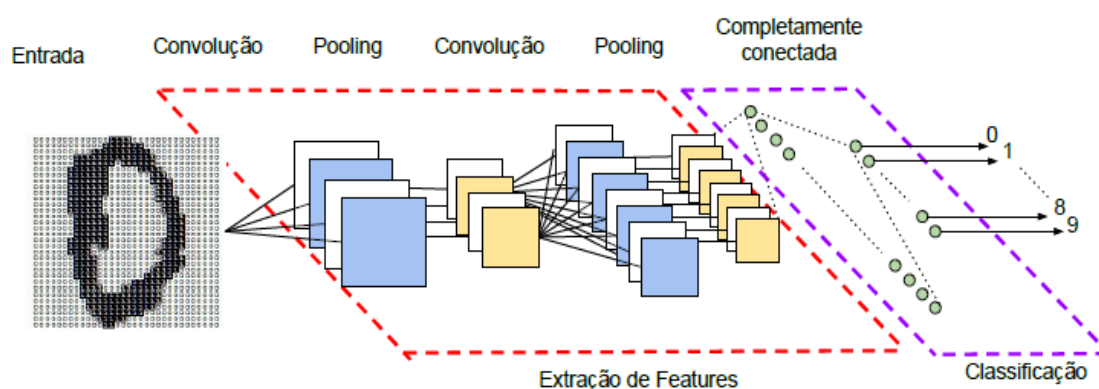


Figura 5 Ilustração da arquitetura de uma CNN. (Vargas, 2016)

Desta forma, a estrutura de uma CNN é formada basicamente por:

- **Camada de Convolução:** Uma camada de convolução consiste de neurônios que se conectam a sub-regiões das imagens de entradas ou saídas da camada

anterior, onde é aplicado um conjunto de filtros convolucionais, que são responsáveis por varrer toda a imagem e extrair mapas de recursos. Cada filtro possui um conjunto de pesos, assim, diferentes filtros aprendem diferentes tipos de características da entrada. A Figura 6 é um exemplo de detecção de borda vertical, onde uma entrada 6x6, com valores em escala de cinza, é varrida a cada um passo por um filtro de tamanho 3, ou seja, com um *stride* de 1, sendo o *stride* uma peça básica vital para a construção dessa camada, indicando a forma como o filtro avança sobre a entrada, se 1 a 1 ou 2 a 2, etc (Lecun, 2015).

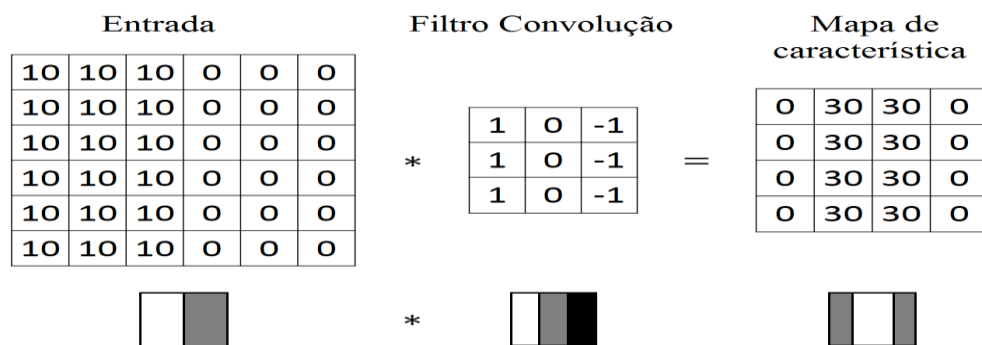


Figura 6 Extração de característica – Detecção de bordas.

Além do *stride*, outra técnica bastante empregada na camada de convolução é o *padding*, que adiciona zeros ao redor das bordas da imagem, tornando possível a extração de características contidas próximo às bordas. A Figura 7 é um exemplo da aplicação do *padding* de tamanho 1, ou seja, uma borda extra com valor igual a zero.




Figura 7 Exemplo da utilização de um *padding*

- Camada de Normalização em lote:** Consiste em normalizar os dados fornecidos à cada camada oculta. A normalização é aplicada em cada mini-lote. (Pascal et al., 2010) para aumentar a eficiência durante a aplicação da transformação. De acordo com os experimentos realizados pelos autores da técnica (Sergey, 2015), ela também produz um efeito de regularização sobre o treinamento. Uma aceleração significativa do tempo de treinamento também foi observada, resultante da diminuição de 14 vezes na quantidade de passos de treinamento necessários, quando comparada ao tempo de treinamento sem o uso da normalização.
- Unidade linear retificada (Rectified Linear Unit – ReLU):** As camadas de convolução e de normalização em lote geralmente são seguidas por uma função de ativação não linear, como uma ReLU. Ela executa uma operação de limiar para cada elemento, sem alterar o tamanho de sua entrada, onde qualquer entrada de valor inferior a zero é definida como zero, conforme:

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (5)$$

Foi demonstrado por meio de experimentos em (Alex, 2012) que em geral a função ReLU, através da sua propriedade de não-linearidade e não-saturação, produz tempo e erro de treinamento menor, comparado com as funções sigmoide e tangente hiperbólica, que implementa a não-linearidade saturante. A funcionalidade ReLU está ilustrada na Figura 8.

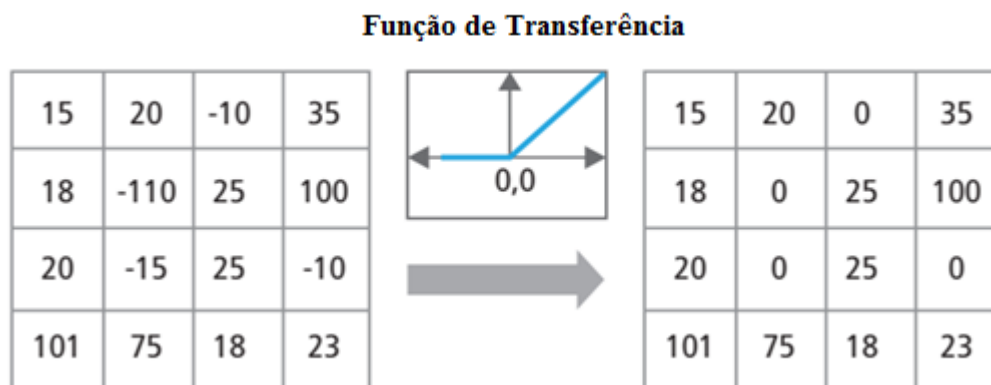


Figura 8 Representação gráfica da funcionalidade do ReLU. (Hijazi, 2015)

As atualizações dos pesos da rede em cada iteração são proporcionais ao gradiente. Por exemplo, o gradiente da função tanh nas regiões superior a 1 ou inferior a -1 é basicamente zero. Uma vez que a saída de certos neurônios entra nesse intervalo, seu gradiente será próximo de zero e os pesos deixarão de mudar. Isso é considerado problemático se ocorrer no início do processo de treinamento. Com a função de ativação ReLU, os pesos de um neurônio podem continuar a crescer na mesma proporção ao longo do processo de treinamento. (Alex, 2012)

- **Camadas de Pooling:** Também conhecida como sub amostragem, essa camada reduz a dimensionalidade de um mapa de característica fornecido como entrada e produz outro mapa de característica, uma espécie de resumo do primeiro (Hijazi, 2015). Há várias formas de sub amostragem aplicáveis a um mapa de

característica: selecionar o valor máximo (*max pooling*), a média (*average pooling*) ou a norma do conjunto (*L2- pooling*), entre outras. A Figura 9 apresenta outro mapa de característica, resultante da operação de *max-pooling* com o uso de filtros de tamanho igual a 2×2 e *stride* igual a 2.




Figura 9 Max-Pooling com um filtro de tamanho 2×2 e tamanho do passo (Stride) igual a 2. (Hijazi, 2015)

- **Camada totalmente conectada (*Fully Connected Layer*):** conecta todos os neurônios da camada anterior a ela com os neurônios de saída, que representam as classes a serem classificadas. Esta camada combina todas as características (informações locais) aprendidas em camadas anteriores, gerando descritores de características da imagem que podem ser mais facilmente classificados pela camada de saída (que normalmente usa a função *softmax*). A Figura 10 explica a camada totalmente conectada L, onde os dois mapas de características da camada anterior são combinados com os pesos $w^{(L)}$, que através dos processos descritos na imagem, determinam como resultado o *target* específico da camada de saída. (Hijazi, 2015).

