



**UNIVERSIDADE DA INTEGRAÇÃO INTERNACIONAL DA LUSOFONIA AFRO-  
BRASILEIRA**

**INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL**

**CURSO DE ENGENHARIA DE ENERGIAS**

**FRANCISCO WANDERSON FREITAS FERREIRA**

**IDENTIFICAÇÃO DE ASSINATURAS ELÉTRICAS DE CARGAS EM  
SUPERPOSIÇÃO, ATRAVÉS DE TRANSFORMADA DE GABOR E REDE MLP**

**REDENÇÃO - CE**

**2021**

FRANCISCO WANDERSON FREITAS FERREIRA

**IDENTIFICAÇÃO DE ASSINATURAS ELÉTRICAS DE CARGAS EM  
SUPERPOSIÇÃO, ATRAVÉS DE TRANSFORMADA DE GABOR E REDE MLP**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Energias do Instituto de Engenharias e Desenvolvimento Sustentável da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, como requisito parcial à obtenção do grau de bacharel em Engenharia de Energias.

Orientador: Prof. Me. Humberto Ícaro Pinto Fontinele.

REDENÇÃO - CE

2021

Universidade da Integração Internacional da Lusofonia Afro-Brasileira  
Sistema de Bibliotecas da UNILAB  
Catalogação de Publicação na Fonte.

---

Ferreira, Francisco Wanderson Freitas.

F439i

Identificação de assinaturas elétricas de cargas em superposição, através de transformada de Gabor e rede MLP / Francisco Wanderson Freitas Ferreira. - Redenção, 2021.  
92f: il.

Monografia - Curso de Engenharia de Energias, Instituto de Engenharias e Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Redenção, 2021.

Orientador: Prof. Humberto Ícaro Pinto Fontinele.

1. Redes elétricas inteligentes. 2. Redes neurais. 3. Gabor, Transformadas. I. Título

CE/UF/BSP

CDD 621.31

---

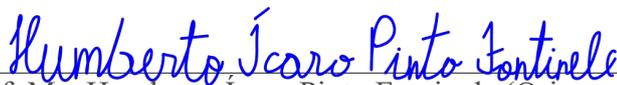
FRANCISCO WANDERSON FREITAS FERREIRA

**IDENTIFICAÇÃO DE ASSINATURAS ELÉTRICAS DE CARGAS EM  
SUPERPOSIÇÃO, ATRAVÉS DE TRANSFORMADA DE GABOR E REDE MLP**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Energias do Instituto de Engenharias e Desenvolvimento Sustentável da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, como requisito parcial à obtenção do grau de bacharel em Engenharia de Energias.

Aprovada em: 24/ 8 / 2021 .

BANCA EXAMINADORA



Prof. Me. Humberto Ícaro Pinto Fontinele (Orientador)

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)



Prof. Dr. Vandilberto Pereira Pinto

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)



Prof. Dr. Antônio Alisson Pessoa Guimarães

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

A Deus.

Aos meus pais, irmãs, esposa, professores e  
amigos.

## **AGRADECIMENTOS**

À UNILAB, por ter tornado esse sonho possível com toda a infraestrutura e apoio financeiro.

Ao Prof. Me. Humberto Ícaro Pinto Fontinele, pela excelente orientação.

Aos professores participantes da banca examinadora pelo tempo, pelas valiosas colaborações e sugestões.

A todos os professores do corpo docente do instituto que foram meus professores, pelos valiosos ensinamentos.

Aos meus pais, minhas irmãs e esposa por acreditarem em mim e sempre me apoiarem.

E a todos os colegas que fiz pelas turmas que passei, pelos conselhos e esforço nos trabalhos.

“Eu imagino um mundo onde a inteligência artificial nos permitirá ser mais produtivos, viver mais e ter energia mais limpa” (Fei-Fei Li)

## RESUMO

O monitoramento não intrusivo permite monitorar simultaneamente diversas cargas de uma instalação, realizando a medição em apenas um ponto da instalação. Portanto, esse tipo de monitoramento não requer o acesso físico a cada uma das cargas da instalação, o que significa redução significativa de custos com hardware. Porém, softwares sofisticados são necessários para essa tarefa, visto que os métodos para desagregar sinais elétricos individuais sobrepostos em um único sinal não é uma tarefa trivial. Esse é um dos avanços que podem resultar em novas tecnologias para *smart grid*. O aumento da participação da mini e micro geração por fontes renováveis e pela busca por um desenvolvimento mais sustentável impulsiona investimentos nos sistemas elétricos de distribuição. Nesse sentido, o trabalho propõe um método baseado em classificador neural com treinamento supervisionado e na análise de sinais nos domínios do tempo e frequência através da transformada de Gabor, para identificar transitórios de entradas e saídas de cargas. As cargas utilizadas para avaliar a eficácia do método foram reator eletrônico, lâmpadas incandescentes, motor de indução trifásico e motor de indução monofásico. Ao final, os resultados permitiram concluir que o método proposto apresentou um desempenho satisfatório para as configurações de rede neural implementada no trabalho.

**Palavras-chave:** monitoramento não intrusivo, desagregar sinais, *smart grid*, transformada de Gabor.

## ABSTRACT

Non-intrusive monitoring allows you to simultaneously monitor several loads in an installation, measuring at only one point in the installation. Therefore, this type of monitoring does not require physical access to each of the installation's loads, which means a significant reduction in hardware costs. However, sophisticated software is needed for this task, as the methods to disaggregate individual electrical signals superimposed into a single signal is not a trivial task. This is one of the advances that can result in new technologies for the smart grid. The increased participation of mini and micro generation from renewable sources and the search for a more sustainable development drives investments in electrical distribution systems. In this sense, the work proposes a method based on a neural classifier with supervised training and on the analysis of signals in the domains of time and frequency through the Gabor transform, to identify transients of input and output loads. The loads used to evaluate the effectiveness of the method were electronic ballast, incandescent lamps, three-phase induction motor and single-phase induction motor. In the end, the results allowed us to conclude that the proposed method presented a satisfactory performance for the neural network configurations implemented in the work.

**Keywords:** non-intrusive monitoring, signal disaggregation, smart grid, Gabor transform.

## LISTA DE FIGURAS

Figura 1	– Energia máxima armazenada x Capacidade de regularização .....	22
Figura 2	– Rede de comunicação básica de uma <i>Smart Grid</i> .....	24
Figura 3	– Evolução do medidor de energia .....	25
Figura 4	– Conceito de integração de uma <i>Smart Grid</i> .....	26
Figura 5	– Possibilidades de serviços prestados por baterias .....	31
Figura 6	– Monitoramento não intrusivo .....	33
Figura 7	– Sinais senoidais de 5, 10 e 15 Hz .....	38
Figura 8	– Sinais senoidais sobrepostos de 5, 10 e 15 Hz .....	39
Figura 9	– Transformada de Fourier .....	39
Figura 10	– Transformada de Gabor de $x(t)$ com melhor resolução no tempo .....	40
Figura 11	– Transformada de Gabor de $x(t)$ com melhor resolução na frequência .....	40
Figura 12	– Transformada de Gabor de $x(t)$ , com $\sigma = 1$ .....	41
Figura 13	– Efeito de contorno das janelas retangular, triangular e Hann .....	42
Figura 14	– Neurônio biológico x neurônio artificial .....	44
Figura 15	– Rede de Perceptrons .....	45
Figura 16	– Desenvolvimento da Inteligência Artificial .....	45
Figura 17	– Relação entre $v$ e $u$ .....	47
Figura 18	– Sigmoides e sua derivada .....	48
Figura 19	– Tangente hiperbólica e sua derivada .....	48
Figura 20	– Função limiar (ou degrau) .....	49
Figura 21	– ReLu .....	49
Figura 22	– Rede alimentada adiante com camada única .....	51
Figura 23	– Rede alimentada diretamente com múltiplas camadas .....	52
Figura 24	– Rede recorrente sem auto-realimentação ou camadas ocultas .....	52

Figura 25 – Aprendizagem supervisionada .....	53
Figura 26 – Aprendizagem supervisionada por reforço .....	54
Figura 27 – Aprendizado não-supervisionado .....	54
Figura 28 – Perceptron Multicamadas (MLP) .....	55
Figura 29 – Fluxo de sinal no neurônio de saída j .....	56
Figura 30 – Fluxo de sinal entre o neurônio j e o neurônio k .....	58
Figura 31 – Sinal de corrente do reator eletrônico com lâmpadas fluorescentes .....	68
Figura 32 – Sinal de corrente das lâmpadas incandescentes .....	68
Figura 33 – Sinal de corrente de uma fase do MIT .....	69
Figura 34 – Sinal de corrente do motor de indução monofásico .....	69
Figura 35 – Espectrograma da corrente do reator eletrônico .....	70
Figura 36 – Espectrograma da corrente das lâmpadas incandescentes .....	71
Figura 37 – Espectrograma da corrente do MIT .....	71
Figura 38 – Espectrograma da corrente do motor de indução monofásico .....	72
Figura 39 – Espectrograma do reator eletrônico em escala de cinza e redimensionado para 5% .....	72
Figura 40 – Espectrograma das lâmpadas incandescentes em escala de cinza e redimensionado para 5% .....	73
Figura 41 – Espectrograma do MIT em escala de cinza e redimensionado para 5% .....	73
Figura 42 – Espectrograma do motor de indução monofásico em escala de cinza e redimensionado para 5% .....	73
Figura 43 – EQM do treinamento para reator eletrônico .....	74
Figura 44 – EQM do treinamento para lâmpadas incandescentes .....	74
Figura 45 – EQM do treinamento para MIT .....	75
Figura 46 – EQM do treinamento para motor de indução monofásico .....	76

## LISTA DE TABELAS

Tabela 1 – Matriz de confusão de múltiplas classes .....	67
Tabela 2 – Matriz de confusão .....	77

## LISTA DE ABREVIATURAS E SIGLAS

AMI	<i>Advanced Metering Infrastructure</i> (Infraestrutura de medição avançada)
AMR	<i>Automated Meter Reading</i> (Leitura automatizada do medidor)
CA	Corrente Alternada
EAR	Energia Armazenada
EPE	Empresa de Pesquisa Energética
EQM	Erro Quadrático Médio
FFT	<i>Fast Fourier Transform</i> (Transformada rápida de Fourier)
FP	Falso Positivo
GUI	<i>Graphical User Interface</i> (Interface gráfica do usuário)
HAN	<i>Home Area Network</i> (Rede de Área Doméstica)
IA	Inteligência Artificial
IEC	<i>International Electrotechnical Commission</i> (Comissão Eletrotécnica Internacional)
MLP	<i>MultiLayer Perceptron</i> (Perceptron Multicamadas)
MME	Ministério de Minas e Energia
NAN	<i>Neighborhood Area Network</i> (Rede de Área de Vizinhança)
NILM	<i>Nonintrusive Load Monitoring</i> (Monitoramento de Carga não Intrusivo)
ONS	Operador Nacional do Sistema Elétrico
PLC	<i>Power Line Communication</i> (Comunicação via rede elétrica)
RMR	<i>Remote Meter Reading</i> (Leitura de Medidor Remoto)
RNA	Rede Neural Artificial
STFT	<i>Short Time Fourier Transform</i> (Transformada de Fourier de curto tempo)
VP	Verdadeiro Positivo
WAN	<i>Wide Area Network</i> (Rede de Área Ampla)

## LISTA DE SÍMBOLOS

$W$	Watt
$\partial$	Derivada parcial
$\Sigma$	Somatório
%	Porcentagem
$\sigma$	Meira largura da janela
$x_0$	Entradas
$w_0$	Pesos
$b$	Bias
$f$	Função de ativação

## SUMÁRIO

<b>1.</b>	<b>INTRODUÇÃO</b>	<b>17</b>
1.1	OBJETIVOS	18
1.1.1	Objetivo geral	18
1.1.2	Objetivos específicos	18
1.2	METODOLOGIA	19
1.3	JUSTIFICATIVA	19
1.4	ESTRUTURA DO TRABALHO	20
<b>2.</b>	<b>SMART GRIDS</b>	<b>22</b>
2.1	INTRODUÇÃO	22
2.2	ATUAIS DESAFIOS PARA IMPLEMENTAÇÃO DE SMART GRIDS	29
2.3	IDENTIFICAÇÃO DE CARGAS ELÉTRICAS EM SUPERPOSIÇÃO	32
<b>3.</b>	<b>TRANSFORMADA DE GABOR DE REDE MLP</b>	<b>36</b>
3.1	A TRANSFORMADA DE GABOR	36
3.2	REDE NEURAL ARTIFICIAL	43
3.3	A REDE MLP	55
<b>4.</b>	<b>METODOLOGIA PROPOSTA</b>	<b>63</b>
4.1	INTRODUÇÃO	63
4.2	DEFINIÇÃO DO PROBLEMA	63
4.3	METODOLOGIA DO TRABALHO	64
4.3.1	Aquisição dos Dados	65
4.3.2	Tratamento dos Dados	65
4.3.3	Particionamento dos Dados	66
4.4	TREINAMENTO	66
4.4.1	Seleção de Hiperparâmetros	66
4.4.2	Critério de Parada do Treinamento	67
4.5	O CLASSIFICADOR	
4.6	TESTE DOS MODELOS (MATRIZ DE CONFUSÃO)	68
<b>5.</b>	<b>RESULTADOS</b>	<b>70</b>
5.1	RESULTADOS NO TRATAMENTO DOS DADOS	70
5.2	TREINAMENTO	76
5.3	MATRIZ DE CONFUSÃO	79
<b>6.</b>	<b>CONCLUSÃO</b>	<b>81</b>
6.1	RESUMO DAS CONTRIBUIÇÕES DESTE TRABALHO	81

6.2	CONSIDERAÇÕES GERAIS O MÉTODO PROPOSTO	82
6.3	CONSIDERAÇÕES FINAIS	82
6.4	SUGESTÕES DE TRABALHOS FUTUROS	82
	<b>REFERÊNCIAS</b>	<b>83</b>
	<b>ANEXO I</b>	<b>89</b>

## 1. INTRODUÇÃO

A crescente incorporação de novas fontes de energia ao sistema elétrico tem levado as distribuidoras a pensarem na modernização das suas infraestruturas. Diante da evolução da geração distribuída e do aumento da participação da geração eólica e solar, têm surgido novos desafios para se garantir um fornecimento de energia de qualidade. Além disso, a relação das distribuidoras com o consumidor vem mudando nos últimos anos. Estes, que até então eram consumidores cativos totalmente dependentes do fornecimento da distribuidora, agora são clientes com a possibilidade de produzir a sua própria energia e ter um abatimento na sua fatura, através do sistema de compensação (DE CASTRO *et al.*, 2019).

As crises do setor petrolífero, que tiveram grande impacto nas economias emergentes, as secas prolongadas, que provocaram racionamento de energia e aumento da tarifa, e a preocupação com um desenvolvimento sustentável, tem motivado cada vez mais a diversificação das fontes de energia, buscando-se ter mais segurança no fornecimento deste recurso.

Junto à utilização de fontes renováveis, também se tem implementado medidas de eficiência energética, como medida para mitigar a necessidade da construção de novas usinas, para atender o crescimento da demanda. Todas essas mudanças no setor elétrico demandam grande empenho das concessionárias e dos órgãos governamentais, como o Operador Nacional do Sistema Elétrico (ONS) e a Empresa de Pesquisa Energética (EPE), no planejamento da demanda e na criação de regulamentações, visto que os cenários de demanda estão em constante evolução (DE CASTRO *et al.*, 2018).

A preocupação com mudanças climáticas, decorrentes de exploração de recursos energéticos não renováveis, como o petróleo e o carvão, tem motivado cada vez mais a adoção de fontes renováveis, tanto por grandes empresas quanto pelos pequenos consumidores. Mais importante ainda para a mudança cultural dos consumidores, é a possibilidade de maior independência energética e estabilidade financeira, uma vez que os reajustes de tarifa não são tão importantes para os consumidores que optaram por energias renováveis (DE CASTRO *et al.*, 2019).

O consumidor terá cada vez mais impacto no planejamento energético do país e na regulação tarifária, dado que este terá mais liberdade para negociar os serviços oferecidos, decorrente da redução do limite para acesso ao mercado livre, cuja abertura para consumidores com menor potência instalada apresenta como vantagens a redução da tarifa e o aumento da eficiência, no qual se reconhece que as distribuidoras devem focar suas atividades na

modernização da infraestrutura da rede e na qualidade de serviços prestados, e não apenas na venda de energia (MINISTÉRIO DE MINAS E ENERGIA - MME, 2019).

Uma das estratégias para se postergar o investimento na instalação de novas usinas geradoras é investir em eficiência energética, o que permite diminuir o consumo de energia, mantendo-se o nível de conforto ou produtividade demandada pelos consumidores.