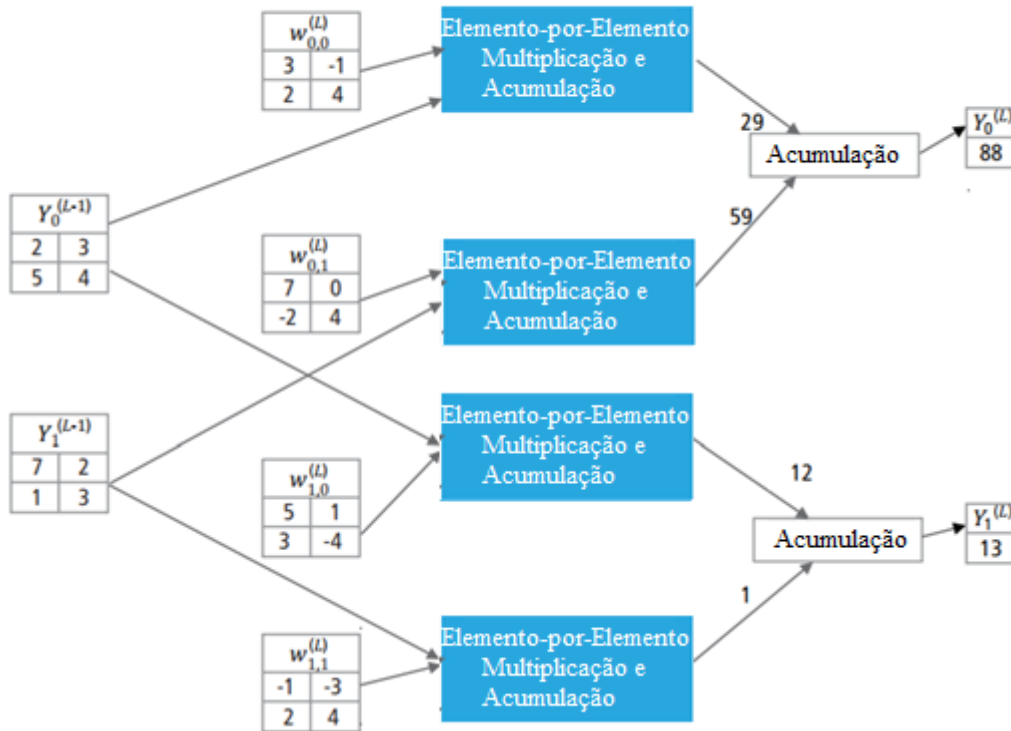


Figura 10 Processamento de uma camada totalmente conectada. (Hijazi, 2015)

- **Softmax:** A função de ativação *Softmax* normaliza a saída da camada totalmente conectada. A saída da camada *Softmax* consiste de números positivos cuja somatória resulta em 1, que podem então ser usados como probabilidade de classificação pela camada de classificação. A função de ativação da unidade de saída é obtida por:

$$y_r(x) = \frac{\exp(a_r(x))}{\sum_{j=1}^k \exp(a_j(x))} \quad (6)$$

onde $0 \leq y_r \leq 1$ e $\sum_{j=1}^k y_j = 1$.

- **Camada de Classificação:** Deve ser utilizada após a camada *Softmax*. Na saída da camada de classificação, a função de treinamento tira os valores da função

Softmax e atribui cada entrada a uma das k classes mutuamente exclusivas usando a função entropia cruzada para um esquema de codificação de 1-de- k :

$$E(\theta) = -\sum_{i=1}^n \sum_{j=1}^k t_{ij} \ln y_j(x_i, \theta) \quad (7)$$

onde t_{ij} é o indicador de que a amostra i pertence à classe j , θ é o vetor de parâmetros. A saída para a amostra i é definida como $y_j(x_i, \theta)$, que neste caso é o valor da função *Softmax*. Ou seja, é a probabilidade de a rede associar a entrada i à classe j conforme:

$$P(t_j = 1 | x_i) \quad (8)$$

3.3 Treinamento de Redes Neurais Convolucionais

Como as redes neurais convolucionais são geralmente usadas para aprendizado supervisionado elas precisam de treinamento com grandes montantes de dados para serem capazes de generalizar melhor as demais entradas às quais nunca foi exposta. A forma com que a rede é treinada é um fator determinante no desempenho da rede, tanto quanto sua própria arquitetura. Esse treinamento é realizado através da passagem dos dados de treinamento pela rede múltiplas vezes, onde o número dessas iterações é um dos parâmetros a serem determinados. Cada passagem de dados pela rede é dividida em duas etapas, *Forwardpass* e *Backpropagation* (Karpathy, 2016).

O *Forwardpass* consiste na passagem da entrada por todos os neurônios necessários para alcançar a saída, ou seja, é a passagem do volume de entrada pelas camadas da rede, nas quais suas operações típicas serão realizadas levando em consideração os pesos já aprendidos (ou inicializados de forma aleatória). Os resultados

obtidos pelo *forwardpass* de cada camada são então utilizados na etapa de Backpropagation para a atualização dos parâmetros da rede. Formalmente nessa etapa a entrada é propagada pelas funções específicas de cada camada da rede, na forma $f_n(\dots f_2(f_1(f_0(x)))) \dots$ onde f_i é a função de ativação da camada i e n se refere ao número de camadas da rede. (Guedes, 2016)

A etapa de *Backpropagation* é onde a aprendizagem dos pesos é realizada. Esse aprendizado se dá através da otimização (minimização) da função perda, a qual determina a qualidade da classificação do dado de entrada. Atualmente esse tipo de otimização é realizado utilizando um método chamado *Stochastic Gradient Descent* (SGD) que busca a minimização da função perda ao alterar os pesos na direção de maior declive do gradiente dessa função. Essa alteração dos parâmetros é feita através da modificação dos pesos W e dos valores de bias b que são parâmetros livres da rede. Esse passo busca otimizar $S_j = f(X_i, W, b)_j$ de forma que quando $J = y_i$ o valor de S_j seja o maior possível. Onde X_i e Y_i são referentes à entrada e o rótulo da amostra i respectivamente e f a função composta das camadas da rede. Essa otimização é realizada em lotes (*batches*) muitas vezes chamados *mini-batches* que são subconjuntos da entrada, divididos assim por conta de limitações na capacidade de memória das GPUs, as quais são os dispositivos mais utilizados nos treinamentos de redes neurais convolucionais atualmente. Essa divisão também é um hiperparâmetro da rede, sendo geralmente aceito que o treinamento com *batches* maiores resulta num melhor desempenho da mesma. (Guedes, 2016)

3.4 Estado da arte de Redes Neurais profundas aplicadas aos sistemas NILM

Devido ao avanço na área, alguns pesquisadores têm procurado aplicar as Redes Neurais Profundas para o problema de monitoramento não-intrusivo de carga.

Alguns trabalhos são apresentados a seguir, mostrando as aplicações e técnicas utilizadas.

No estudo feito em (Garcia et al., 2017), os autores, após construírem um medidor inteligente para aquisição dos dados, apresentam um método de desagregação de energia baseado em Autoencoders, que pertence ao conjunto de técnicas aplicadas em aprendizado profundo. Para o treinamento da rede foram utilizados como entrada os dados agregados de consumo de energia (em Watts), e seus resultados foram avaliados usando o erro médio absoluto (MAE – *mean absolute error*) e a proporção de energia corretamente atribuída como métricas para a desagregação do sinal. Os resultados mostram que o modelo foi capaz de decompor um sinal agregado de consumo de energia da casa inteira, decompondo-o em sinais individuais de consumo de energia dos aparelhos. Inicialmente, o modelo foi avaliado em dados de quatro equipamentos (Máquina de lavar, Computador, Fogão Elétrico e Aquecedor) e obteve resultados favoráveis em relação ao MAE, onde cada equipamento obteve erro em watts inferiores a 27W, e com relação a acurácia cada equipamento obteve valores ente 90% a 94% de energia corretamente classificada.