Uma maneira que permite consumir energia de forma eficiente é ter acesso à fatura estratificada da energia elétrica, pois com essas informações é possível identificar as cargas mais significativas, permitindo que o usuário defina estratégias para reduzir ou alterar o horário de utilização dessas cargas, para um horário de menor tarifa. Motivado por este cenário, esse trabalho propõe desenvolver um método que permita estratificar, de forma eficaz, a conta de energia elétrica de uma residência, através de leituras de energia realizada apenas no ponto de alimentação geral da instalação. O método proposto é baseado em transformada de Gabor e rede neural artificial (RNA) do tipo *MultiLayer Perceptron* (MLP).

## 1.1 OBJETIVOS

### 1.1.1 Objetivo geral

O objetivo desse trabalho é elaborar um classificador neural capaz de discriminar cargas elétricas alimentadas simultaneamente por um mesmo circuito, utilizando-se transformada de Gabor para identificação de transientes e para a geração dos atributos necessários para o projeto do classificador neural. Inicialmente a rede MLP será treinada para identificar cada uma das assinaturas, individualmente, utilizando como atributos os dados gerados pela transformada de Gabor, para diferentes janelas de observação, com diferentes amplitudes. A base de dados para treinamento da rede foi coletada em laboratório, através de um circuito elétrico simples, que opera com somente um equipamento energizado por vez. Por fim, o desempenho do classificador é testado em um circuito onde vários equipamentos estão energizados simultaneamente.

### 1.1.2 Objetivos específicos

Para se obter o objetivo geral, os seguintes objetivos específicos são desenvolvidos.

- Realizar a aquisição de dados de corrente, de transiente e de regime permanente, das cargas que se deseja reconhecer a assinatura elétrica, através de osciloscópio.
- Tratar os dados obtidos por meio do software Matlab<sup>®</sup>.

- Transformar os dados utilizando a transformada de Gabor, no intuito de identificar os instantes de início e fim dos transientes das cargas, assim como realizar a extração de atributos para construção de um banco de dados para o treinamento das redes neurais artificiais do tipo MLP.
- Treinar redes neurais MLP, utilizando o software Matlab<sup>®</sup>, para modelar os padrões de assinatura elétrica de quatro tipos de carga.
- Projetar um classificador, baseado nas respostas das redes MLPs, para classificação das diferentes cargas;
- Avaliação dos resultados obtidos;

## 1.2 METODOLOGIA

Esta pesquisa adota a seguinte sequência de procedimentos como metodologia:

- Aquisição de dados;
- Tratamento dos dados (filtragem, eliminação de outliers e normalização);
- Transformação dos dados através da transformada de Gabor;
- Avaliação da eficácia da transformada de Gabor na identificação dos transientes das cargas de teste;
  - Extração de características por meio da transformada de Gabor, utilizando-se diferentes tipos de janelas, com diferentes amplitudes;
  - Utilizar a transformada de Gabor para reconhecer instantes de entrada e saídas de carga, através da observação da variação temporal do espectro de frequência do sinal de corrente, de modo a permitir o desacoplamento destas e o posterior reconhecimento individual da assinatura elétrica, mesmo que os sinais de diversas cargas estejam sobrepostos.
  - Projetar e avaliar um classificador baseado em rede MLP para classificar a assinatura de quatro diferentes cargas elétricas, sendo utilizado como atributo de entrada das redes os espectrogramas da transformada de Gabor, para diferentes funções de janelas, como atributos de entrada da rede;
  - Avaliar o desempenho do classificador para uma aplicação real.

## 1.3 JUSTIFICATIVA

Uma *smart grid* reúne muitos equipamentos de medição, telecomunicações,

processamento de dados, sensoriamento e automação. Um dos desafios para as *smart grid* é a identificação de assinaturas elétricas, que podem ser utilizadas para permitir reconhecer a entrada e saída de cargas específicas no sistema e a identificação de falhas elétricas na rede e em equipamentos, entre outras tarefas. A proposta deste trabalho é contribuir com as pesquisas voltadas a identificação de assinaturas elétricas, aplicadas na tarefa de estratificação de contas de energia, como uma forma de permitir que o usuário final utilize a energia de forma mais eficiente.

Entregar ao usuário uma ferramenta de estratificação de faturas pode ser uma forma eficiente de reduzir o consumo de energia elétrica, especialmente em horários de ponta. Além disso, faturas estratificadas permitem que o usuário identifique facilmente as cargas mais significativas em sua residência, facilitando assim a definição de estratégias para tornar o consumo da energia mais eficiente como, por exemplo, deslocando o uso de determinadas cargas para horários fora de ponta, reduzindo o tempo de uso dessas cargas ou até mesmo substituindo equipamentos menos eficientes por equipamentos de melhor eficiência.

#### 1.4 ESTRUTURA DO TRABALHO

Este trabalho divide-se em seis capítulos. No primeiro capítulo se faz uma introdução ao tema objeto de pesquisa deste trabalho, os objetivos estabelecidos para a pesquisa, a metodologia adotada e a justificativa do tema escolhido.

No segundo capítulo é feita uma revisão bibliográfica sobre as *smart grids*, considerando os conceitos que a cercam e o seu potencial de melhoria dos serviços de fornecimento de energia.

No terceiro capítulo é exposto uma revisão detalhada da transformada de Gabor e como essa transformada pode ser aplicada na identificação do transiente das cargas, além de uma revisão bibliográfica sobre as redes neurais artificiais, e mais detalhadamente sobre a rede *MultiLayer Perceptron* (MLP) utilizada neste trabalho.

No quarto capítulo é apresentada a metodologia adotada neste trabalho, descrevendo a geração do conjunto de dados das cargas a serem identificadas, o tratamento desses dados antes da submissão ao processo de extração de características, a seleção dos parâmetros de treinamento, o treinamento da RNA e, por fim, os testes quantitativos dos modelos construídos.

No capítulo cinco estão presentes os principais resultados obtidos nos testes dos

modelos construídos através da rede MLP, para identificação das assinaturas elétricas das cargas de teste, em sobreposição em um mesmo circuito.

Por fim, no capítulo seis é mostrado as conclusões sobre os resultados obtidos, assim como as contribuições desta pesquisa e sugestões de trabalhos futuros.

## 2. SMART GRIDS

### 2.1 INTRODUÇÃO

O modo de vida moderno que dispõe de vários aparelhos elétricos para as atividades cotidianas, só é possível graças aos avanços tecnológicos promovidos pela engenharia, e que vêm sendo empregados também no desenvolvimento do setor elétrico, o qual tem modificado profundamente a vida das pessoas.

Desde a construção do primeiro sistema elétrico de potência em corrente alternada, feita por William Stanley e financiado por George Westinghouse em 1886, e o seu aperfeiçoamento em 1887 por Nikola Tesla, este tem passado por muitas transformações. As principais evoluções do setor elétrico podem ser cronologicamente organizadas da seguinte forma: 1885 o transformador CA; 1887 a máquina síncrona trifásica; 1891 o transformador trifásico a seco; 1895 a geração hidrelétrica, a transmissão e distribuição em CA; 1984 geração fotovoltaica (BATTAGLIN; BARRETO, 2011).

Até 2050 o crescimento populacional esperado será de 21 milhões, que corresponde a 0,3% a.a., e o aumento previsto no número de domicílios será de 33 milhões. Em virtude deste crescimento populacional, o aumento da demanda de energia esperado varia entre 1,4% e 2,2% a.a. (EPE, 2018). Nesse cenário, o papel do consumidor é muito importante para o desenvolvimento do setor energético, visto que este pode mudar o seu comportamento, direcionando-o para contribuir com a uma rede descentralizada, descarbonizada e digitalizada (WILLIAMS; SHORT, 2020).

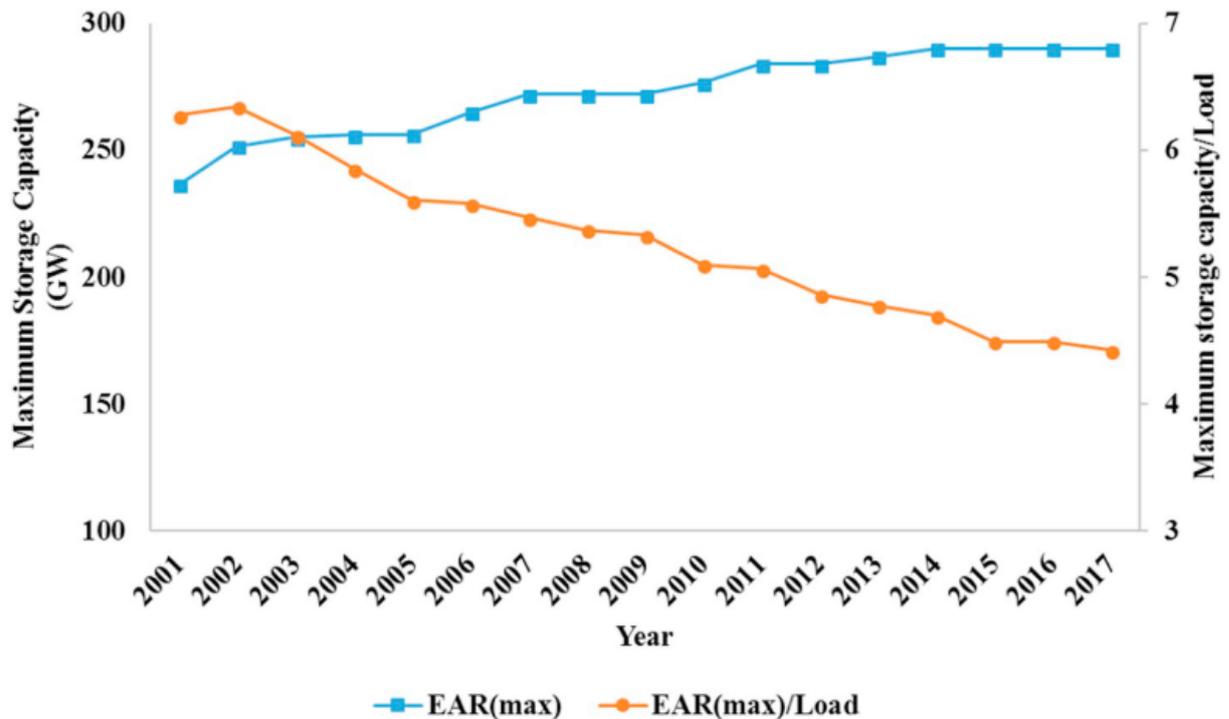
A matriz energética brasileira tem em operação 174.883,1 MW de potência instalada, sendo, 58,34% de usinas hidrelétricas, 25,08% de termoeletricas, 10% de eólica, 3,12% de pequenas centrais hidrelétricas, 1,87% de fotovoltaica, 1,13% de nuclear e 0,47% de centrais geradoras hidrelétrica (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL, 2021). A participação percentual da fonte hídrica na matriz energética vem constantemente reduzindo devido à crescente participação de novas fontes de energia e a questões socioambientais que desencorajam a implantação de usinas com grandes reservatórios. No entanto, tem sido implantado cada vez mais usinas a fio-d'água, que não possuem reservatórios ou são de dimensões reduzidas. Isso torna o sistema mais sensível às mudanças dos ciclos hidrológicos, o que representa um aumento no risco de desabastecimento e pode acarretar o aumento da tarifa de energia, dado que pode ser necessário despachar mais usinas termoeletricas para suprir a demanda (DRANKA, FERREIRA, 2020).

Embora a energia armazenada máxima  $EAR(max)$  tenha aumentado com a

implantação de usinas a fio d'água nos últimos anos, a capacidade de regularização EAR(max)/Load, tem diminuído significativamente. A capacidade regularização é uma medida da capacidade dos reservatórios do sistema elétrico de regularizar a geração de energia no período seco.

A Figura 1 retrata a relação entre a EAR(max) em GW e a EAR(max)/Load em meses, no período de 2001 a 2017. É possível observar que ocorreu uma redução constante da capacidade de regularização, embora tenha havido aumento na EAR(max). Nos anos de 2001 e 2002 se tinha aproximadamente 6,2 meses de suprimento energético, ou seja, os reservatórios das usinas hidrelétricas poderiam suprir a demanda nacional por 6,2 meses sem a contribuição de outras fontes. Devido aos motivos já citados, a instalação de usinas a fio d'água tem contribuído para o aumento da energia armazenada máxima, mas, por não se ter grandes reservatórios, este acréscimo não tem acompanhado o crescimento na demanda. Dessa forma, a capacidade de regularização do sistema elétrico reduziu para aproximadamente 4,4 meses até 2017 (DRANKA, FERREIRA, 2020).

Figura 1 – Energia máxima armazenada x Capacidade de regularização



Fonte: (DRANKA, FERREIRA, 2020)

Outro desafio a ser vencido pelos responsáveis pela operação o sistema elétrico de potência é a redução das perdas, permitindo que a demanda possa ser atendida de forma satisfatória, sem a necessidade da ampliação imediata da capacidade de geração.

As perdas do sistema elétrico de potência podem ser divididas em técnicas e não

técnicas, sendo as não técnicas aquelas provenientes dos furtos de energia. No Brasil as perdas são estimadas em 6,6% da energia total injetada, totalizando-se 33,3 TWh, e custam R\$ 5 bilhões ao ano para os consumidores, representando cerca de 3% da tarifa de energia (ANEEL, 2019). Vale destacar que no intervalo de 2018 a 2019 a tarifa no ambiente de contratação regulada aumentou em média 7,8%. Embora menor que no período anterior de 2017 a 2018, no qual aumentou em média 12,6%, o aumento da tarifa em todo o território brasileiro foi superior a 6% (EPE, 2020).

Devido a essas questões e a busca por melhorias no setor elétrico, este tem progredido para um sistema descentralizado, digitalizado, com interconexão e armazenamento de energia (WEC, 2019). Em 2005, Bruce F. Wollenberg e S. M. Armin cunharam o termo “*smart grid*”, em seu trabalho intitulado “*Toward A Smart Grid*”, descrevendo uma rede elétrica inteligente, que é preparada para suportar as demandas futuras do setor elétrico (BANCO NACIONAL DE DESENVOLVIMENTO ECONÔMICO E SOCIAL - BNDES, 2013).

As melhorias buscadas com a construção de uma *smart grid* necessitariam de conectividade e troca de informações entre pessoas e máquinas e entre máquinas entre si. E isto vem sendo possível graças a desenvolvimentos tecnológicos nas áreas de computação em nuvem (*Cloud Computing*), internet das coisas (*Internet of Things — IoT*), *Big Data*, inteligência artificial (*Artificial Intelligence — AI*), internet de banda larga e mobilidade em redes sem fio (JOÃO *et al.*, 2019).

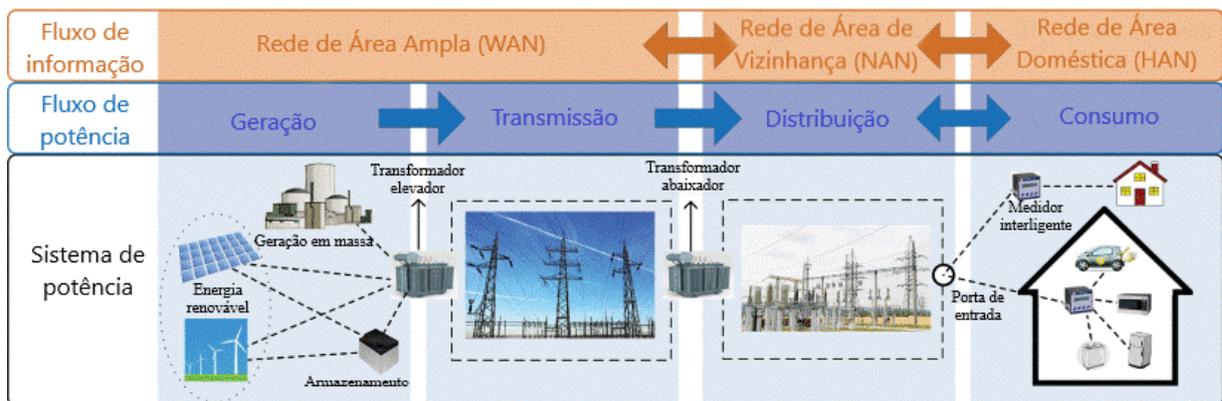
O conceito de *smart grid* pode parecer de difícil compreensão e na literatura é possível encontrar conceituações brevemente distintas. Nem todas as soluções tecnológicas podem ser aplicadas em todos os possíveis cenários, por isso, diferentes visões de uma *smart grid* podem surgir, mas todas elas compartilham uma similaridade: há uma infraestrutura que integra, através de tecnologias de telecomunicações, medição, processamento de dados e automação, os consumidores, as distribuidoras, as transmissoras e as geradoras (ROSS *et al.*, 2017).