Uma investigação empírica de métodos de aprendizagem profunda em desagregação de carga (NILM), foi apresentado em (HE W., 2016). Neste trabalho foram adaptados dois tipos de arquiteturas de rede neural ao NILM utilizando o framework Keras (Chollet, 2018). O primeiro modelo de rede pode ser visto como um problema de regressão, que utiliza rede autoencoder para estimar a demanda de energia transitória de um único aparelho, considerando toda a série da energia agregada como entrada. O segundo tipo de rede é uma rede neural recorrente (RNN) que utiliza camadas LSTM (Long Short TermMemory), o qual se assemelha à estrutura usada em (Kelly, 2015). Os resultados experimentais mostraram as vantagens do modelo RNN

baseado em LSTM sobre as demais técnicas, como Otimização combinatória, Factorial Hidden Markov Model (FHMM). Tais vantagens podem ser analisadas utilizando como métrica de avaliação o erro médio absoluto em Watts. O modelo proposto obteve com os cinco equipamentos um erro de 25,12W enquanto os demais tiveram erro entre 27,66W a 86.2320W.

O autor em (Nascimento, 2016) experimentou e analisou vários métodos de aprendizado profundo para melhorar o desempenho de um sistema NILM, como Redes Neurais Recorrentes, Redes Neurais Convolucionais e *Gated Recurrent Unit* (GRU), além de utilizar diversas arquiteturas de aprendizado profundo para comparação. Durante a etapa de treinamento, foi aplicado a base de dados pública REED, sendo utilizados os equipamentos: micro-ondas, lava-louças e geladeira; em que cada equipamento foi treinado individualmente com um tipo de rede neural, assim, como resultado da avaliação, pode-se perceber que os resultados foram bastantes promissores para alguns equipamentos. O GRU foi a arquitetura com o melhor desempenho geral enquanto a rede LSTM obteve a pior performance. Isso mostra como a escolha de uma específica arquitetura é muito importante para o desempenho, mesmo para os diferentes tipos de aprendizagem profunda. No caso do microondas, nenhuma das redes possui um desempenho superior a 82%, sendo a proporção de energia total classificada corretamente (PECC) a métrica utilizada para avaliação. No caso da máquina de lavar louça e geladeira, o GRU funcionou melhor com PECC entre 89% a 94%, conseguindo capturar o complexo comportamento de consumo temporal desses aparelhos.

O trabalho apresentado em (Patel et al., 2007) é substancialmente diferente da maioria das outras abordagens para desagregação, pois usam medições de alta frequência para procurar transientes do sinal de tensão de uma residência e não necessariamente a corrente. Para isso, utilizaram um sensor plug-in para detectar

eventos elétricos dentro de uma casa, como lâmpadas, televisores, computadores etc. Foi empregado Máquina de Vetores de Suporte para classificar qual aparelho foi ativado. Em vários casos, eles encontraram precisão de 85-90% na classificação dos eventos. No entanto, eles não determinaram a energia consumida durante cada evento.

Em (Deyvison P. P., 2017) é proposta uma rede neural convolucional para a identificação de equipamentos elétricos em um sistema de monitoramento não intrusivo. Para o experimento foi utilizado 7 equipamentos da base de dados REDD, sendo utilizado como entrada para a CNN seus transitórios de potência. Além disso, os dados de entrada foram redimensionados para ser interpretados como uma matriz de 4D, caracterizando uma matriz de imagens. Através dessa técnica o sistema conseguiu alcançados resultados promissores com acurácia de 82%, além de trazer uma nova abordagem para sistemas baseados em CNN, pois é possível extrair características de sinais temporais sem haver a necessidade de uma etapa de conversão e processamento de imagens.

4 SISTEMA PROPOSTO DE IDENTIFICAÇÃO DE EQUIPAMENTOS BASEADO EM CNN

4.1 Introdução

Este capítulo tem como objetivo apresentar o sistema proposto desenvolvido para identificação de equipamentos elétricos em sistemas de monitoramento não intrusivo de carga em ambiente residencial empregando Redes Neurais Convolucionais. Para isso, foi utilizado o software Matlab durante os procedimentos e modelos desenvolvidos nesta proposta. Como já mencionado, uma rede CNN é um caso especial da rede MLP com uma arquitetura baseada em camadas alternadas de convolução e *pooling*. A sua escolha para o problema se deve principalmente à sua capacidade de extrair importantes características de um sinal de entrada sendo adequada para aplicação em problemas de classificação.

As CNNs são projetadas para processar dados que vêm na forma de múltiplos arrays, como por exemplo, uma imagem colorida composta por três matrizes 2D contendo intensidade de pixels nos três canais de cores. Muitas modalidades de dados estão na forma de múltiplas matrizes, como: 1D para sinais e sequências, incluindo linguagem; 2D para imagens ou espectrogramas de áudio; e 3D para imagens em vídeo ou volumétricas. Diversos trabalhos, com resultados promissores, foram apresentados na literatura utilizando Redes Neurais Convolucionais. Em (Guedes, 2016), o autor utiliza CNNs para, em tempo real, conseguir detectar gestos (Handshapes) em uma imagem de vídeo, para isso faz-se o uso de uma rede pré-treinada GoogLeNet. Já em (Vargas, 2016) tem-se as CNNs sendo aplicadas em detecção de pedestres. Para isso os autores utilizaram imagens como parâmetros de entrada para uma rede CNN pré-treinada AlexNet com alguns ajustes na arquitetura das camadas, para que pudesse se

adaptar ao problema proposto. Uma outra abordagem é apresentada em (Abdel et al., 2014) para aplicar a CNN no reconhecimento de voz. Neste artigo os autores converteram os sinais de áudio em uma imagem de espectrograma, para então aplicá-la a uma CNN.

Considerando então as características das redes CNN, foi proposto e desenvolvido um sistema de identificação de equipamentos conforme Figura 11, onde se tem como parâmetro de entrada para a CNN uma matriz composta pelas amostras do sinal transitório de potência dos equipamentos, que após passar pela etapa de extração de características, fornece como saída a classificação do equipamento correspondente a entrada analisada.

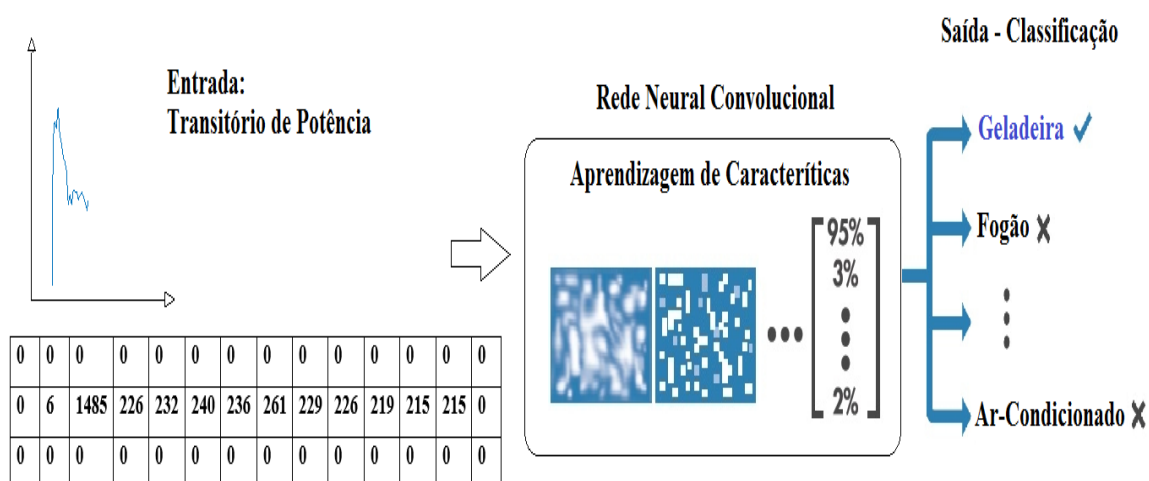


Figura 11 Sistema de identificação de equipamentos baseado em CNN

Com relação ao treinamento da rede CNN foi utilizado o sinal de potência medido do momento em que o equipamento é ligado até entrar em regime permanente (sinal em regime transitório). A escolha do uso do sinal transitório de potência de um evento de liga/desliga se deve ao fato desta informação/assinatura possuir uma distribuição dos dados com características diferentes para cada tipo de equipamento, dependendo do mecanismo de geração do mesmo, o que é propício para um problema de classificação.