Para as *smart grids*, as tecnologias mais visíveis são os medidores inteligentes. Grande parte das funcionalidades propostas pela *smart grid* encontram-se vinculadas justamente a esses equipamentos, que se tornarão a janela de comunicação entre o consumidor e a concessionária. Estes devem proporcionar uma comunicação bidirecional entre o consumidor e a distribuidora, registrando o consumo em tempo real, monitorando a qualidade de energia, a ocorrência de faltas e as tentativas de furto de energia. Além de possibilitar a integração da rede com a geração distribuída e o armazenamento de energia (AVANCINI *et al.*, 2019).

A criação de uma *smart grid* requer a integração de sensores inteligentes, instalados por longas distâncias e para milhares de consumidores, além da instalação de medidores inteligentes. O volume de dados criado pela *smart grid* torna necessário adotar um sistema robusto de gerenciamento de dados, capaz de lidar com seu grande volume e extrair informações úteis. Através destes dados, as concessionárias podem entender melhor a demanda, as condições de funcionamento da rede, localizar falhas e tentativas de furto de energia. Os consumidores podem ter acesso a dados de consumo em tempo real e informações sobre a tarifa vigente, incentivando assim o consumo no horário fora ponta, por exemplo. Com isso, a *smart grid* tem uma grande capacidade de promover o gerenciamento de energia pelo lado da demanda (DAKI *et al.*, 2017).

Na Figura 2 ilustra uma visão esquemática de cada nível de abrangência geográfica da rede de comunicação básica de uma *smart grid*.

Figura 2 – Rede de comunicação básica de uma *Smart Grid*



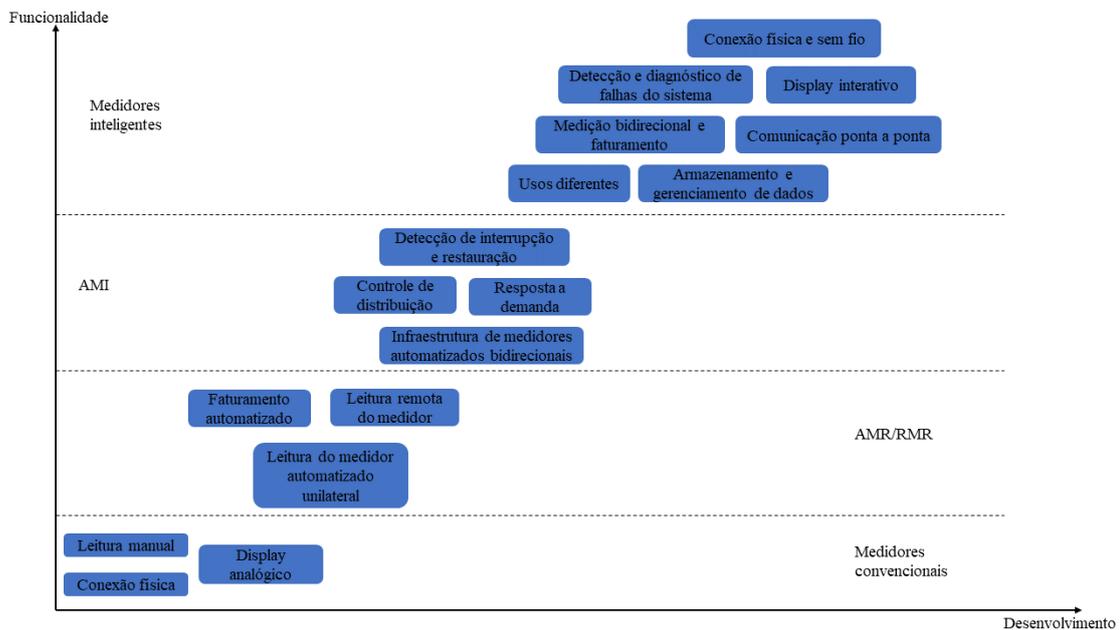
Fonte: (SALEEM *et al.*, 2019)

Dependendo da arquitetura, a informação que circula pela *smart grid* pode passar por até três níveis de abrangência geográfica, até chegar à distribuidora, e também utilizar diferentes tecnologias de comunicação. O primeiro nível é denominado de *Home Area Network* (HAN) ou Rede de Área Doméstica, o qual conecta os dispositivos residenciais com o medidor inteligente, e pode ser utilizando em tarefas de automação residencial. As tecnologias de comunicação mais comumente empregadas podem ser o ZigBee, Bluetooth e Wi-Fi, sendo este último o mais popular. Para o segundo nível, tem-se o *Neighborhood Area Network* (NAN) ou Rede de Área de Vizinhança, que ocorre a comunicação de dados dos diversos medidores com um concentrador de dados local. As tecnologias empregadas para tal nível podem ser a Wi-Fi e RF Mesh. Por fim, no terceiro nível vem a *Wide Area Network* (WAN) ou Rede de Área Ampla. Cujas NANs se comunicam entre si, coletando dados de medição e enviando para a central de dados das distribuidoras. As tecnologias empregadas para esse nível pode ser a rede celular de última geração (5G), ou gerações anteriores, a fibra óptica e *Power Line*

Communication (PLC) ou comunicação via rede elétrica (AVANCINI *et al.*, 2019; DAKI *et al.*, 2017, SALEEM *et al.*, 2019).

Dispondo-se dessas tecnologias e arquitetura de rede, os primeiros passos na evolução dos medidores de energia podem ser descritos como a implementação do *Automated Meter Reading* (AMR) e do *Remote Meter Reading* (RMR), que realizam a medição e reportam à concessionária o consumo, sem a necessidade de intervenção humana (SUN, *et al.*, 2016). A combinação da infraestrutura de rede supracitadas com os medidores inteligentes, constituem o *Advanced Metering Infrastructure* (AMI) ou infraestrutura de medição avançada. Especificamente, para um medidor que faz parte do AMI ser considerado inteligente, este deve ser capaz de se conectar à rede de comunicação física e remotamente, ter um display interativo, dispor de comunicação bidirecional, detectar e diagnosticar falhas no sistema, poder adquirir outras funcionalidades com a adição de módulos, ter um sistema de armazenamento e gerenciamento de dados e ter comunicação ponta a ponta (AVANCINI *et al.*, 2019). A evolução dos medidores de energia, em termos de funcionalidade, pode ser conferida na Figura 3.

Figura 3 - Evolução do medidor de energia



Fonte: Adaptado de (AVANCINI *et al.*, 2019)

Eventuais problemas de fornecimento que possam surgir em *smart grids* tendem a ser rapidamente localizados e solucionados, visto que estas podem atuar isolando-se o problema e em seguida, envia, instantaneamente, informação à central de operações. Ademais, permite restabelecer rapidamente o suprimento de energia para os consumidores que foram afetados por falhas, bem como, analisar e redistribuir o fornecimento para aquelas linhas com reserva de capacidade, o que representa uma economia considerável para os clientes, que estariam sujeitos

a diversos prejuízos com a interrupção ou falhas no fornecimento de energia, como perdas de produção, prestação de serviços e entre outros (KABALCI, 2016; MME, 2010).

O Brasil, por ter seu sistema elétrico interligado, necessita de soluções que integrem as diferentes regiões produtoras. Contudo, para que não haja conflito entre as tecnologias empregadas pelos diferentes agentes de distribuição, é importante que se definam padrões a serem seguidos na construção da *smart grid*, enquanto se promove a competição, evitando-se os monopólios de tecnologias e permitindo-se, assim, a diminuição dos custos de implantação.

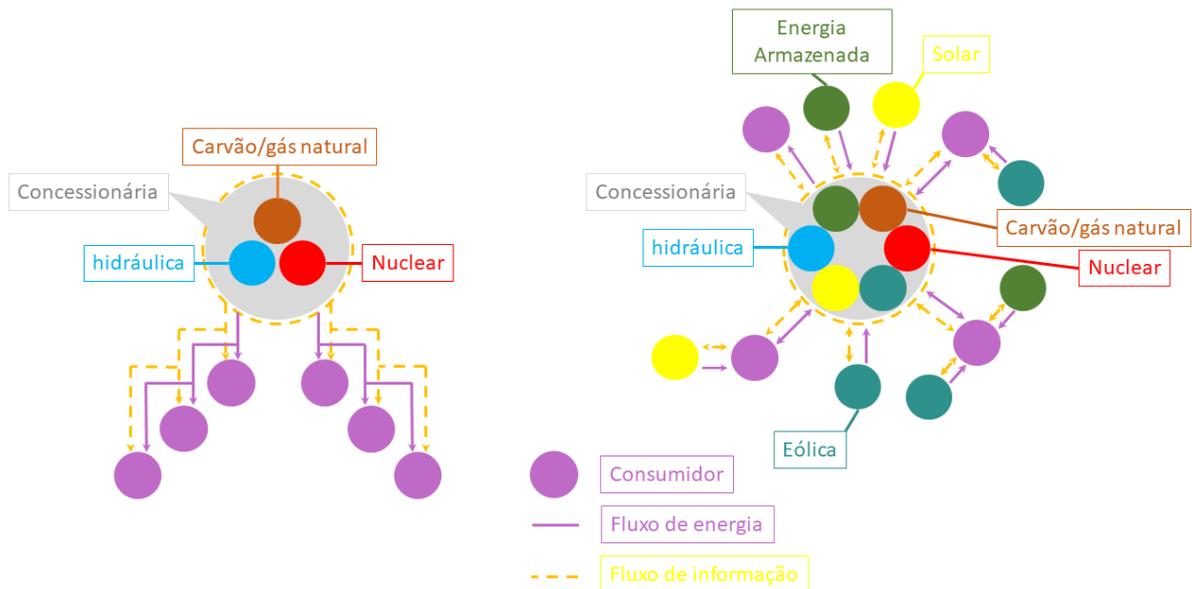
Para que o sistema opere de forma coordenada, pretende-se que as interfaces de comunicação de dados, bem como sua modelagem, sigam um protocolo aberto, público e padronizado, possibilitando a utilização de equipamentos e softwares de diferentes fornecedores e permitindo a interoperabilidade do sistema (MME, 2010, p. 13).

A base da *smart grid* está no sistema de telecomunicações e, dependendo da topografia da rede, pode haver a necessidade de desenvolvimento de uma tecnologia individualizada a ser empregada em cada nível. Sendo a sincronia da rede, requisito indispensável, realizada no nível WAN, para promover sua integração, além de atender a critérios mínimos de confiabilidade, segurança e eficiência. Entre esses critérios, podemos citar a economicidade da energia, a diminuição de perdas, a maior participação dos consumidores, através de micro e minigeração, segurança, confiabilidade e flexibilidade, além de velocidade de resposta a falhas (AVANCINI et al., 2019).

Uma característica obrigatória das *smart grids* é a comunicação bidirecional entre a concessionária e o cliente. Para que essa comunicação funcione de forma eficiente, a *smart grid* precisa dispor de sensoriamento remoto, capaz de detectar falhas em qualquer ponto da rede e de se auto recuperar ou restringir o problema a uma área reduzida, o mais rápido possível, de forma que afete o menor número possível de consumidores. Além disso, os sensores devem capturar, em tempo real, dados de operação da rede, ajudando os operadores a tomar decisões mais assertivas (MME, 2010).

Uma visão de como a *smart grid* deve funcionar e cumprir seu papel de integradora de recursos energéticos é mostrada na Figura 4.

Figura 4 - Conceito de integração de uma *Smart Grid*



Fonte: Adaptado de (MME, 2010)

No diagrama da esquerda, ilustra como a rede elétrica convencional funciona. Nela o fluxo de informação possui sentido único, da concessionária para o cliente, na forma da fatura de energia, e o cliente é simplesmente um consumidor. Além disso, as fontes de energia são limitadas às fontes convencionais.

Já no diagrama da direita, é mostrado o conceito de *smart grid*, que é a integração das fontes de energia convencionais com as intermitentes, como a solar e eólica, tanto como minigeração quanto microgeração, cujos clientes também são geradores de sua própria energia e podem injetá-la à rede, em troca de benefícios. Assim, para que toda a integração seja efetivada, o fluxo de informação deve ser nos dois sentidos, entre o cliente e a concessionária.

Pelo esquema é possível observar uma maior densidade de informações compartilhadas entre os clientes e a concessionária em redes do tipo *smart grids*. Essa nova característica na rede também demanda dos operadores uma reestruturação das centrais e da forma com que trabalham, visto que novos serviços tendem a surgir e os trabalhos que antes deveriam ser feitos presencialmente, como a entrega da fatura, podem ser feitos remotamente. Esse novo paradigma exige que a equipe seja treinada para realizar os serviços da concessionária utilizando as novas tecnologias.

A integração dos vários recursos na criação de uma *smart grid* exige a construção de uma arquitetura de rede adequada. Por arquitetura de rede entendemos como a forma da disposição de seus elementos, como estes estão interligados e como os protocolos são utilizados para que estes se comuniquem e promovam a integração dos recursos distribuídos e da comunicação bidirecional requerida na *smart grid*.

De acordo com Ornelas *et al.* (2016), a arquitetura da rede deve ser escolhida

considerando, entre outros fatores, a densidade populacional e a latência de cada nível da *smart grid*. Além disso, precisa ser cada vez mais rápida, à medida que a informação atinge os diferentes níveis, aproximando-se dos bancos de dados das concessionárias, visto que tais níveis, a informações vão se concentrando e a comunicação entre os operadores e as subestações necessitam de alta agilidade para que a automação responda na velocidade necessária para o correto funcionamento da rede.

## 2.2 ATUAIS DESAFIOS PARA IMPLEMENTAÇÃO DE SMART GRIDS

Alguns dos desafios que as concessionárias têm enfrentado mundialmente concentram-se na sobrecarga do sistema de potência devido ao crescimento da demanda e ao surgimento de novas cargas significativas, como, por exemplo, o carro elétrico. Outro fator, a grande distância entre a geração e a carga, seja devido à alta exploração de fontes hídricas próximas dos centros de consumo ou as restrições técnicas, econômicas e socioambientais. Além disso, as concessionárias necessitam aprimorar os dispositivos de proteção de rede, devido ao crescente impacto que a geração distribuída produz, visto que esta fonte de energia apresenta disponibilidade flutuante (DRANKA, FERREIRA, 2020).

Observando este ponto, Dantas *et al.*, (2018) aponta que as medidas públicas mais eficazes no incentivo a criação da *smart grid* seriam políticas que promovam o gerenciamento pelo lado da demanda, a geração distribuída e o armazenamento de energia. Adicionalmente, são necessárias mudanças regulamentares para fomentar a inovação no setor energético, além da definição de padrões de comunicação para os diversos dispositivos de rede.

A abundância de dispositivos, níveis de rede e de dados que podem circular pela *smart grid* representam, certamente, um desafio ao sistema de comunicação, desde que o processamento for concentrado em uma única central e se não forem adotados padrões para toda a rede. Por isso, uma estratégia para reduzir o volume de dados e, em simultâneo, diminuir o consumo de energia e a latência do sistema de comunicação, seria realizar o processamento próximo aos medidores e sensores inteligentes. Dessa forma somente metadados, dados dos dados, seriam enviados para o processamento central (STOJKOSKA; TRIVODALIEV, 2017; DAKI *et al.*, 2017).

Assim, de acordo com a *International Electrotechnical Commission* — IEC (2010), organização mundial responsável por preparar e publicar normas internacionais para todas as tecnologias elétricas, eletrônicas e relacionadas, a tecnologia não é um desafio para a implementação da *smart grid*. O principal desafio está na definição de padrões que proporcionem os maiores benefícios para os clientes e ofereçam interoperabilidade e segurança

em todos os seus níveis.

A IEC (2020) também aponta que padrões e práticas maduras já estão disponíveis, porém os responsáveis pelos projetos das *smart grids* tem pouco conhecimento dessas práticas. Mesmo que os responsáveis pelo projeto tenham conhecimento de padrões que parecem se encaixar, mas que foram desenvolvidos por diferentes organizações, a rede pode não ter a interoperabilidade desejada, pois cada organização desenvolve seus padrões com diferentes interesses.

Neste contexto, a IEC desenvolveu uma série de normas para as *smart grids*. Dentre as quais, destacam-se a IEC / TR 62357, que trata do gerenciamento de sistemas de energia e da troca de informações associadas. Por sua vez, a IEC 61970 a qual trata de modelos de informação voltados para o gerenciamento de energia, enquanto a IEC 61850 aborda a automação das concessionárias de energia. Outras normas da IEC relacionada a *smart grids* está condicionada a IEC 61968, que estabelece um modelo de informações voltado para o gerenciamento da distribuição, bem como, a IEC 62351, que trata da segurança da *smart grid*. Por fim, a IEC 62056 é responsável por definir padrões para a troca de dados entre os medidores e concentradores, o controle da tarifa e cargas, enquanto a IEC 61508 trata da integridade funcional dos sistemas elétricos relacionados à segurança.