Para o desenvolvimento e teste do sistema de identificação proposto foi utilizada a base de dados pública, e muito utilizada pelos pesquisadores da área, *Reference Energy Disaggregation Data set* (REDD). O sistema foi desenvolvido para identificação de 7 equipamentos, sendo estes classificados como cargas *on / off*, de multinível ou variável.

4.2 Banco de dados REED

Para o desenvolvimento do sistema de identificação proposto foi utilizada a base de dados pública *Reference Energy Disaggregation Data set*- REED (Kolter & Johnson, 2011), que é uma das bases de dados mais utilizadas no campo da pesquisa de sistemas NILM. A base de dados é formada por dados coletados em 6 residências, e contém dados agregados de corrente e voltagem coletados na frequência de 15kHz, dados de 24 circuitos individuais coletados na frequência de 0,5 Hz, além de dados provenientes de mais de 20 monitores de equipamentos coletados na frequência de 1 HZ (Kolter & Johnson, 2011). A Tabela 2 apresenta os equipamentos por residência que fazem parte do banco de dados REDD.

Tabela 2 Equipamentos do banco de dados REED

Residência	Equipamentos
1	Eletrônicos, Luz, refrigerador, lava louças, aquecedor, secadora de roupas, alarmes de incêndio, equipamentos de banheiro,DVD, utensílios de cozinha, Micro-ondas.
2	Luzes, refrigerador, lava loucas, secadora de roupas, equipamentos de banheiro, utensílios de cozinha, Micro-ondas, forno, aquecedor, fogão.
3	Eletrônicos, Luzes, refrigerador, lava loucas, aquecedor, secadora de roupas, alarmes de incêndio, equipamentos de banheiro, utensílios de cozinha, Micro-ondas, utensílios externos.
4	Luzes lava loucas, aquecedor, secadora de roupas, alarmes de incêndio, equipamentos de banheiro, utensílios de cozinha, fogão, ar condicionado.
5	Luzes, refrigerador, lava loucas, secadora de roupas, utensílios de cozinha, fogão, Micro-ondas.
6	Luzes, refrigerador, lava loucas, aquecedor, secadora de roupas, equipamentos de banheiro, utensílios de cozinha, fogão, eletrônicos, ar condicionado.

Para o desenvolvimento do sistema proposto foram escolhidos 7 equipamentos, sendo eles: micro-ondas, fogão, forno, lava louças, ar-condicionado, lavadora/secadora e geladeira. Estes equipamentos foram escolhidos por serem considerados o que mais consomem energia em uma residência. Segundo Batra (2015) deve-se priorizar a identificação de equipamentos com maior consumo de energia nas residências, pois esses aparelhos contribuem com as características mais significantes na carga agregada, podendo os outros aparelhos, com menor consumo, serem considerados apenas como ruído na carga total agregada. As Figura 12 a Figura 18 apresentam

exemplos de carga medida em um período de tempo de 1h para todos os 7 tipos de equipamentos a serem identificados.




Figura 12 Exemplo de carga medida do equipamento geladeira no decorrer de um 1h




Figura 13 Exemplo de carga medida do equipamento micro-ondas no decorrer de um 1h.




Figura 14 Exemplo de carga medida do equipamento fogão no decorrer de um

1h.




Figura 15 Exemplo de carga medida do equipamento forno no decorrer de um

1h.




Figura 16 Exemplo de carga medida do equipamento lava-louças no decorrer de

um 1h.




Figura 17 Exemplo de carga medida do equipamento ar-condicionado no decorrer de um 1h.




Figura 18 Exemplo de carga medida do equipamento lava-louças no decorrer de um 1h.

Para o desenvolvimento do sistema foram utilizadas como entradas para a rede CNN os sinais transitórios de potência obtidos no momento em que um equipamento é ligado em uma residência. Para criação do banco de dados para treinamento da rede CNN classificadora, um algoritmo para detecção de eventos foi desenvolvido baseado na detecção de eventos apresentada em (Batra, 2010) sendo que neste algoritmo, para cada evento detectado na carga medida em uma residência, considerando cada medidor individual monitorando um equipamento específico, as doze primeiras amostras do transitório foram separadas para formar o banco de dados para desenvolvimento do sistema. A escolha do número de amostras utilizadas como entrada

para o sistema foi baseada na avaliação, para todos os equipamentos, do número de amostras suficiente para caracterizar um transitório completo.

4.3 Treinamento da CNN

A base de dados para desenvolvimento do sistema de identificação possui 700 padrões, considerando todos os 7 equipamentos. Cada padrão apresenta 12 amostras do transitório de um determinado equipamento, formando assim uma matriz bidimensional 12x700. Os dados foram divididos em dados de treinamento, validação e teste, correspondendo respectivamente, a aproximadamente 60%, 20% e 20% do total de padrões, como pode ser observado na Tabela 3.

Tabela 3 Divisão dos dados

Nº	Aparelhos	Train.	Valid.	Test	Total
1	Geladeira	60	20	20	100
2	Micro-ondas	60	20	20	100
3	Fogão	60	20	20	100
4	Forno	60	20	20	100
5	Lava louças	60	20	20	100
6	Ar-condicionado	60	20	20	100
7	Lavadora/secadora	60	20	20	100
#	Geral	420	140	140	700

A metodologia proposta consiste em utilizar diretamente as 12 amostras do sinal transitório de potência dos equipamentos como entrada para a CNN, sem a necessidade de aplicar técnicas de transformação do sinal para imagens, como espectrograma (Abdel-Hamid et al., 2014), ou imagens binárias (Atabay, H. A., 2016). Para isso foi necessário apenas redimensionar a matriz 12x420 de entrada de treino, para 4D, assumindo então a dimensão 1x12x1x420, onde as primeiras três dimensões referem-se à altura, largura e canais, sendo que a última dimensão deve indexar as

imagens individuais, ou seja, para o caso, indexar os transitórios. Dessa forma a CNN interpreta os dados como uma matriz numérica 4-D, um aglomerado de imagens que podem ser coloridas, caso o canal seja igual a 3, ou em escala de cinza se o canal for igual a 1. Para essa modelagem, as matrizes redimensionadas estão com o canal em escala de cinza, ou seja, com o canal igual a 1.

Diversas arquiteturas de CNN foram testadas variando-se o número de camadas de convolução, taxa de aprendizado, tamanho dos filtros e tamanho do *stride*, como pode ser visto nas Tabelas de 4 a 10. O melhor valor de acurácia, levando em consideração o menor custo computacional, foi predominante para a definição da melhor arquitetura. A Tabela 11 apresenta os resultados obtidos para as arquiteturas treinadas.

Tabela 4 Arquitetura 1 com taxa de aprendizado igual a 0,01

Nome da camada	Nº de Filtros	Tamanho do Filtro	Stride	Padding	Saída da Camada
Convolução	10	2x2	1	1	2x13
Max-pooling	1	2x2	1	0	1x12
Convolução2	30	2x2	1	1	2x13

Tabela 5 Arquitetura 2 com taxa de aprendizado igual a 0,01

Nome da camada	Nº de Filtros	Tamanho do Filtro	Stride	Padding	Saída da Camada
Convolução 1	10	2x2	1	1	2x13
Max-pooling	1	2x2	1	0	1x12
Convolução 2	20	2x2	1	1	2x13
Max-pooling	1	2x3	1	0	1x12
Convolução 3	40	2x2	1	1	2x13
Max-pooling	1	2x2	1	0	1x12
Convolução 4	50	2x2	1	1	2x13

Tabela 6 Arquitetura 3 com taxa de aprendizado igual a 0,3

Nome da camada	Nº de Filtros	Tamanho do Filtro	Stride	Padding	Saída da Camada
Convolução 1	10	2x2	1	1	2x13
Max-pooling	1	2x2	1	0	1x12
Convolução 2	20	2x2	1	1	2x13
Max-pooling	1	2x2	1	0	1x12
Convolução 3	40	2x2	1	1	2x13
Max-pooling	1	2x3	2	0	1x6
Convolução 4	50	2x2	1	1	2x7

Tabela 7 Arquitetura 4 com taxa de aprendizado igual a 0,3

Nome da camada	Nº de Filtros	Tamanho do Filtro	Stride	Padding	Saída da Camada
Convolução	10	2x2	1	1	2x13
Max-pooling	1	2x2	1	0	1x12
Convolução2	20	2x2	1	1	2x13
Max-pooling	1	2x3	2	0	1x6
Convolução3	30	2x2	1	1	2x7

Tabela 8 Arquitetura 5 com taxa de aprendizado igual a 0,01

Nome da camada	Nº de Filtros	Tamanho do Filtro	Stride	Padding	Saída da Camada
Convolução	10	3x3	1	1	2x13
Max-pooling	1	1x2	2	0	1x12
Convolução2	20	2x2	1	1	2x13

Tabela 9 Arquitetura 6 com taxa de aprendizado igual a 0,05

Nome da camada	Nº de Filtros	Tamanho do Filtro	Stride	Padding	Saída da Camada
Convolução	10	2x3	1	1	2x12
Max-pooling	1	2x2	2	0	1x6
Convolução2	20	1x2	2	1	3x3
Max-pooling	1	3x3	1	0	1x1
Convolução3	30	2x2	1	1	2x2

Tabela 10 Arquitetura 7 com taxa de aprendizado igual a 0,01

Nome da camada	Nº de Filtros	Tamanho do Filtro	Stride	Padding	Saída da Camada
Convolução	10	2x2	1	1	2x13
Max-pooling	1	2x2	1	0	1x12
Convolução2	20	2x2	1	1	2x13
Max-pooling	1	2x3	1	0	1x11
Convolução3	30	2x2	1	1	2x12

Tabela 11 Desempenho das arquiteturas em relação a Acurácia

Ambiente de Simulação	Desempenho		
	Acurácia Treino	Acurácia Validação	Acurácia Teste
Arquitetura 1	0.9405	0.8714	0.8786
Arquitetura 2	0.9714	0.7786	0.8857
Arquitetura 3	0.8762	0.5286	0.6786
Arquitetura 4	0.6143	0.5286	0.4714
Arquitetura 5	0.9095	0.6786	0.8000
Arquitetura 6	0.1429	0.1429	0.1429
Arquitetura 7	0.9571	0.8429	0.9143

Com os resultados obtidos em cada combinação de arquitetura, pode-se inferir que para o problema proposto, ao aumentar o número de camadas convolucionais para acima de quatro, há uma diminuição nas características extraídas e assim ocorre uma diminuição da performance da rede. Outro fator importante analisado é a taxa de aprendizagem, em que ao aumentá-la (generalização), aumenta a dificuldade do algoritmo fazer distinção dos equipamentos, haja em vista que alguns equipamentos os transitórios de potência são bastante similares. Diante disso, a arquitetura 7 foi a que apresentou melhor resultado de acurácia para os dados de teste e foi então arquitetura escolhida. Esta arquitetura é apresentada na Figura 19.

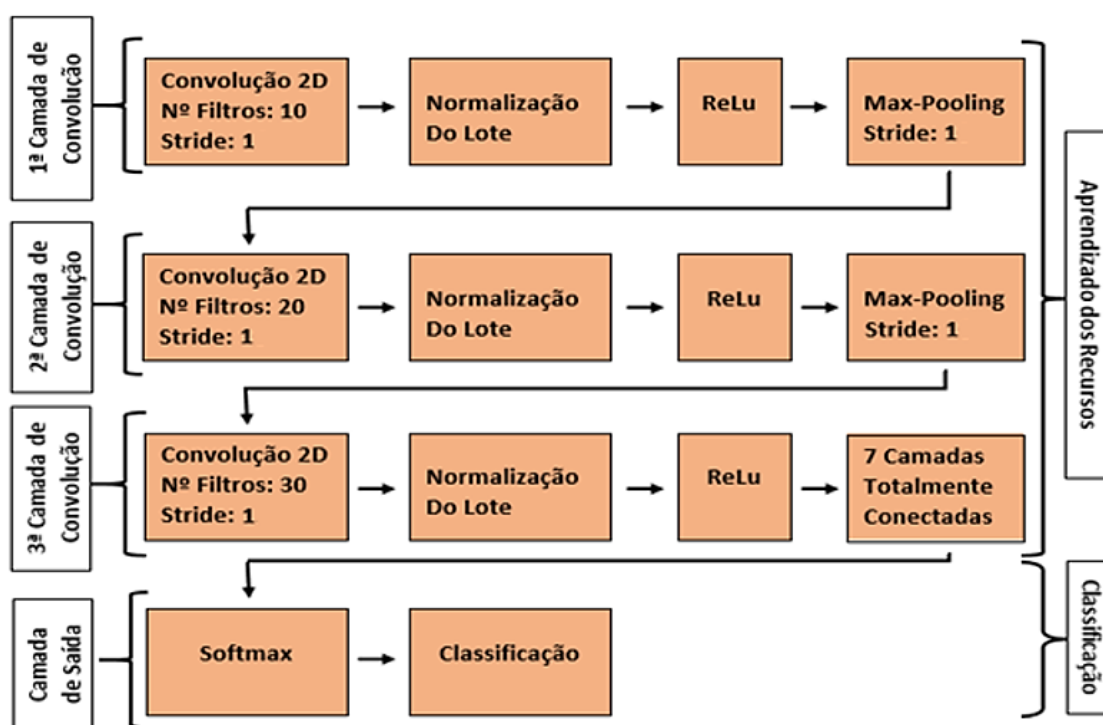


Figura 19 Arquitetura da CNN

Para esta arquitetura, entre cada camada de convolução e *pooling* foi aplicada a normalização nos conjuntos de filtros (lotes), que serviu para acelerar a formação de rede e reduzir a sensibilidade para inicialização. Além disso, utilizou-se a função de

ativação não linear (ReLU). Após as 3 camadas de convolução foi utilizada uma camada totalmente conectada, seguida pela função *softmax*.

Durante o treinamento da CNN foi gerado valores aleatórios para os filtros de convolução através de uma distribuição gaussiana e multiplicação pela taxa de aprendizagem, que foi definida como sendo 0.01 a fim de se obter uma melhor aprendizagem. Vale ressaltar que em todas as camadas de convolução foi utilizado um *padding* de tamanho 1. Por exemplo, ao analisar a primeira camada de convolução, os transítórios de entrada passaram de 1x12 para o tamanho 3x14. Após o emprego dos filtros de convolução essa matriz ficou com a dimensão de 2x13x10, sendo o último parâmetro o volume, que é definido pela quantidade de filtros. A matriz teve seu tamanho novamente modificado ao passar pelos filtros de *max-pooling*, porém não há alteração do volume, assim ficando seu tamanho reduzido para 1x12x10.

Ainda na etapa de treinamento, foi empregada a validação cruzada (*cross validation*), a fim de evitar o sobre-treinamento da rede. A Figura 20 apresenta o resultado do progresso de treinamento da arquitetura escolhida utilizando a função ‘*training-progress*’ para fazer o monitoramento do progresso de treinamento.