Como a *smart grid* trabalha com uma grande variedade de dados dos clientes e do status da própria rede, há preocupações de invasões aos sistemas de comunicação por *hackers*. Esses ataques podem visar tanto os dados do cliente, obtidos pelo medidor eletrônico, como a própria rede, colocando em risco o serviço. Dessa forma, a concessionária precisa enfrentar esse desafio, que é decorrente da maior digitalização da rede elétrica e da implantação de novos recursos de gerenciamento a distância. A segurança e a privacidade deve ser um campo de constante atualização, além de ser necessário discutir os limites do direito da concessionária de acessar e divulgar dados de clientes.

Os diversos países que já dispõem de *smart grids* adotam padrões de intervalo de medições distintos, que vão desde minuto a minuto, até hora em hora, ou até mesmo medições mensais. No Brasil, as medições são feitas a cada 15 minutos. Dependendo do tipo de cliente, esses dados podem ser mostrados em diversos níveis de detalhamento, na fatura de energia, podendo ir desde somente o consumo, a tarifa e o perfil de consumo anual, até o detalhamento do consumo diário de um determinado número de dias anteriores à consulta e índices de qualidade de energia.

A viabilidade de implantação de uma *smart grid* passa por uma análise de investimentos. Atualmente algumas cidades brasileiras, como Rio de Janeiro – RJ, Búzios – RJ,

São Paulo – SP, Aparecida do Norte – SP, Fernando de Noronha – PE, Sete Lagoas – MG e Parintins – AM, implementam projetos-pilotos de *smart grids*, servindo de base para a avaliação de viabilidade econômica do projeto brasileiro (CAVALCANTE *et al.*, 2019). Pesquisas conduzidas pelo MME, já em 2010, buscavam no exterior experiências de implementação da *smart grid*, com o objetivo de considerar todas as alternativas tecnológicas disponíveis e buscar soluções mais baratas para sua implementação.

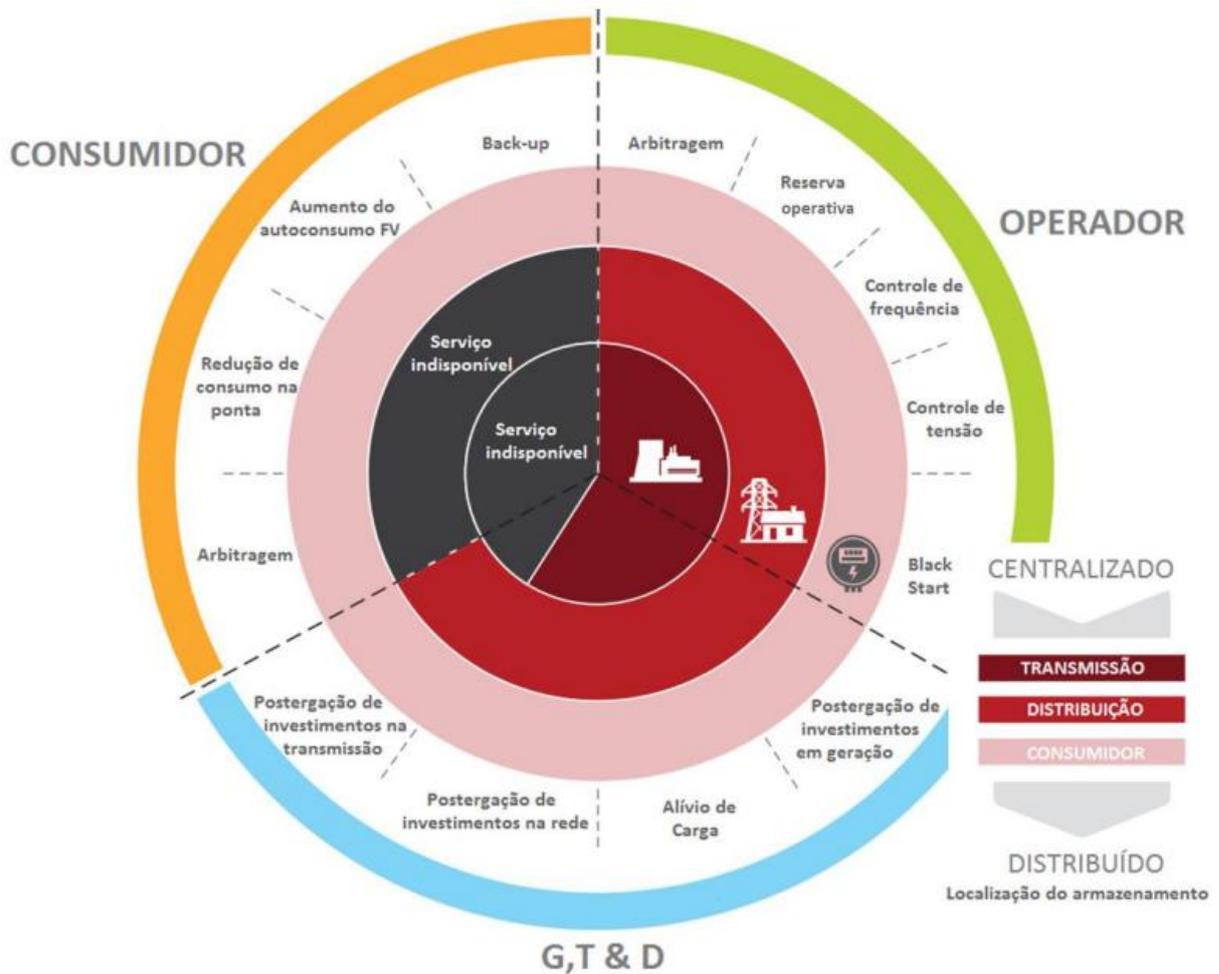
De acordo com a IEC (2020), as motivações para a implementação da *smart grid*, mundialmente, são a infraestrutura de rede envelhecida, onde na sua maior parte data de 1960 e está chegando ao fim da vida útil. Esta também tem suportado o estresse dos períodos de pico de carga, assim como a introdução de fontes renováveis intermitentes na rede, que podem causar a sobrecarga. A introdução de maior inteligência à rede tem por objetivo melhorar a qualidade do serviço e reduzir os impactos de novas fontes e cargas que tem surgido e podem ter impacto nos índices de qualidade de energia, como tensão, frequência e taxa de distorção harmônica.

Outra motivação é a busca por tarifas mais baixas, o que seria alcançado com o aumento da competitividade entre as fontes de energia, conectadas a *smart grid*. Além disso, aumentará a segurança do suprimento de energia a uma sociedade em constante aumento de demanda por esse recurso, contribuindo também para um crescimento econômico mais sustentável e para o uso eficiente das fontes de energia (IEC, 2020).

Os sistemas de armazenamento de energia também têm um importante papel na modernização da rede, visto que pode viabilizar um melhor gerenciamento de energia, controle de frequência, controle de tensão, equilíbrio de carga e “*backup*”. Existem diversas formas de armazenamento, como mecânico, eletroquímico, térmico, elétrico e químico. Exemplos de tecnologias de armazenamento são as usinas hidrelétricas bombeadas, ar comprimido, ultra capacitores, baterias, entre outros. Algumas destas tecnologias de armazenamento já são economicamente viáveis, porém, condicionada ao dimensionamento da aplicação. Usinas hidrelétricas bombeadas representam uma opção de armazenamento muito atraente para armazenar a energia de fontes intermitentes, mas exigem condições topográficas adequadas. Outras tecnologias ainda estão em desenvolvimento para superar problemas como custo e eficiência (EPE, 2019).

As baterias têm grande destaque como sistema de armazenamento devido a sua grande variedade de aplicação e por algumas apresentarem características como alta densidade de energia, alta eficiência e curto tempo de resposta (EPE, 2019). Algumas possibilidades de serviços que as baterias viabilizam na geração, transmissão, distribuição e consumo podem ser vistas na Figura 5.

Figura 5 – Possibilidades de serviços prestados por baterias



Fonte: (EPE, 2019)

Percebe-se no esquema proposto, que as aplicações de armazenamento por baterias dentro do sistema elétrico são bem diversificadas, com isso, a pesquisa e o desenvolvimento dessa tecnologia se faz muito importante para atingir as metas de desempenho e de custo necessários para uma maior utilização dentro do setor.

### 2.3 IDENTIFICAÇÃO DE CARGAS ELÉTRICAS EM SUPERPOSIÇÃO

A coleta de informações tem se tornado cada vez mais necessária para o gerenciamento de sistemas elétricos, que estão ficando mais complexos com a incorporação de novas fontes, como a fotovoltaica, e de novas cargas, como os carros elétricos. Para a obtenção de informação de qualidade pode se fazer necessário o investimento em sensores e em estrutura de redes de comunicações, que tende a se tornar cada vez mais complexa e onerar os benefícios advindos do monitoramento.

Existem diversas aplicações voltadas ao monitoramento e identificação de equipamentos elétricos em casas inteligentes (*smart homes*) e em prédios inteligentes (*smart*

*buildings*). Nesse segmento, diversos métodos estão disponíveis e os principais parâmetros usados são: corrente, tensão, potência ativa, reativa, aparente, fator de potência e as harmônicas. Dessa forma, eletrodomésticos podem ser controlados a distância e automatizados para operar em determinados horários (GHASEMPOUR, 2019; SALEEM *et al.*, 2019; SHI *et al.*, 2019).

Uma estratégia para promover o monitoramento de cargas em uma *smart grid*, sem comprometer a sua qualidade e, em simultâneo, reduzir os custos com sensores, é utilizar o monitoramento não intrusivo de cargas, ou *Nonintrusive Load Monitoring* (NILM), o qual instrumentos que não requerem intrusão no circuito terminal para realizar a medição de parâmetros como corrente e tensão, realizando a medição em um ponto a todos os circuitos que se deseja monitorar. A seguir é apresentada uma revisão bibliográfica sucinta de trabalhos que utilizam o monitoramento não intrusivo para obtenção de sinais de cargas residenciais, e então utilizam esses dados para projetar classificadores baseados em inteligência artificial.

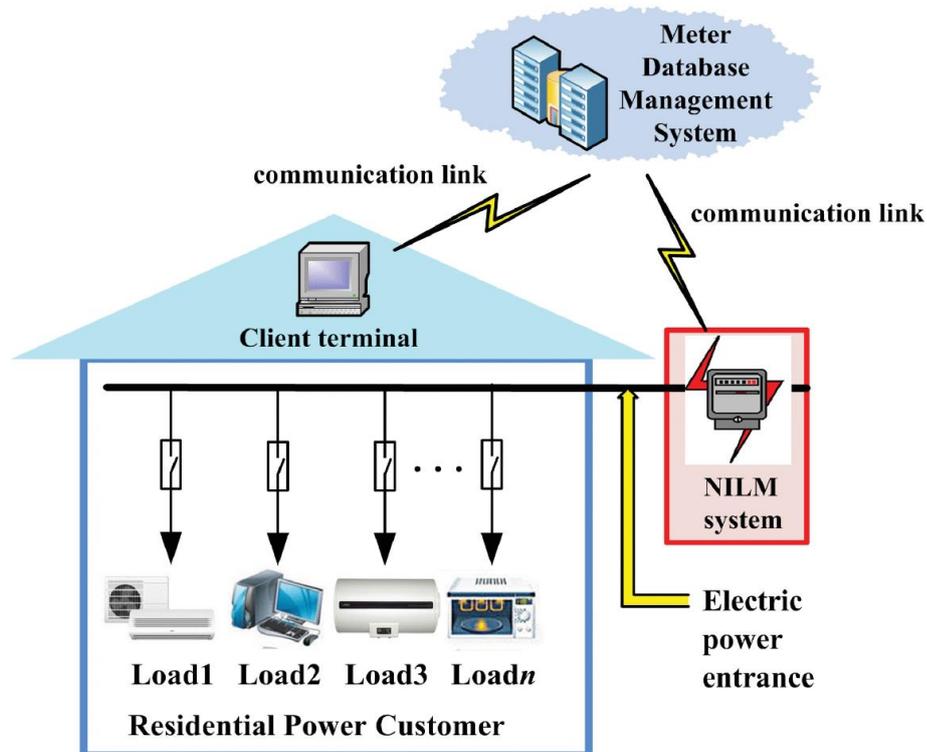
O método proposto por Sousa *et al.* (2018), para identificação de cargas residenciais, utiliza o método intrusivo para coletar dados sobre os equipamentos e realiza a identificação por meio de um algoritmo de inteligência artificial, previamente treinado, baseado no algoritmo de Naive Bayes. Este método apresenta a limitação de não ser capaz de identificar aparelhos que estejam em funcionamento simultâneo.

Wu *et al.* (2018) utiliza o método de NILM e propõe um algoritmo, que identifica cargas em sobreposição através do seu espectro de frequências. Através de um algoritmo de limiar de encolhimento iterativo de duas etapas, e assumindo que dificilmente dois equipamentos são ligados ou desligados em simultâneo, é possível identificar o equipamento no sinal de corrente sobreposto, comparando o sinal de corrente atual e o anterior. A diferença no sinal de corrente atual é passada para o domínio da frequência e comparado com o espectro de frequência característico de cada carga no banco de dados, e, visto que as cargas têm componentes de frequência específicos, a identificação da carga que entrou em funcionamento pode ser obtida através da filtragem por seu espectro. Assim, quando todas as componentes de frequência retiradas do sinal de corrente atual passam pelo filtro de frequência de um equipamento, o mesmo é considerado identificado. A suposição de que mais de um equipamento não é ligado em simultâneo, impõe uma limitação nessa proposta para uma aplicação real.

A medição realizada no ramal de entrada de energia de um cliente, por exemplo, usualmente fornece um sinal que é a sobreposição dos sinais de diversos equipamentos. Utilizar algoritmos que consigam identificar padrões de assinaturas elétricas específicas, contidos nesse sinal, pode permitir o reconhecimento de diversas cargas, lendo apenas os sinais no ponto de

alimentação geral da instalação. A identificação das cargas pode ser utilizada para a estimação do consumo de energia de cada equipamento, assim como acompanhar o comportamento do consumidor. Isso mostra que o NILM representa uma solução tecnicamente mais vantajosa para o monitoramento de cargas do que o monitoramento intrusivo, e pode se transformar em uma importante tecnologia para fornecer informações para as concessionárias implementarem estratégias de gerenciamento pelo lado da demanda. Uma visão geral do NILM é apresentada na Figura 6.

Figura 6 – Monitoramento não intrusivo



Fonte: (WU *et al.*, 2018)

A proposta apresentada por Welikala *et al.* (2016) utiliza uma abordagem de medição não intrusiva para o monitoramento de cargas residenciais em tempo real. Utilizando um medidor de energia ativa e uma “interface” de usuário (GUI), as assinaturas, tanto de equipamentos individuais quanto de suas combinações, puderam ser extraídas através da expansão de Karhunen-Loève, que, assim como a transformada de Fourier, permite decompor um sinal em um número infinito de funções ortogonais. Uma dada quantidade finita dessas funções ortogonais é utilizada para formar um banco de dados das assinaturas individuais de cada dispositivo, e outro banco de dados com as assinaturas de dispositivos combinados, que são então utilizados para realizar a identificação. Esse método mostrou uma precisão maior que 80% quando 10 dispositivos foram utilizados.

Biansoongnern e Plangklang (2016) propõem um sistema de monitoramento não

intrusivo e com baixa taxa de amostragem, em que utiliza uma RNA treinada pelo algoritmo *Backpropagation* para realizar a identificação de quatro aparelhos. Isto é feito com base em dados de estado estacionário, de potência ativa, retirados pelo medidor inteligente, a uma frequência de 1Hz e enviados para a central de processamento. Observando então que a precisão de identificação atingiu 95% de taxa de acerto quando apenas uma carga era ligada ou desligada enquanto as outras permaneciam desligadas.

Em Xiao *et al.* (2019), apresenta-se um método não intrusivo de identificação de cargas, baseado na teoria dos grafos e construído com base no algoritmo aprimorado de Kuhn-Munkras, o qual foi aplicado uma janela de tempo adaptativa para detectar a entrada e saída da carga, e a identificação é feita com base na assinatura de potência ativa e reativa armazenada no banco de dados. Foi alcançando uma taxa de acerto de até 90%.

Sirojan *et al.* (2017) propõe a identificação de cargas a partir dos dados obtidos por um medidor inteligente pelo método do NILM. A transformada wavelet discreta é usada para extrair a assinatura transitória de alta frequência das cargas do sinal sobreposto. Esses dados são então usados por uma rede neural artificial (RNA) de avanço (*feedforward*) de três camadas, embarcada no medidor inteligente, para realizar a identificação das cargas. Esse método mostrou uma precisão de até 98,9% na identificação, quando existiam 4 cargas em funcionamento simultâneo.