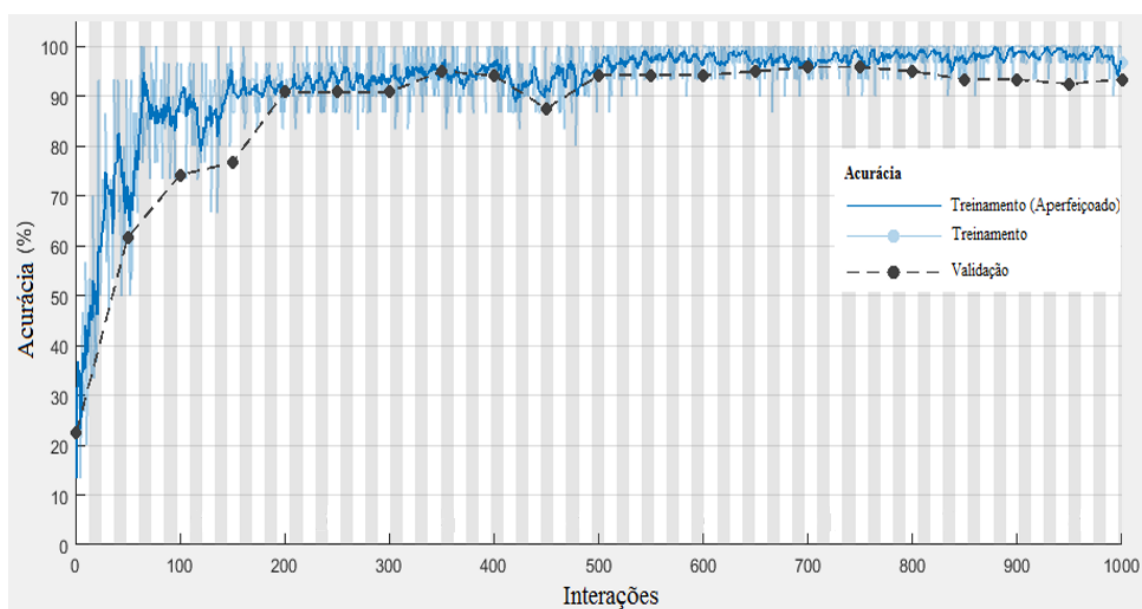


Figura 20 Treinamento da rede CNN Utilizando Validação Cruzada

4.4 Resultados

A tabela 12 apresenta os resultados obtidos para dados de teste para a arquitetura CNN escolhida. Os resultados são apresentados por meio das métricas sensibilidade (Sens), precisão (Prec) e F-score (F).

Tabela 12 Resultado para os dados de Teste

N°	Aparelhos	Sens.	Prec.	F-Score
1	Geladeira	0.9000	0.9474	0.9231
2	Micro-ondas	0.9000	0.9000	0.9000
3	Fogão	0.8000	0.9412	0.8649
4	Forno	0.9500	0.9048	0.9268
5	Lava louças	0.8500	0.8947	0.8718
6	Ar-condicionado	1.0000	0.8333	0.9091
7	Lavadora/secadora	1.0000	1.0000	1.0000
#	Geral	0.9143	0.9173	0.9137

As 3 métricas de avaliação utilizadas nesse trabalho ajudam a medir o desempenho da CNN de uma perspectiva diferente. Assim, tem-se como exemplo, os equipamentos Ar-condicionado e Lavadora, que foram classificados de forma precisa, não possuindo FP, além de apresentarem o mesmo desempenho para a sensibilidade. Então para harmonizar as duas métricas de avaliação já citadas e trazer uma melhor comparação entre os equipamentos, utiliza-se a métrica F-score. Dessa forma, podemos analisar na coluna F-Score que o equipamento Lavadora/Secadora teve o melhor resultado com 100% de precisão e sensibilidade, além dele outros equipamentos demonstraram um excelente desempenho com base no modelo proposto. Outros equipamentos também possuíram ótimos valores de F-score como geladeira, forno, ar-condicionado e microondas, todos com valores acima de 90%.

A Figura 21 apresenta a matriz de confusão obtida para dados de teste, permitindo assim, ter uma visão mais ampla acerca do desempenho do sistema, além de detalhar os resultados obtidos na Tabela 12. Os 7 equipamentos estão definidos da seguinte forma: micro-ondas (Mi), forno (Fr), ar-condicionado (Ar), máquina de lavar louça (Ll), lavadora/secadora (Ls) e geladeira (Ge). Cada coluna da matriz representa a classe de equipamento predito pela CNN, enquanto as linhas representam as classes reais, sendo que a última coluna representa a precisão e a última linha a sensibilidade total. As células na diagonal principal correspondem a observações que são corretamente classificadas. Tanto o número de observações como a porcentagem em relação ao número total de observações são mostradas em cada célula. Por fim, a célula que se localiza na última coluna da última linha, marcada em azul, corresponde a acurácia geral da classificação.

GE	18 12.9%	0 0.0%	0 0.0%	0 0.0%	1 0.7%	0 0.0%	0 0.0%	94.7% 5.3%
MI	0 0.0%	18 12.9%	2 1.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90.0% 10.0%
FG	0 0.0%	0 0.0%	16 11.4%	0 0.0%	1 0.7%	0 0.0%	0 0.0%	94.1% 5.9%
FR	0 0.0%	2 1.4%	0 0.0%	19 13.6%	0 0.0%	0 0.0%	0 0.0%	90.5% 9.5%
LL	2 1.4%	0 0.0%	0 0.0%	0 0.0%	17 12.1%	0 0.0%	0 0.0%	89.5% 10.5%
AR	0 0.0%	0 0.0%	2 1.4%	1 0.7%	1 0.7%	20 14.3%	0 0.0%	83.3% 16.7%
LS	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	20 14.3%	100% 0.0%
	90.0% 10.0%	90.0% 10.0%	80.0% 20.0%	95.0% 5.0%	85.0% 15.0%	100% 0.0%	100% 0.0%	91.4% 8.6%
	GE	MI	FG	FR	LL	AR	LS	

Figura 21 Matriz de confusão para os dados de Teste.

Com base nesses resultados, podemos inferir que os equipamentos que possuem valores de FN tiveram uma diminuição de sensibilidade, como o equipamento Fogão, onde 80% do tempo o modelo prediz corretamente. Os equipamentos Lava-Louças e Ar-Condicionado tiveram as piores precisões, isso se dá pelo fato destes equipamentos possuírem valores de FP. Já o equipamento Lavadora-Secadora, não apresentou valores de FP e FN, alcançando 100% de precisão e sensibilidade.

Através da Figura 22 é possível perceber porque o equipamento geladeira possui 90% de sensibilidade, classificando apenas 18 amostras como TP e 2 amostras como FN para Lava-Louças. Apesar de haver algumas semelhanças nos valores de amplitude de potência, o sistema proposto conseguiu fazer uma boa distinção entre os 2 equipamentos.

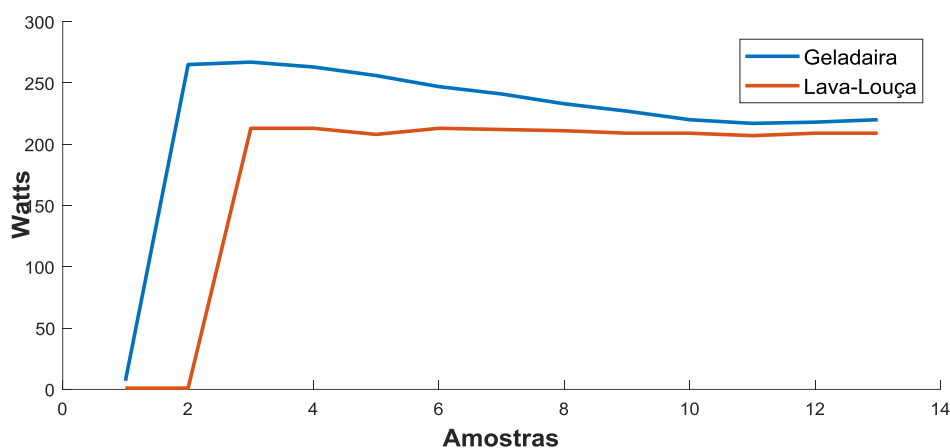


Figura 22 Comparativo entre equipamento geladeira e lava-louça

Fazendo uma análise mais aprofundada no comportamento do sinal de potência dos equipamentos, pode-se também notar semelhanças em alguns transitórios, o que pode ser visto na Figura 23, onde podemos observar três transitórios muito semelhantes, caso do micro-ondas, fogão e geladeira, justificando assim alguns FP encontrado na matriz de confusão.




Figura 23 Comparativo entre micro-ondas, fogão e forno

Em comparação com resultados já apresentados na literatura tem-se um sistema classificador de equipamentos com resultados satisfatórios, tendo em vista que entre os equipamentos utilizados existem aqueles com comportamento de carga complexo (cargas no estado multinível ou variável), o que torna o processo de classificação mais difícil.

A Tabela 13 apresenta os resultados de alguns sistemas já desenvolvidos para identificação de equipamentos em sistemas NILM usando como entrada as medidas do transitório de potência para baixas frequências e para desenvolvimento do sistema a base de dados REED. Uma comparação direta de resultados deve ser realizada com cuidado visto que para todos os sistemas apresentados tem-se a base de dados usada para treino, teste e validação diferentes e equipamentos e número de equipamentos identificados também diferentes.