Para que seja possível identificar com boa assertividade as cargas alimentadas por um mesmo circuito, se faz necessário identificar o instante da entrada dessa carga no circuito, assim como extrair os atributos necessários para reconhecer a assinatura elétrica desta carga como, por exemplo, as componentes harmônicas da corrente propagada na rede, que podem ser únicas para cada equipamento.

O NILM vem sendo utilizado para, além do monitoramento e identificação de cargas residenciais, o monitoramento de operação de subestações. Os desafios que a rede enfrentará, com a geração distribuída e o aumento no número de carros elétricos, faz com que seja necessário conhecer a quantidade, o tipo e o estado das cargas, para que as distribuidoras possam conhecer as fontes dos problemas e aplicar programas de eficiência e gerenciamento pelo lado da demanda (WANG *et al.*, 2020).

### 3. TRANSFORMADA DE GABOR DE REDE MLP

#### 3.1 A TRANSFORMADA DE GABOR

A transformada de Fourier é uma das ferramentas mais utilizadas na análise do espectro de sinais estacionários, mas somente a análise do espectro nos diz muito pouco sobre o comportamento de sinais não periódicos, por concentrar-se exclusivamente no domínio da frequência, não podendo analisar as variações de frequência no tempo. A proposta da transformada de Fourier de Tempo Curto ou Short Time Fourier Transform (STFT) é analisar a variação da frequência com o tempo, fornecendo a sua distribuição temporal ao utilizar uma função como janela de análise (KUMAR; FOUFOULA-GEORGIOU, 1994).

Muitas funções podem ser usadas como janela, mas para isso é desejável que as mesmas sejam integráveis em todo o seu domínio, centrada em zero, além de ser simétrica e ortogonal, para que a transformada inversa reconstrua o sinal na mesma escala. Como exemplo de janelas com essas características, podemos citar a de Hamming, de Blackman e a Gaussiana.

Na transformada de Fourier convencional, a função  $f(t)$  é descrita como uma combinação linear dela com a base ortogonal  $e^{(j2\pi ft)}$ , com  $-\infty \leq t \leq +\infty$  e  $w = 2\pi f$ . Portanto, temos que a transformada de Fourier é dada pela Equação 3.1.

$$F(w) = \int_{-\infty}^{+\infty} f(t) e^{-j\omega t} dt \quad (3.1)$$

Conhecendo o espectro de frequência de um sinal, é possível obtê-lo no domínio do tempo utilizando a transformada inversa, que é dada pela Equação 3.2.

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(w) e^{j\omega t} dw \quad (3.2)$$

Onde,  $f(t)$  precisa ser absolutamente integrável, ou seja,  $\int_{-\infty}^{+\infty} |f(t)| dt < +\infty$ , e ter energia finita,  $\int_{-\infty}^{+\infty} |f(t)|^2 dt < +\infty$ .

Para aplicações de análise de sinais, é preferível e tecnicamente mais conveniente que estes estejam em tempo discreto do que em tempo contínuo. Um sinal contínuo  $f(t)$  pode ser bem representado por suas amostras em instantes  $t = nT$ ,  $n \in \mathbb{Z}$  e com frequência de amostragem  $f_s = \frac{1}{T}$ , o que permite obter o sinal na forma discreta e implementar a transformada de discreta Fourier, conforme as Equações 3.3 e 3.4.

$$f[n] = f(nT) \quad (3.3)$$

$$F(e^{jw}) = \sum_{n=-\infty}^{+\infty} f[n] e^{-jwn} \quad (3.4)$$

A sua transformada inversa é dada pela Equação 3.5.

$$f[n] = \frac{1}{2\pi} \int_{-\pi}^{\pi} F(e^{jw}) e^{jwn} dw \quad (3.5)$$

Para evitar o efeito de serrilhamento (*aliasing*), a frequência de amostragem aplicado na STFT deve ser maior que o dobro da frequência do sinal de dados, como orienta o teorema de Nyquist. Se o sinal é limitado no tempo, pode-se usar a Fast Fourier Transform (FFT) para diminuir o tempo computacional (DING, 2015).

Comumente as funções são representadas em função do tempo ou da frequência, mas em 1946, Dennis Gabor propôs uma análise simultânea de uma função, com representação tanto em termos do espectro de frequência quanto no domínio do tempo.

O STFT usa uma janela deslizante  $g(t)$  invariante para amostrar todo o sinal e em seguida passá-lo para o domínio da frequência.

Assim, a STFT é definida através da Equação 3.6 ou 3.7.

$$\text{STFT}_f(w, t) = \int_{-\infty}^{+\infty} f(u) g(u - t) e^{-jwu} du \quad (3.6)$$

$$= \int_{-\infty}^{+\infty} f(u) g_{w,t}(u) du \quad (3.7)$$

Onde,  $g_{w,t}(u) = g(u - t) e^{-jwu}$ . Como uma janela é utilizada na STFT, temos que, para intervalos maiores que a janela,  $g(t) \approx 0$ , assim isolamos somente a porção do sinal contido na janela para análise.

A transformada janelada é uma isometria, dessa forma a energia do sinal é conservada na mudança de domínio, conforme é mostrado na Equação 3.8.

$$\int_{-\infty}^{+\infty} |f(t)|^2 dt = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} |\text{STFT}_f(w, t)|^2 dw dt \quad (3.8)$$

Onde, se assume que  $\int_{-\infty}^{+\infty} |f(t)|^2 dt = 1$ . Sua transformada inversa é calculada pela Equação 3.9.

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \text{STFT}_f(w, u) g(u - t) e^{jw t} dw du \quad (3.9)$$

Como já mencionado, para a análise de sinais é preferível que este seja analisado na forma discreta, então, fazendo  $t = nt_0$  e  $w = mw_0$ , regularmente espaçados, onde  $m$  e  $n$  são inteiros positivos, e  $w_0, t_0 > 0$  e fixos. Assim, a transformada STFT discreta pode ser calculada através da Equação 3.10.

$$\text{STFT}_d(m, n) = \int_{-\infty}^{+\infty} f(u)g(u - nt_0)e^{-jm\omega_0 u} du \quad (3.10)$$

Para que a transformada janelada discreta seja invertível, é necessário que  $w_0 t_0 < 2\pi$ . Quando  $w_0 t_0 > 2\pi$ , não existem quadros e, portanto, os vetores são independentes do tempo e da frequência, para a representação no espaço. Quando  $w_0 t_0 = 2\pi$ , existem quadros, mas com uma localização de tempo e frequência ruins. Quando  $w_0 t_0 < 2\pi$ , é possível fazer uma excelente localização no tempo e frequência, mesmo a dos quadros estreitos (KUMAR; FOUFOULA-GEORGIU, 1994).

Precisamos entender ainda as propriedades da incerteza no tempo  $|g_{w,t}|^2$  e na frequência  $|\hat{g}_{w,t}|^2$  da função janela  $g(t)$ , pois, eles determinam os recursos de  $f(t)$  que são extraídos. Aplicando o teorema de Parseval, que diz: seja o par de transformadas  $f(t) \leftrightarrow F(w)$  de um sinal, de energia finita, então a energia do sinal pode ser calculada em qualquer dos domínios, conforme mostrado na Equação 3.11.

$$\int_{-\infty}^{+\infty} |f(t)|^2 dt = \frac{1}{2\pi} \int_{-\infty}^{+\infty} |F(w)|^2 dw \quad (3.11)$$

Então, a Equação 3.7 pode ser reescrita como:

$$\text{STFT}_f(w, t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \hat{f}(w') \overline{\hat{g}_{w,t}(w')} dw' \quad (3.12)$$

Onde,  $\hat{g}_{w,t}(w')$  indica a transformada de Fourier de  $g_{w,t}(u)$  e a barra horizontal indica o conjugado complexo. Definindo o desvio padrão de  $g_{w,t}$  e  $\hat{g}_{w,t}$  como  $\sigma_g$  e  $\sigma_{\hat{g}}$  respectivamente, esses podem ser calculados através das Equações 3.13 e 3.14, respectivamente.

$$\sigma_g = \left( \int_{-\infty}^{+\infty} (u - t)^2 |g_{w,t}(u)|^2 du \right)^{1/2} = \left( \int_{-\infty}^{+\infty} u^2 g(u)^2 du \right)^{1/2} \quad (3.13)$$

e

$$\sigma_{\hat{g}} = \left( \int_{-\infty}^{+\infty} (w' - w)^2 |\hat{g}_{w,t}(w')|^2 dw' \right)^{1/2} \quad (3.14)$$

Esses parâmetros medem a propagação da função  $|g_{w,t}|$  e  $|\hat{g}_{w,t}|$ , em  $t$  e  $w$  respectivamente. Devido ao princípio da incerteza de Gabor-Heisenberg, que estabelece um limite inferior sobre o produto  $\Delta t \cdot \Delta w$ , como é mostrado na Equação 3.15.

$$\Delta t \cdot \Delta w = \frac{1}{2} \quad (3.15)$$

E somente quando a janela é uma Gaussiana o produto de  $\sigma_g^2$  por  $\sigma_{\hat{g}}^2$  é dado pela Equação 3.16.

$$\sigma_g^2 \sigma_{\hat{g}}^2 \geq \frac{\pi}{2} \quad (3.16)$$

Dessa forma,  $t$  e  $w$  não podem ser simultaneamente definidos de forma exata. A resolução de tempo e frequência, para qualquer  $t_0$  e  $w_0$  não pode ser menor que a célula de tamanho fixo  $[t_0 \pm \sigma_g \times w_0 \pm \sigma_{\hat{g}}]$ . Isso implica que se o sinal possui componente transitória menor que  $\sigma_g$ , essa é dificilmente localizada, e se o sinal possui características importantes de tamanhos diferentes, a janela deslizante  $g(t)$ , por ser fixa, não poderá analisar com precisão o sinal (KUMAR; FOUFOULA-GEORGIU, 1994).

Quando a função Gaussiana é utilizada como janela deslizante na STFT, esta é comumente chamada de Transformada de Gabor. A função Gaussiana padrão é definida pela Equação 3.17.

$$g(t) = e^{-\frac{1}{2}\left(\frac{t}{\sigma}\right)^2}, t \in (-\infty, \infty) \quad (3.17)$$

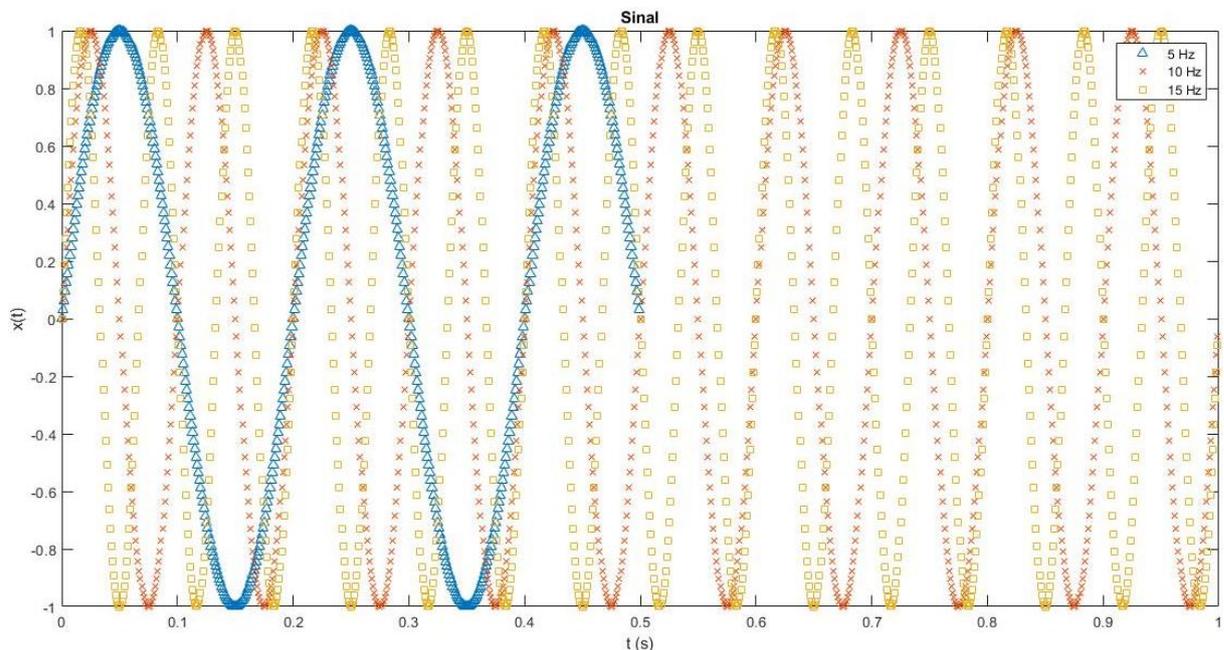
onde  $\sigma$  é a meia largura da janela.

Portanto, a Transformada de Gabor é definida como:

$$\text{STFT}_f(w, t) = \int_{-\infty}^{+\infty} f(u) e^{-jwu} e^{-\frac{(u-t)^2}{2}} du \quad (3.18)$$

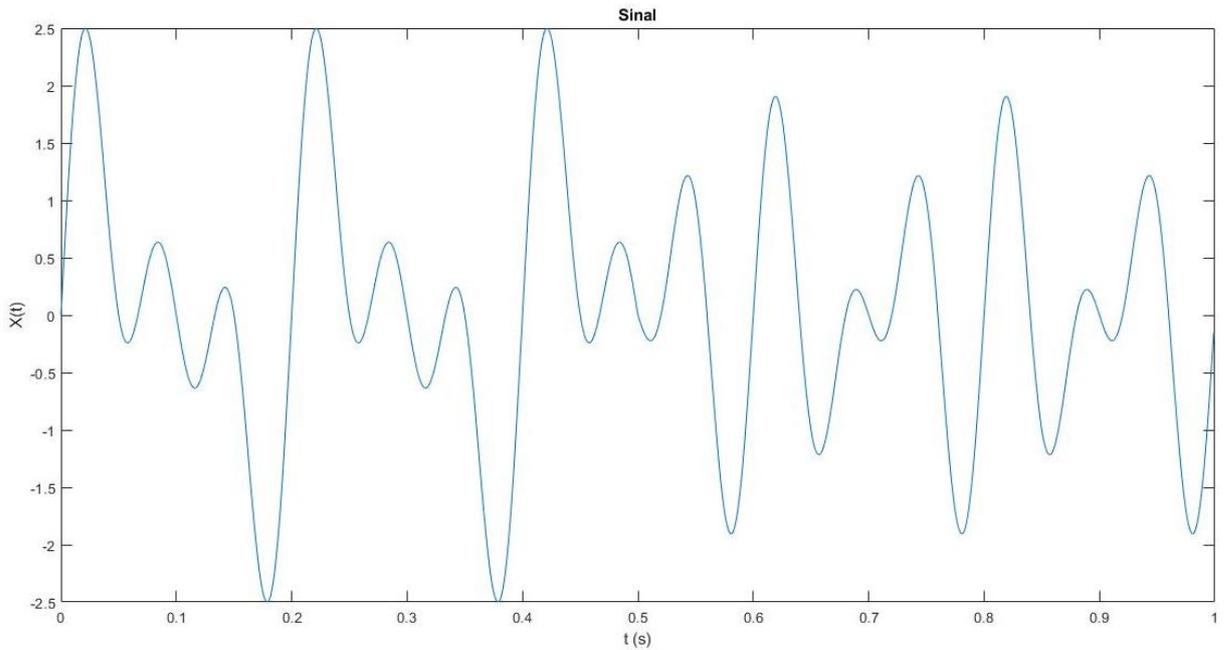
Para ilustrar graficamente o resultado da transformação de Gabor, foram gerados 3 sinais, como mostrados na Figura 7. Tratam-se de senoides com frequências de 5, 10 e 15 Hz, separadamente, ao longo do tempo de 1 segundo, mas a partir de 0,5 s o sinal de 5 Hz deixa de existir. Logo em seguida, na Figura 8, é apresentado o sinal composto pela sobreposição desses sinais.

Figura 7 – Sinais senoidais de 5, 10 e 15 Hz



Fonte: do autor.

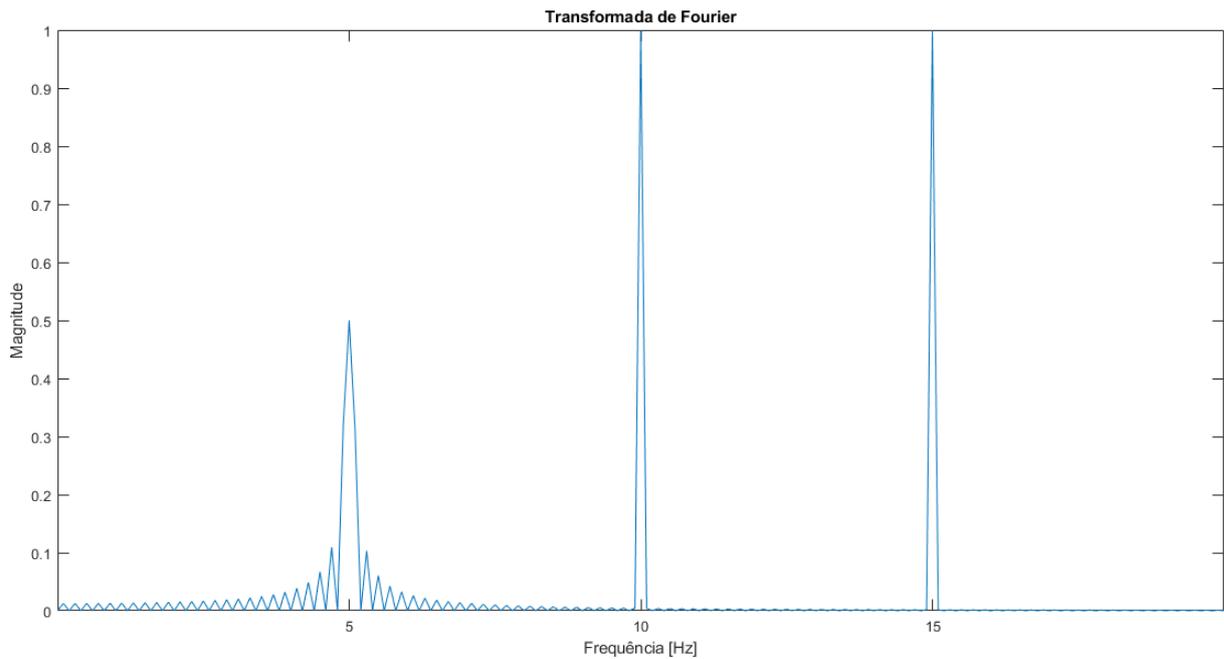
Figura 8 – Sinais senoidais sobrepostos de 5, 10 e 15 Hz



Fonte: do autor.

A transformada rápida de Fourier desse sinal nos fornece o espectro mostrado na Figura 9.

Figura 9 – Transformada de Fourier



Fonte: do autor.

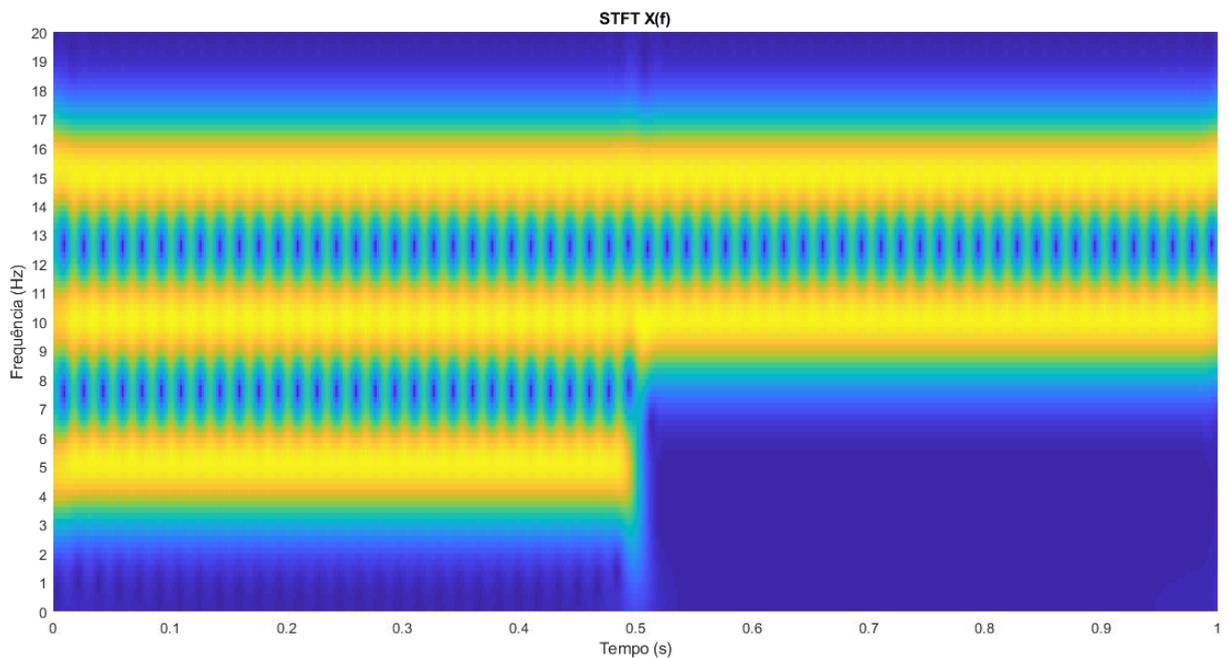
Neste gráfico é possível ver cada componente de frequência do sinal, mas não a sua localização no tempo. Na transformada de Fourier cada componente de frequência é representada em termos de sua densidade no sinal. Com isso, o sinal de 5 Hz que estava presente

em metade do tempo do sinal analisado, apresenta amplitude de 0,5 enquanto os sinais de 10 Hz e 15 Hz apresentam amplitude 1. Pode-se notar que nas proximidades da frequência de 5 Hz, surgem componentes de frequência que não existem no sinal original. Isso ocorre devido a descontinuidade no instante  $t = 0,5$  s. Esse fato sempre ocorre quando se utiliza a FFT em sinais com descontinuidade.

Na STFT a escolha do tamanho da janela é muito importante. Uma janela menor melhora a resolução no tempo, ao custo de uma menor resolução de frequência, enquanto uma janela maior melhora a resolução na frequência, piora a resolução no tempo.

Com a transformada janelada é possível obtermos a distribuição temporal de frequência em um único gráfico, como podemos observar nas Figuras 10, 11 e 12. Na Figura 10 foi utilizada uma janela estreita,  $\sigma = 0,1$ , de forma que se pode notar que a resolução no tempo está bem definida, em detrimento de uma baixa resolução em frequência.

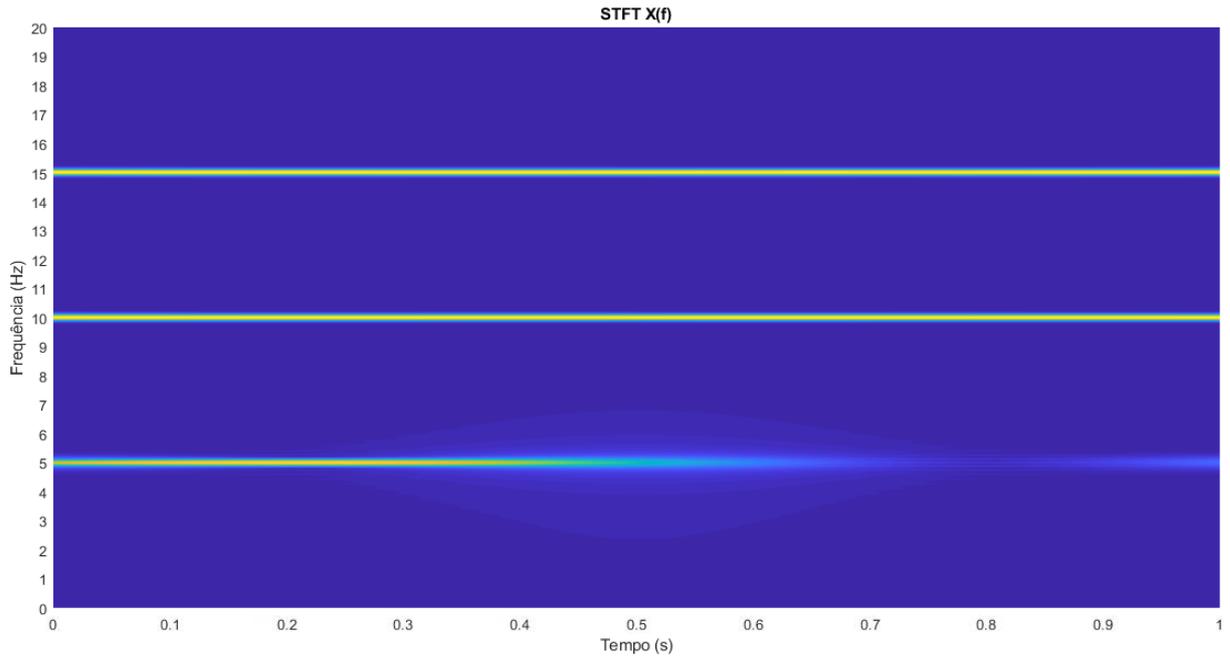
Figura 10 – Transformada de Gabor de  $x(t)$  com melhor resolução no tempo



Fonte: do autor.

Uma melhor resolução em frequência pode ser obtida com uma janela maior,  $\sigma = 2$ , como pode ser visto na Figura 11.

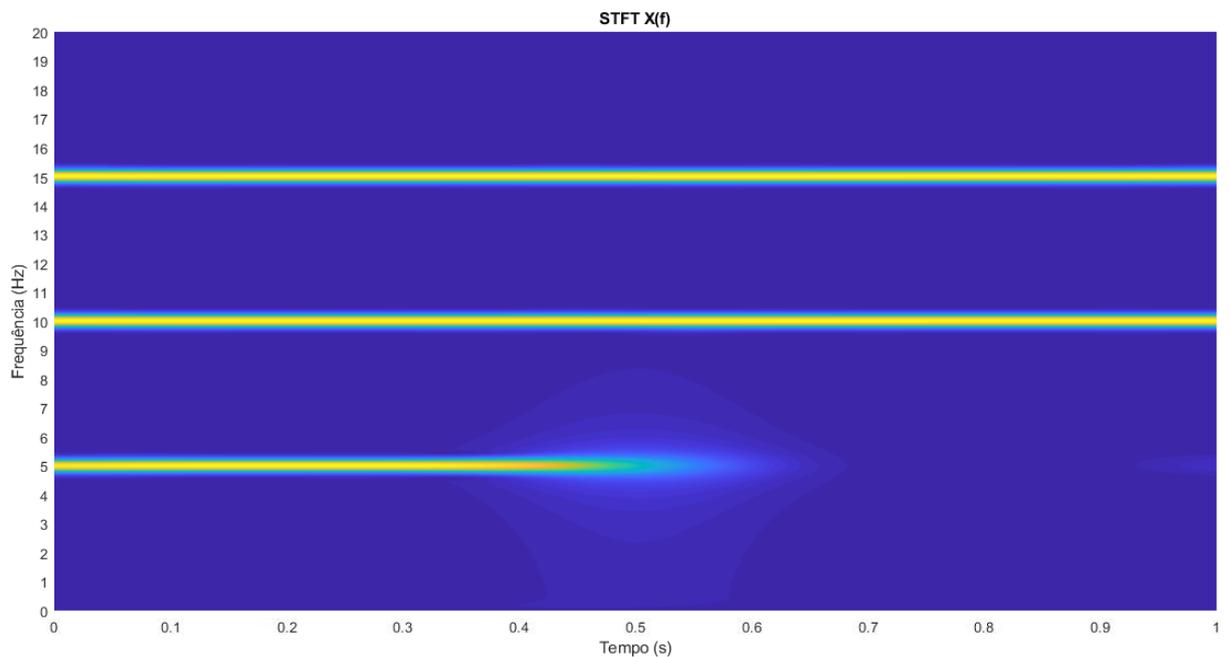
Figura 11 – Transformada de Gabor de  $x(t)$  com melhor resolução na frequência



Fonte: do autor.

Se nota que a resolução no tempo foi prejudicada, então uma janela muito grande ou uma muito pequena não são o ideal. Portanto, se deve escolher uma largura de janela que forneçam boa precisão, tanto no tempo quanto na frequência, que depende diretamente da variação do sinal analisado no tempo. Para o exemplo apresentado na Figura 7, uma janela gaussiana com desvio padrão unitário apresenta bom resultado, como pode ser visto na Figura 12.

Figura 12 – Transformada de Gabor de  $x(t)$ , com  $\sigma = 1$



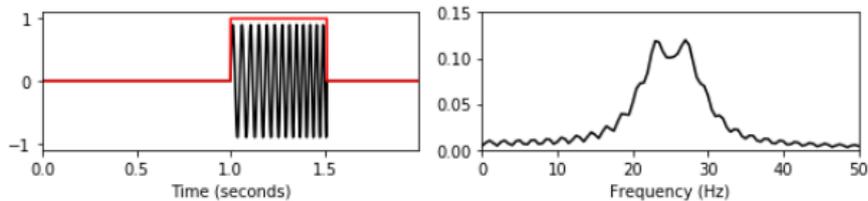
Fonte: do autor.

A forma como o sinal é representado na STFT é influenciado pela janela que é

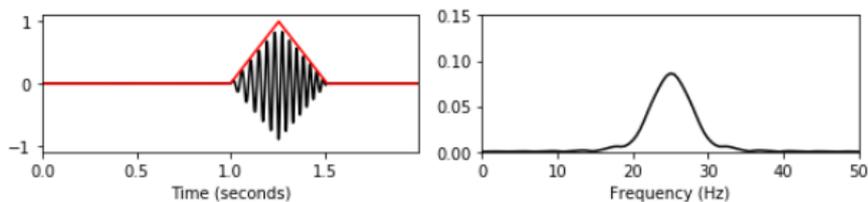
utilizada. A janela retangular, embora preserve todo o sinal contido nela, de forma que não seja alterado, por apresentar descontinuidade nas extremidades, introduz componentes de frequência que não fazem parte do sinal. O efeito de contorno apresentado pela janela retangular é atenuado quando uma janela triangular é utilizada. Uma atenuação ainda mais eficiente é oferecida pela janela Hann, que é um cosseno elevado que cai suavemente para zero nas extremidades (MÜLLER; ZALKOW, 2015). Na Figura 13 é apresentado o efeito de contorno no espectro de frequência por essas três janelas.

Figura 13 – Efeito de contorno das janelas retangular, triangular e Hann

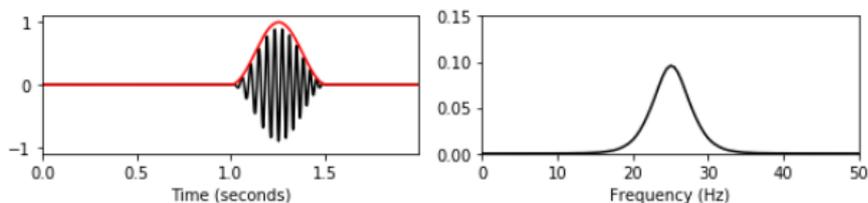
Janela retangular:



Janela triangular:



Janela Hann:



Fonte: (MÜLLER; ZALKOW, 2015).

Dessa forma, a escolha da janela a ser usada deve considerar também os impactos que esta provoca na representação do sinal no espectro de frequência e, conseqüentemente, na resolução do espectrograma obtido pela transformada janelada.

### 3.2 REDE NEURAL ARTIFICIAL

A evolução das relações entre homem, máquina e natureza, na busca por uma coexistência sustentável em uma cidade inteligente, torna necessário o desenvolvimento de tecnologias inteligentes para enfrentar os novos desafios no gerenciamento de recursos. Dessa forma, a Inteligência Artificial — IA, é um fator-chave no desenvolvimento de soluções para a nova estrutura organizacional das cidades inteligentes (KIRWAN; ZHIYONG, 2020).

IA é um campo de estudo da computação que se desenvolveu após a Segunda Guerra Mundial com o aparecimento dos computadores. Como as *smart grids*, a inteligência artificial não tem uma definição única, e existem tanto entusiastas da área quanto aqueles que a veem como uma ameaça a própria humanidade. Podemos, no entanto, entendê-la como uma área de pesquisa que busca criar máquinas que imitam o pensamento humano através de algoritmos sofisticados (TEIXEIRA, 2019).

No Simpósio de Hixon, realizado na Califórnia em 1948, foram reunidos pesquisadores de diversas áreas do conhecimento, para mostrar suas descobertas direcionadas ao entendimento do funcionamento do cérebro humano. Como resultado desse encontro, os pesquisadores conseguiram fazer uma analogia entre o funcionamento do cérebro humano e o funcionamento de um computador. No cérebro humano os neurônios se comunicam com outros neurônios através de impulsos elétricos, o que se assemelha aos circuitos elétricos de um computador (TEIXEIRA, 2019).