Tabela 13 Comparação entre Sistemas apresentados na literatura

Autores	Técnica	Nº de Aparelhos	Sens	Prec	F	Acc
Esta Proposta	CNN	7	0.9143	0.9173	0.9137	0.9143
(Penha, 2017)	CNN	7	0.82	0.84	0.82	0.82
(Penha, 2018)	CNN	6	0.933	0.936	0.930	0.93
(Kelly, 2015)	Autoencoder	5	0.80	0.58	0.55	0.91
(Kelly, 2015)	LSTM	5	0.69	0.39	0.39	0.68
(Wong, 2014)	PDT	6	0.77	0.76	0.73	-----
(Zhao, 2016)	GSP	8	0.51	0.89	0.64	0.77

(Kelly, 2015) Uses long short-term memory; (Wong, 2014) Uses Particle-based Distribution Truncation (PDT) and (Zhao, 2016) Uses Graph Signal Processing (GSP).

Com base nos resultados obtidos é possível observar o bom desempenho de redes neurais convolucionais em comparação com outras técnicas empregadas a identificação de equipamentos em sistemas NILM. Comparados com os resultados encontrados na literatura, pode-se perceber que este trabalho pode trazer uma contribuição as pesquisas pertencentes a área de aplicação, podendo, essa técnica, também ser empregada em outros contextos em que haja a necessidade de extrair características de sinais em serie temporais.

5 CONCLUSÃO

Neste trabalho foi apresentado o sistema desenvolvido para identificação de equipamentos em sistemas NILM utilizando Redes Neurais Convolucionais. Os resultados obtidos indicam a eficiência do sistema proposto, onde se obteve uma média ponderada de precisão, sensibilidade e acurácia superiores a 90%. Os resultados obtidos podem ser considerados satisfatórios quando comparados com resultados de sistemas de identificação já apresentados na literatura, considerando a complexidade do sistema proposto que foi desenvolvido para identificação de cargas no estado multinível ou variável.

Um ponto que pode ser destacado em relação ao sistema diz respeito ao uso direto do sinal transitório de potência como entrada para o sistema de identificação sem a necessidade de uma fase de extração de características, o que diminui o custo computacional do sistema de identificação. Tem-se ainda um sistema que consegue obter bons resultados de classificação, utilizando dados de potência medidos a uma baixa frequência, o que é desejável, visto que o uso de baixas frequências é comum nos medidores de baixo custo disponíveis atualmente para desenvolvimento de sistemas NILM.

Outro ponto a ressaltar se dá ao fato de uma única CNN ter a capacidade de classificar os 7 equipamentos, enquanto muitos trabalhos apresentados na literatura se baseiam em uma rede neural para cada equipamento de forma individual, aumentando assim a complexidade computacional do sistema de identificação, ou então reduzem a quantidade de equipamentos a serem identificados para aumentar o desempenho do sistema.

5.1 Trabalhos Publicados

Como parte dos resultados apresentados neste trabalho, foi utilizado o artigo a seguir, publicado em conferência internacional voltada a aplicações na área de inteligência artificial.

- PENHA, Deyvison de Paiva; CASTRO, Adriana Rosa Garcez. “Convolutional neural network applied to the identification of residential equipment in non-intrusive load monitoring systems”. In: 3rd International Conference on Artificial Intelligence and Applications, pp. 11– 21, 2017. © CS & IT-CSCP 2017.

Também o seguinte trabalho foi publicado em jornal internacional:

- PENHA, Deyvison de Paiva; CASTRO, Adriana Rosa Garcez. “Home Appliance Identification for Nilm Systems Based on Deep Neural Networks”. In: International Journal of Artificial Intelligence & Applications (IJAIA), pp.69– 80, v. 9, n. 2, March 2018.

5.2 Trabalho Futuro

As Redes neurais profundas tipicamente são aplicadas em uma grande quantidade de dados. Assim, é possível que resultados ainda melhores possam ser obtidos se a base de dados de treinamento for aumentada. Como proposta de trabalho futuro, seria interessante considerar uma base maior ou a criação de uma base de dados própria, implementada em cenários reais.

REFERÊNCIAS

ABDEL-HAMID, Ossama et al. Convolutional neural networks for speech recognition. *IEEE/ACM Transactions on audio, speech, and language processing*, v. 22, n. 10, p. 1533-1545, 2014.

Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton. Imagenet classification with deep convolutional neural networks. In F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger, editors, *NIPS 25*, pages 1097–1105. Curran Associates, Inc., 2012.

Atabay, H.A.: Binary shape classification using convolutional neural networks. *IIOAB J.* 7(5), 332–336 (2016)

BATRA, Nipun; SINGH, Amarjeet; WHITEHOUSE, Kamin. If you measure it, can you improve it? exploring the value of energy disaggregation. In: *Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments*. ACM, 2015. p. 191-200.

CARVALHO, J.M., “Metodologias de Monitoração de Consumo”. Universidade do Porto.2013.

CENEDESE, Angelo et al. Padova smart city: An urban internet of things experimentation. In: *World of Wireless, Mobile and Multimedia Networks (WoWMoM)*, 2014 IEEE 15th International Symposium on a. IEEE, 2014. p. 1-6.

Chollet F. Keras: Deep Learning library for TensorFlow and Theano[CP/OL]. Disponível em: <https://github.com/fchollet/keras>. Acesado em 17/03/2018.

COLE A., ALBICKI A. “Nonintrusive Identification of Electrical Loads in a Three-Phase Environment Based on Harmonic Content.”*Proceedings of Instrumentation*

and Measurement Technology Conference; Baltimore, MD, USA. 1–4 May 2000; pp. 24–29.

COLE A., ALBICKI A. “Nonintrusive Identification of Electrical Loads in a Three-Phase Environment Based on Harmonic Content.” Proceedings of Instrumentation and Measurement Technology Conference; Baltimore, MD, USA. 1–4 May 2000; pp. 24–29.

DE BAETS, Leen et al. Appliance classification using VI trajectories and convolutional neural networks. *Energy and Buildings*, v. 158, p. 32-36, 2018.

DO NASCIMENTO, Pedro Paulo Marques. Applications of Deep Learning Techniques on NILM. 2016. Tese de Doutorado. Universidade Federal do Rio de Janeiro.

DONG, H.; WANG, B.; LU, Chang-Tien. Deep Sparse Coding based Recursive Disaggregation Model for Water Conservation. In *International Joint Conference on Artificial Intelligence*, Beijing, China, 2013.

FAUSTINE, Anthony et al. A Survey on Non-Intrusive Load Monitoring Methodies and Techniques for Energy Disaggregation Problem. arXiv preprint arXiv:1703.00785, 2017.

FIGUEIREDO, Marisa B.; DE ALMEIDA, Ana; RIBEIRO, Bernardete. An experimental study on electrical signature identification of non-intrusive load monitoring (nilm) systems. In: *International Conference on Adaptive and Natural Computing Algorithms*. Springer, Berlin, Heidelberg, 2011. p. 31-40.

Garcia, F. C. C., Creayla, C. M. C., & Macabebe, E. Q. B. (2017). Development of an Intelligent System for Smart Home Energy Disaggregation Using Stacked Denoising Autoencoders. *Procedia Computer Science*, 105, 248-255.

GUEDES, André Bernardes Soares. Reconhecimento de Gestos usando Redes Neurais Convolucionadas. Monografia em Engenharia de Software, Universidade de Brasília, 2016.

HART, George William. Nonintrusive appliance load monitoring. Proceedings of the IEEE, v. 80, n. 12, p. 1870-1891, 1992.

HE, Wan; CHAI, Ying. An Empirical Study on Energy Disaggregation via Deep Learning. Advances in Intelligent Systems Research, v. 133, 2016.

HIJAZI, Samer; KUMAR, Rishi; ROWEN, Chris. Using convolutional neural networks for image recognition. Tech. Rep., 2015. [Online]. Available: <http://ip.cadence.com/uploads/901/cnn-wp-pdf>.

K. D. Anderson, M. E. Berges, A. Ocneanu, D. Benitez, and J. M. F. Moura. Event detection for Non-Intrusive load monitoring. In IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society, 2012.

Karim Said Barsim, Roman Streubel, and BinYang. An Approach for Unsupervised Non-Intrusive Load Monitoring of Residential Appliances. In Proceedings of the 48th International Universities' Power Engineering Conference (UPEC), pages 1-5, Dublin, 2013.