Os neurônios enviam informações através de sinais elétricos e químicos (neurotransmissores), por meio dos axônios, até uma célula-alvo específica ou conjunto de células vizinhas. Os sinais elétricos percorrem o sistema nervoso com uma velocidade de até 120 m/s, os quais são idênticos em amplitude e sua intensidade média depende da frequência de sinalização. A complexidade da rede neural determina características de um indivíduo, como a inteligência, emoções e memória (SILVERTHORN, 2017).

As entradas dos sinais ocorrem nas conexões sinápticas, composta pelo terminal axonal e os dendritos do neurônio alvo. Dependendo do neurotransmissor, o estímulo pode ser excitatório ou inibitório. Os estímulos recebidos pelos dendritos pós-sinápticos decaem quase exponencialmente, mostrando que o neurônio tem uma memória de curto prazo. Se a soma desses estímulos, excitatórios e inibitórios, for suficiente para atingir o limiar de disparo, um impulso nervoso será propagado pelo axônio. Após um impulso nervoso de duração  $T_n$ , o neurônio passa por um período refratário fixo  $T_a$ , em que nenhum outro impulso é transmitido. Dessa forma, a frequência máxima de impulsos propagada pelo axônio é  $f_{max} = 1/(T_n + T_a)$  (KOVÁCS, 2006). A função matemática responsável por definir um limiar de disparo é chamada de função de ativação.

Um modelo matemático de primeira ordem para o neurônio biológico é dado pela Equação 3.19 (KOVÁCS, 2006).

$$f_T = g \left( \int_T \sum_i w_i(t) x_i dt \right) \quad (3.19)$$

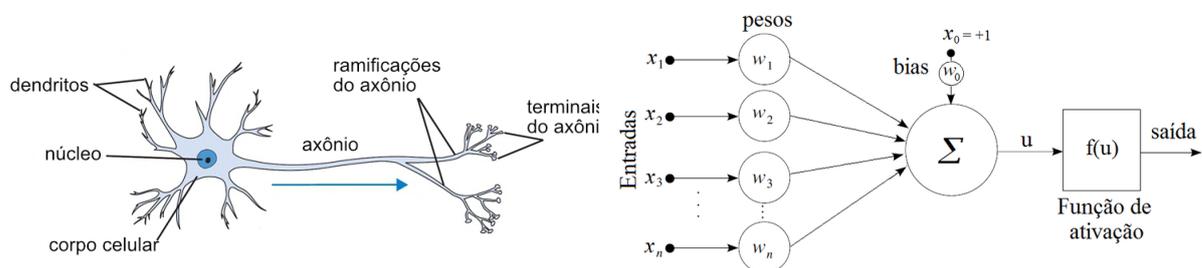
Onde,  $f_T$  é a frequência média de impulsos em um intervalo de tempo  $T$ ,  $g(v)$  é a função de ativação,  $w_i$  é o ganho ou peso sináptico e  $x_i$  é o sinal de entradas do neurônio.

Os conhecimentos em neurofisiologia, acumulados até 1943, e as contribuições de Alan Turing e John van Neumann, possibilitaram Warren S. McCulloch e Walter Pitts apresentarem a primeira tentativa de imitar o funcionamento dos neurônios humanos através de um neurônio artificial, de natureza binária. As entradas desses neurônios, tanto excitatórias quanto inibitórias, tinham pesos sinápticos arbitrários e a soma ponderada destas desencadeavam saídas do tipo pulso ou não pulso, quando atingissem um determinado limiar. Entre as funções que este neurônio poderia realizar, tinha-se o atraso unitário e as funções booleanas E e OU (KOVÁCS, 2006).

Em 1957 Frank Rosenblatt publicou o seu modelo de neurônio artificial do tipo discriminador linear, que ficou conhecido como *Perceptron*. Neste, as entradas e saídas são numéricas e não mais binárias. Suas entradas são associadas a pesos sinápticos ajustáveis e com presença de um parâmetro externo de ajuste, chamado de *bias*. Se constituído por mais de um neurônio, as entradas e o *bias* são compartilhadas por todos os neurônios da rede. Com esta rede, Rosenblatt buscou resolver os problemas de ajuste dos pesos sinápticos e escolha do valor do limiar, que eram quase triviais no modelo de McCulloch e Pitts (KOVÁCS, 2006, HAYKIN, 2001).

Na Figura 14 é apresentada a analogia entre o neurônio biológico e o neurônio artificial de McCulloch e Pitts.

Figura 14 – Neurônio biológico x neurônio artificial



Fonte: (BEZERRA, 2016; NETO; BONINI, 2010).

Sendo:

- $x_1, x_2, x_3, \dots, x_n$ : os valores do sinal de entrada;
- $w_1, w_2, w_3, \dots, w_n$  e  $w_0$ : os pesos sinápticos correspondentes aos sinais de entrada;
- $x_0$ : o *bias* ou viés;
- $f$ : a função de ativação;

Inspirado na teoria de aprendizado de Hebb, Rosenblatt propôs o algoritmo de aprendizado descrito pelas Equações 3.20 e 3.21 (GÉRON, 2017).

$$y(n) = \text{sinal}(w^T(n)x(n)) \quad (3.20)$$

$$w(n+1) = w(n) + \alpha[d(n) - y(n)]x(n) \quad (3.21)$$

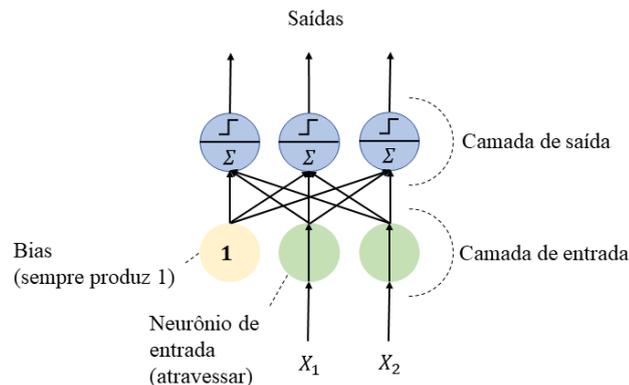
Onde

$$- \text{sinal}(n) = \begin{cases} +1 & \text{se } w^T(n)x(n) > 0 \\ -1 & \text{se } w^T(n)x(n) < 0 \end{cases}$$

- $w^T(n)$  é o vetor peso transposto.
- $x(n)$  é o vetor de entrada.
- $y(n)$  é a resposta real da rede.
- $d(n)$  é a resposta desejada.
- $\alpha$  é a taxa de aprendizado.
- $n$  é o número da interação

Um exemplo de uma rede *perceptron*, com duas entradas e três saídas, é apresentado na Figura 15.

Figura 15 – Rede Perceptron

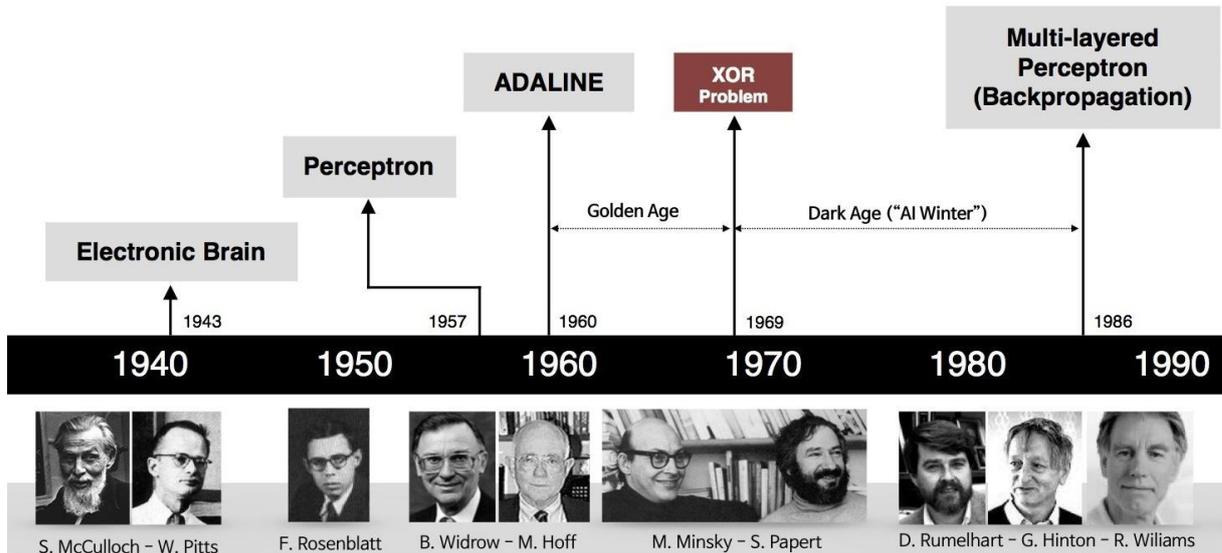


Fonte: Adaptado de (GÉRON, 2017).

Depois de várias contribuições para o aperfeiçoamento deste algoritmo de treinamento, finalmente em outubro de 1986, David E. Rumelhart, Geoffrey E. Hinton e Ronald J. Williams apresentaram um algoritmo de aprendizagem que hoje é conhecido por *backpropagation* ou retropropagação do erro. Este algoritmo permitiu a criação de uma rede *perceptron* composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, conhecida por *MultiLayer Perceptron* (MLP).

Uma visão geral da evolução das pesquisas em inteligência artificial pode ser vista na imagem da Figura 16.

Figura 16 – Desenvolvimento da Inteligência Artificial



Fonte: Adaptado de (DEEP LEARNING BOOK, 2020).

Para treinar uma rede MLP pelo algoritmo de retropropagação, é preciso separar os dados entre um conjunto de treinamento e um conjunto para teste da rede treinada. Com os dados de teste é possível ver o quão bem a rede neural está treinada e o poder de generalização da mesma, ou seja, verificar se a rede realmente aprendeu o padrão da classe que se deseja identificar ou apenas decorou os dados de treinamento.

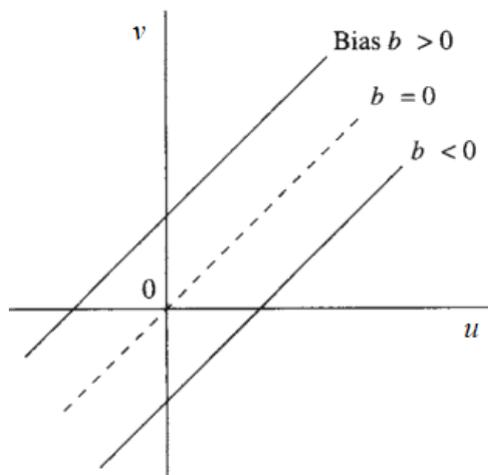
O algoritmo de aprendizado da rede *perceptron* é composto de várias etapas, vejamos os detalhes; inicialmente, realiza-se uma previsão da saída desejada para a rede, propagando os dados de treinamento no sentido direto da rede, da entrada para a saída, passando por todas as camadas da rede neural. Em seguida, realiza-se a medição do erro entre a saída desejada da rede e a saída real ao final de cada época de treinamento. A apresentação de um conjunto completo de exemplos para o treinamento da rede constitui uma época. Esse erro é propagado no sentido inverso, da saída para a entrada, onde é medida a contribuição de cada neurônio na variação do erro que se propaga para a camada seguinte, que pode ser outra camada oculta ou camada de saída. Então o ajuste dos pesos é feito no sentido de diminuir a diferença entre a saída da rede e a saída desejada.

A primeira camada de uma rede *perceptron* recebe as entradas  $x_i$  e é chamada de camada de entrada, e não é composta por neurônios computacionais. A camada de neurônios que recebe como entrada as saídas da camada de entrada é conhecida como camada oculta, no caso da rede possuir mais de uma camada de neurônios computacionais, por fim, a última camada é denominada de camada de saída. Todo neurônio que recebe sinal da camada de entrada ou de uma outra camada oculta resulta em outra camada, que pode ser uma nova camada oculta ou a camada de saída, para o caso de ser a última. Os neurônios de cada camada são totalmente conectados aos neurônios da camada seguinte, exceto na saída, e cada uma destas

camadas possui um neurônio independente que possui um valor fixo, usualmente assumindo o valor +1 ou -1, e é chamado de limiar, ou *bias*. Essa arquitetura resolve alguns problemas do *perceptron* simples proposto por Marvin Minsky em 1969, que impede o algoritmo de lidar com problemas simples, como por exemplo o problema do XOR (GÉRON, 2017).

No modelo de neurônio, o *bias* '*b*' tem a função de aumentar o grau de liberdade da rede, aumentando ou diminuindo a entrada líquida da função de ativação. O *bias* aplica uma transformação afim a combinação linear  $u_j = \sum_{i=1}^m w_{ji}x_i$ , e, dependendo do seu sinal, a relação entre este e o campo local induzido, ou potencial de ativação, dada por  $v_j = u_j + b_j$ , pode ser aditiva ou subtrativa, como é apresentado na Figura 17 (HAYKIN, 2001).

Figura 17 – Relação entre *v* e *u*



Fonte: Adaptado de (HAYKIN, 2001).

A função de ativação  $f(v)$  decide se um neurônio deve ou não ser ativado, restringe a amplitude do sinal de saída e permite introduzir não linearidade a rede, o que aumenta a sua capacidade representativa e de realização de tarefas complexas. Esta permite ainda que pequenas mudanças nos valores dos pesos e bias induzam pequenas mudanças na saída. Quando essas funções são não lineares, geralmente assumem valores entre  $[0, 1]$  ou  $[-1, 1]$ . Dentre as funções mais populares temos a função sigmoide, também conhecida como função logística, e a tangente hiperbólica (HAYKIN, 2001).

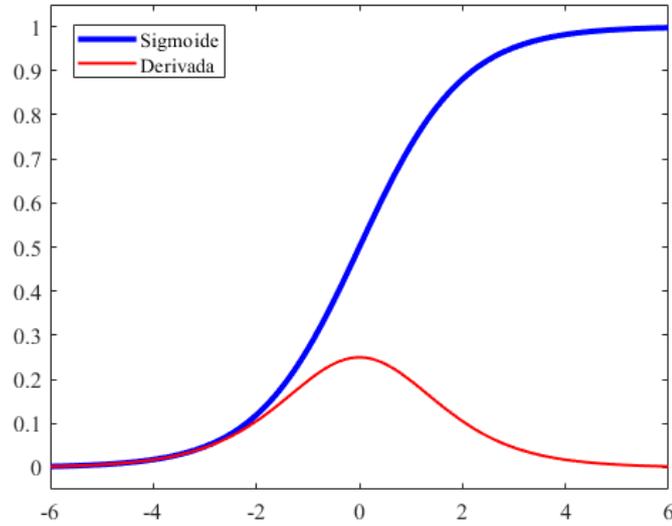
A função sigmoide é estritamente crescente e exibe um balanceamento adequado entre comportamento linear e não linear, além de ser diferenciável em todo o seu domínio, sendo então uma das mais utilizadas (HAYKIN, 2001). Para a etapa de treinamento por *backpropagation*, uma função diferenciável, de gradiente decrescente, é necessária para o cálculo do gradiente local do erro. Nas Equações 3.22 e 3.23 são apresentadas as equações matemáticas da sigmoide e sua derivada, respectivamente, assim como as suas representações gráficas na Figura 18.

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (3.22)$$

Onde o parâmetro constante  $a$  determina a inclinação da função.

$$\varphi'(v) = \varphi(v)(1 - \varphi(v)) \quad (3.23)$$

Figura 18 – Sigmoide e sua derivada



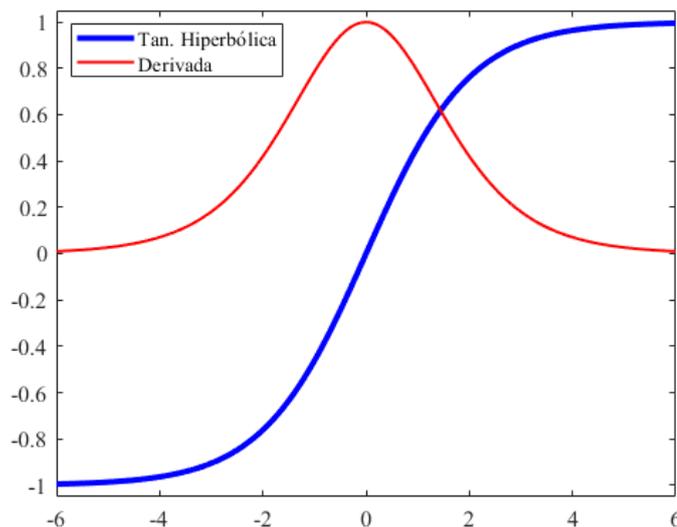
Fonte: do autor.