KARPATHY, A. CS231n Convolutional Neural Networks for Visual Recognition. 2016. Disponível em: <<http://cs231n.github.io/>>, acessado em 17/03/18.

KATO T., CHO H.S., LEE D. "Appliance Recognition from Electric Current Signals for Information-Energy Integrated Network in Home Environments." Proceedings of the 7th International Conference on Smart Homes and Health Telematics; Tours, France. 1-3 July 2009; pp. 150-157.

Kelly, Jack, and William Knottenbelt. "Neural nilm: Deep neural networks applied to energy disaggregation." Proceedings of the 2nd ACM International

Conference on Embedded Systems for Energy-Efficient Built Environments. ACM, 2015. NBR 6023

KLEMENJAK, Christoph; EGARTER, Dominik; ELMENREICH, Wilfried. YoMo: The Arduino-based smart metering board. *Computer Science-Research and Development*, v. 31, n. 1-2, p. 97-103, 2016.

KOLTER, J. Zico; BATRA, Siddharth; NG, Andrew Y. Energy disaggregation via discriminative sparse coding. In: *Advances in Neural Information Processing Systems*. 2010. p. 1153-1161.

KOLTER, J. Zico; JOHNSON, Matthew J. REDD: A public data set for energy disaggregation research. In: *Workshop on Data Mining Applications in Sustainability (SIGKDD)*, San Diego, CA. 2011. p. 59-62.

LAM H.Y., FUNG G.S.K., LEE W.K. "A Novel method to construct taxonomy electrical appliances based on load signatures". *IEEE Trans. ConsumElectron*. 2007;53:653–660.

LÄNGKVIST, Martin; KARLSSON, Lars; LOUTFI, Amy. A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern Recognition Letters*, v. 42, p. 11-24, 2014.

LECUN, Yann et al. Convolutional networks for images, speech, and time series. *The handbook of brain theory and neural networks*, v. 3361, n. 10, p. 3361, 1995.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. *nature*, v. 521, n. 7553, p. 436, 2015.

LEE K.D., LEEB S.B., NORFORD L.K., ARMSTRONG P.R., HOLLOWAY J., SHAW S.R. "Estimation of variable-speed-drive power consumption from harmonic content." *IEEE Trans. Energy Convers*. 2005;20:566–574.

LEE W.K., FUNG G.S.K., LAM H.Y., CHAN F.H.Y., LUCENTE M. “Exploration on Load Signatures”. Proceedings of International Conference on Electrical Engineering (ICEE); Sapporo, Japan. 4–6 July 2004; pp. 1–5.

LEE, Honglak et al. Unsupervised feature learning for audio classification using convolutional deep belief networks. In: Advances in neural information processing systems. 2009. p. 1096-1104

LEITE, D.R.V. Medidores eletrônicos: Análise de viabilidade econômica no contexto de redes inteligentes. Dissertação de Mestrado em Engenharia Elétrica, Universidade de Brasília, 2013.

LI J., WEST S., PLATT G. “Power Decomposition Based on SVM Regression”. Proceedings of International Conference on Modelling, Identification Control; Wuhan, China. 24–26 June 2012; pp. 1195–1199.

MAKONIN, Stephen et al. Inspiring energy conservation through open source metering hardware and embedded real-time load disaggregation. In: Power and Energy Engineering Conference (APPEEC), 2013 IEEE PES Asia-Pacific. IEEE, 2013. p. 1-6.

NAJMEDDINE H., EL KHAMLIHI DRISSE K., PASQUIER C., FAURE C., KERROUM K., DIOP A., JOUANNET T., MICHOU M. “State of Art on Load Monitoring Methods.” Proceedings of the 2nd IEEE International Conference on Power and Energy Conference; Johor Bahru, Malaysia. 1–3 December 2008; pp. 1256–1258.

PARSON, O. “Unsupervised Training methods for non-intrusive appliance load monitoring from smart meter data”. Thesis (Doctor of Philosophy) – Faculty of Physical Science and Engineering, University of Southampton, Hampshire, 2014.

Pascal et al Vincent. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *J. Mach. Learn. Res.*, 11:3371–3408, December 2010.

Patel, Shwetak N., et al. "At the flick of a switch: Detecting and classifying unique electrical events on the residential power line." *Lecture Notes in Computer Science* 4717 (2007): 271-288.

PENHA, Deyvison de Paiva; CASTRO, Adriana Rosa Garcez. "Home Appliance Identification for Nilm Systems Based on Deep Neural Networks". In: *International Journal of Artificial Intelligence & Applications (IJAIA)*, pp.69– 80, v. 9, n. 2, March 2018.

PENHA, Deyvison de Paiva; CASTRO, Adriana Rosa Garcez. Convolutional neural network applied to the identification of residential equipment in non-intrusive load monitoring systems. In: *3rd International Conference on Artificial Intelligence and Applications*, pp. 11– 21, 2017. © CS & IT-CSCP 2017.

PROVOST, Foster; KOHAVI, Ron. Guest editors' introduction: On applied research in machine learning. *Machine learning*, v. 30, n. 2, p. 127-132, 1998.

Sergey Ioffe and Christian Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In David Blei and Francis Bach, editors, *ICML-15*, pages 448–456. *JMLR Workshop and Conference Proceedings*, 2015.

SHAW, Steven R. et al. Nonintrusive load monitoring and diagnostics in power systems. *IEEE Transactions on Instrumentation and Measurement*, v. 57, n. 7, p. 1445-1454, 2008.

Stephen Makonin, Fred Popowich, Ivan V. Bajic, Bob Gill, and Lyn Bartram. Exploiting HMM Sparsity to Perform Online Real-Time Non-Intrusive Load Monitoring. *IEEE Transactions on Smart Grid*, 2015.

SUZUKI K., INAGAKI S., SUZUKI T., NAKAMURA H., ITO K. “Nonintrusive Appliance Load Monitoring Based on Integer Programming.” *Proceedings of SICE Annual Conference; Tokyo, Japan. 20–22 August 2008; pp. 2742–2747.*

VARGAS, Ana Caroline Gomes; PAES, Aline; VASCONCELOS, Cristina Nader. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: *Proceedings of the XXIX Conference on Graphics, Patterns and Images. 2016. p. 1-4.*

Vilaca, N. M. C. A. A., Figueiredo, V. N., Oliveira, L. B., Ferreira, V. H., Fortes, M. Z., Correia, W. F., & Pacheco, O. L. (2014). Smart City—Caso de Implantação em Búzios—RJ. *Revista SODEBRAS*, 9(98).

WANG, Zhiguang; OATES, Tim. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks. In: *Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence. 2015.*

WONG, Yung Fei; DRUMMOND, T.; ŞEKERCIOĞLU, Y. A. Real-time load disaggregation algorithm using particle-based distribution truncation with state occupancy model. *Electronics Letters*, v. 50, n. 9, p. 697-699, 2014.

Yung Fei Wong, Y. Ahmet Sekercioglu, Tom Drummond, and VoonSiong Wong. Recent approaches to non-intrusive load monitoring techniques in residential settings. *IEEE Symposium on Computational Intelligence Applications in Smart Grid, CIASG*, pages 73-79, 2013.

ZHAO, Bochao; STANKOVIC, Lina; STANKOVIC, Vladimir. On a training-less solution for non-intrusive appliance load monitoring using graph signal processing. *IEEE Access*, v. 4, p. 1784-1799, 2016.

ZHENG, Yi et al. Exploiting multi-channels deep convolutional neural networks for multivariate time series classification. *Frontiers of Computer Science*, v. 10, n. 1, p. 96-112, 2016.

ZHENG, Yi et al. Time series classification using multi-channels deep convolutional neural networks. In: *International Conference on Web-Age Information Management*. Springer, Cham, 2014. p. 298-310.

Zico Kolter, Tommi Jaakkola, and J Z Kolter. Approximate Inference in Additive Factorial HMMs with Application to Energy Disaggregation. In *Proceedings of the International Conference on Artificial Intelligence and Statistics*, pages 1472-1482, 2012.

ZOHA, Ahmed et al. Non-intrusive load monitoring approaches for disaggregated energy sensing: A survey. *Sensors*, v. 12, n. 12, p. 16838-16866, 2012.