A função tangente hiperbólica é outra importante função de ativação para a RNA, pois esta pode assumir valores no intervalo aberto entre -1 e 1. Como está centrada em 0, a convergência inicial na etapa de treinamento pode ser acelerada (GÉRON, 2017). A tangente hiperbólica e a sua derivada são descritas pelas Equações 3.24 e 3.25, respectivamente, enquanto a representação gráfica é mostrada na Figura 19.

$$\varphi(v) = \tanh(v) = \frac{1 - e^{-2v}}{1 + e^{-2v}} \quad (3.24)$$

$$\varphi'(v) = 1 - \varphi(v)^2 \quad (3.25)$$

Figura 19 – Tangente hiperbólica e sua derivada

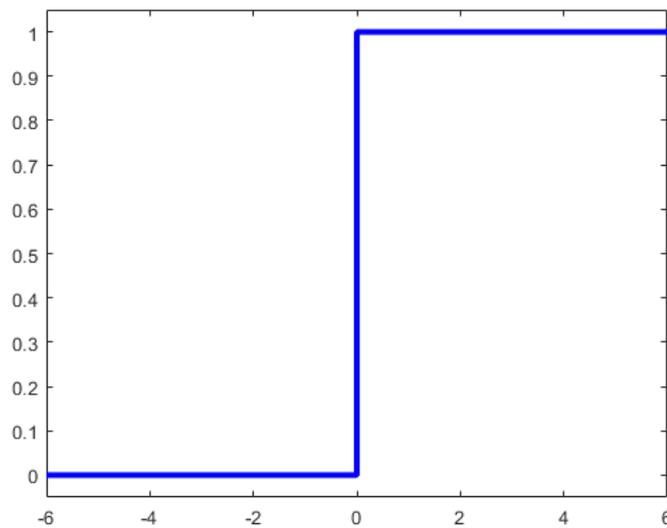


Fonte: do autor.

Além das duas funções de ativação mais comuns, a sigmoide logística e a tangente hiperbólica, existem outras funções bastante adotadas, como a função limiar, que é uma função de ativação simples e de baixíssimo custo computacional. Enquanto o neurônio não atinge um limite a saída do neurônio permanece em 0, caso contrário a saída é 1. Devido a sua simplicidade, também apresenta a limitação de não ser adequada para o treinamento da rede pelo algoritmo de *backpropagation*, por não ser diferenciável em  $t = 0$ . Seu gráfico é apresentado na Figura 20 e sua definição é apresentada pela Equação 3.26.

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (3.26)$$

Figura 20 – Função limiar (ou degrau)



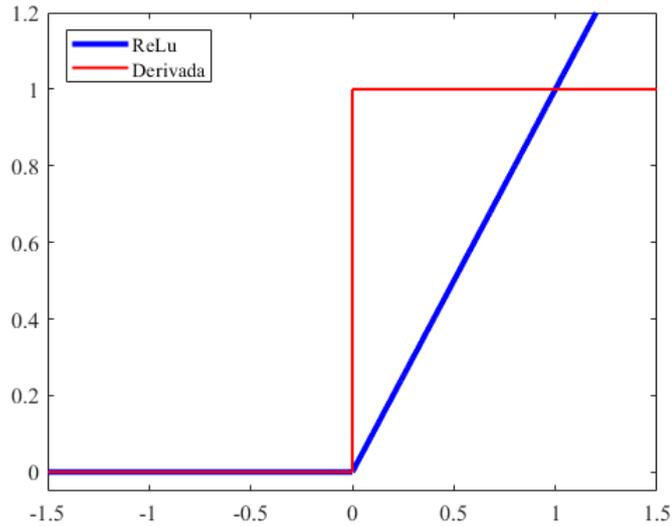
Fonte: do autor.

A função ReLu é outra função bastante utilizada, seu gráfico é apresentado pela Figura 21, enquanto sua definição matemática e sua derivada são apresentadas pelas Equações 3.27 e 3.28 respectivamente.

$$\varphi(v) = \max(0, v) \quad (3.27)$$

$$\varphi'(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{c. c.} \end{cases} \quad (3.28)$$

Figura 21 – ReLu



Fonte: do autor.

Sua simplicidade conduz uma grande capacidade de aprendizado para as redes neurais, especialmente para redes neurais profundas, redes de muitas camadas ocultas, além de conferir eficiência a esse processo. Isso se deve ao fato de que entradas negativas não ativam os neurônios, e estes podem ser ativados individualmente na rede (GLOROT *et al.*, 2011). Sua simplicidade também apresenta a desvantagem de o neurônio entrar no estado de “morte” quando não recebe entradas positivas, não contribuindo para o aprendizado da rede.

A estrutura de uma rede neural é muito flexível, porém a escolha e a combinação dos hiperparâmetros representa um desafio, pois, são vários e tem grande influência no desempenho do aprendizado da rede, como a sua capacidade de generalização e de convergência. Entre os principais hiperparâmetros tem-se o número de camadas ocultas, número de neurônios por camada, a função de ativação em cada camada, a taxa de aprendizagem, o valor de inicialização dos pesos e do bias (GÉRON, 2017).

Redes neurais com poucas camadas ocultas, uma, por exemplo, são conhecidas por redes “rasas”. Uma rede com uma camada oculta consegue aprender funções complexas, mas para isto pode se fazer necessário um grande número de neurônios. Enquanto as redes profundas têm mais camadas ocultas e tem a capacidade modelar essas mesmas funções com um número significativamente menor de neurônios (GÉRON, 2017).

As redes profundas tendem a ser mais poderosas porque nas redes rasas todo o poder de processamento fica contido em uma única camada ou em um pequeno número de camadas, o que pode sobrecarregar os neurônios. Enquanto em uma rede com mais camadas ocultas as tarefas são divididas hierarquicamente em cada uma das camadas, progredindo na complexidade de processamento das camadas mais inferiores para as mais avançadas, até a saída. Isto melhora a eficiência da rede com uma convergência mais rápida e melhora seu poder

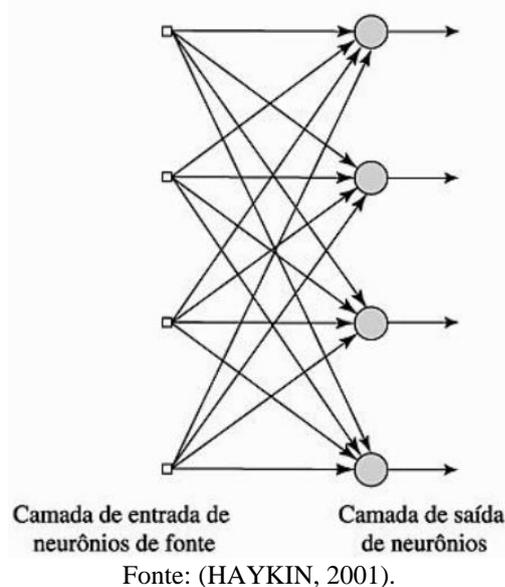
de generalização (GÉRON, 2017).

O processamento realizado por uma rede neural profunda é dividido por várias camadas e vários neurônios, o que implica que a construção de uma nova rede neural que precise reconhecer uma característica das classes da rede anterior, pode ser inicializada reutilizando os pesos das camadas ocultas inferiores da antiga rede neural. Isto diminuirá o tempo de treinamento da rede e exigirá menos dados, pois, esta não precisa começar o treinamento do zero para obter um ajuste satisfatório dos pesos sinápticos (GÉRON, 2017).

O número de neurônios das camadas de entrada e saída é determinado pela entrada e saída que a rede processa. Considerando a estrutura hierárquica das camadas ocultas, estas tendem a ser organizadas em forma de funil. As camadas inferiores guardam recursos de baixo nível das classes a serem classificadas, enquanto o número de recursos de alto nível é bem maior nas camadas avançadas (GÉRON, 2017).

As estruturas das redes estão intimamente ligadas ao algoritmo de aprendizagem que a estas podem ser aplicadas. A mais simples são as redes alimentadas adiante com camada única, como apresentado na Figura 22. Esta é composta apenas por uma camada de entrada e uma de saída, sendo esta chamada de rede de camada única, pois somente a camada de saída é composta por neurônios. A camada de entrada não realiza nenhuma computação, sendo responsável apenas por alimentar a rede com dados, acrescido do *bias* como um dado de entrada adicional (HAYKIN, 2001).

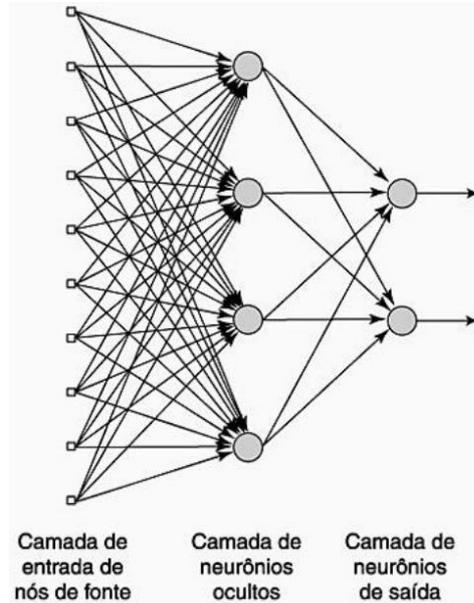
Figura 22 – Rede alimentada adiante com camada única



Por sua vez, nas redes com múltiplas camadas, há neurônios intermediários entre a entrada e a saída, estas são chamadas de camadas ocultas e são úteis para tornar a rede capaz de extrair mais estatísticas de ordem elevada. A saída de cada camada oculta constituem

entradas para as camadas seguintes, até a saída da rede (HAYKIN, 2001). A Figura 23 apresenta um esquema dessa arquitetura.

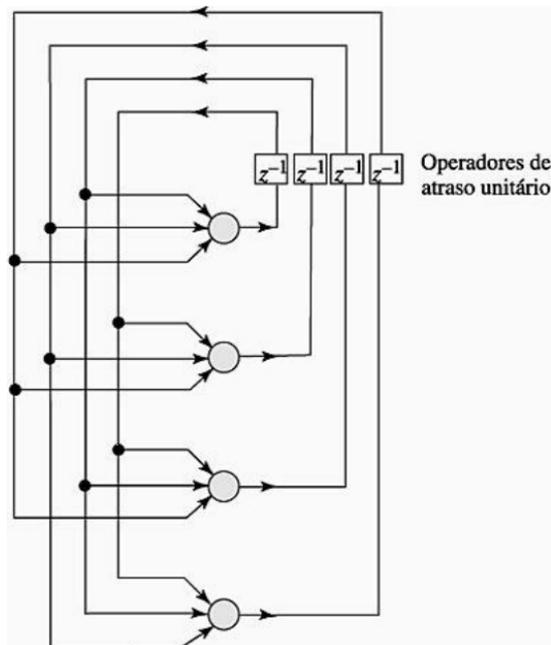
Figura 23 – Rede alimentada diretamente com múltiplas camadas



Fonte: (HAYKIN, 2001).

As redes recorrentes são aquelas que apresentam pelo menos um laço de realimentação. Esses laços são compostos de operadores de atraso unitário  $z^{-1}$ , que alimentam a entrada da rede ou os neurônios da camada oculta com o sinal de saída da rede, ou de saída do neurônio, respectivamente. Quando a saída de um neurônio é usada como entrada neste mesmo neurônio, temos a auto-realimentação (HAYKIN, 2001). Um fluxograma de uma rede recorrente é apresentado na Figura 24.

Figura 24 – Rede recorrente sem auto-realimentação ou camadas ocultas



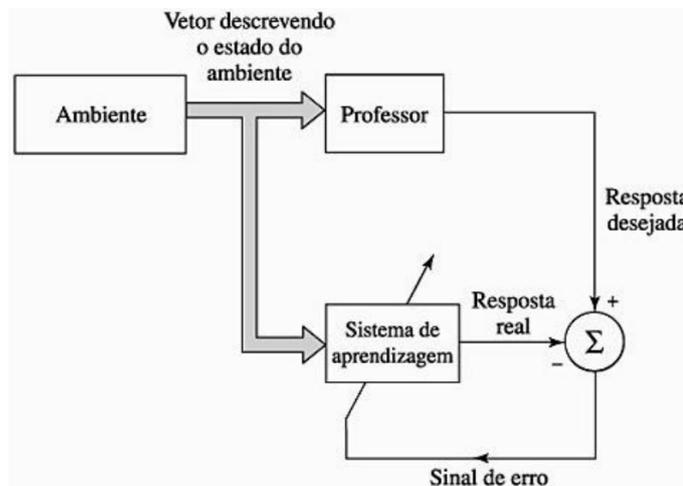
Fonte: (HAYKIN, 2001).

Escolhida a arquitetura da rede mais adequada, tem-se início o processo de aprendizagem. Para isto, um subconjunto de exemplos retirados do mundo real ou artificiais é utilizado em um processo iterativo, para alterar os parâmetros internos da rede, como os pesos sinápticos. A escolha dos valores para inicializar os pesos é muito importante para o processo de aprendizado da rede, especialmente nos primeiros de processamento do treinamento. Valores altos tendem a provocar a saturação dos neurônios, fazendo-se com que estes não contribuam para a convergência da saída da rede para a resposta desejada, enquanto valores muito baixos podem tornar o processo de aprendizado lento a ponto de não permitir aprendizado satisfatório com os dados disponíveis. Estes valores de inicialização devem, preferencialmente está em uma faixa de valores menor que os limites da função de ativação utilizada.

Assim como os pesos sinápticos, o vetor de entrada deve ser normalizado para a faixa de valores limites da função de ativação, para evitar a saturação dos neurônios e estagnação da aprendizagem.

Existe uma variedade de algoritmos de aprendizagem que podem ser utilizados para o treinamento de uma rede neural, mas para que o processo de aprendizado convirja na direção desejada é necessário atribuir crédito ou culpa as decisões tomadas, e uma das formas disso ser feito é por meio aprendizado supervisionado, mostrado em um diagrama de blocos na Figura 25.

Figura 25 – Aprendizagem supervisionada



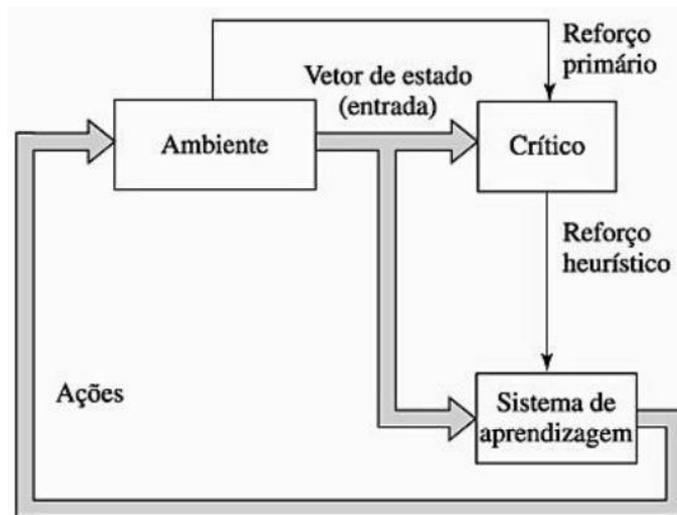
Fonte: (HAYKIN, 2001).

Neste método um conjunto de exemplos artificiais ou retirados do mundo real é apresentado a rede neural por um “professor”, que conhece a resposta desejada. Durante o processo iterativo de treinamento, o sinal de erro entre a resposta desejada e a resposta real proporciona o ajuste dos pesos até que a rede tenha um desempenho satisfatório (HAYKIN,

2001).

Outra forma de treinamento é realizada sem a presença de um ‘professor’, o qual pode acontecer de duas formas. O primeiro é pelo aprendizado por reforço, em que o sinal escalar de reforço primário fornecido pelo ambiente ao crítico, responsável por supervisionar o aprendizado, é convertido em um sinal de reforço heurístico de melhor qualidade, que minimize a função custo, para avançar no aprendizado, cuja função é proporcionar uma sequência de ações tomadas ao longo do treinamento (HAYKIN, 2001). Na Figura 26 é apresentado um diagrama em blocos do aprendizado supervisionado por reforço.

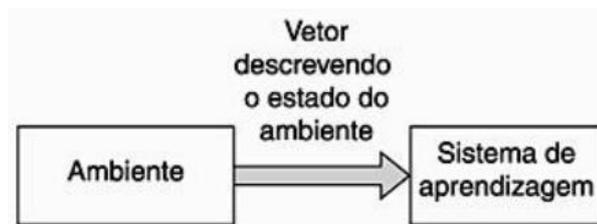
Figura 26 – Aprendizado supervisionado por reforço



Fonte: (HAYKIN, 2001).

A outra forma, a rede pode realizar uma medida independente na qualidade da representação a partir dos dados do ambiente, de modo que ao ajustar seus parâmetros livres a esses dados de entrada, desenvolva a capacidade de formar novas classes (HAYKIN, 2001). O esquema em diagrama de blocos desse aprendizado é apresentado na Figura 27.

Figura 27 – Aprendizado não-supervisionado



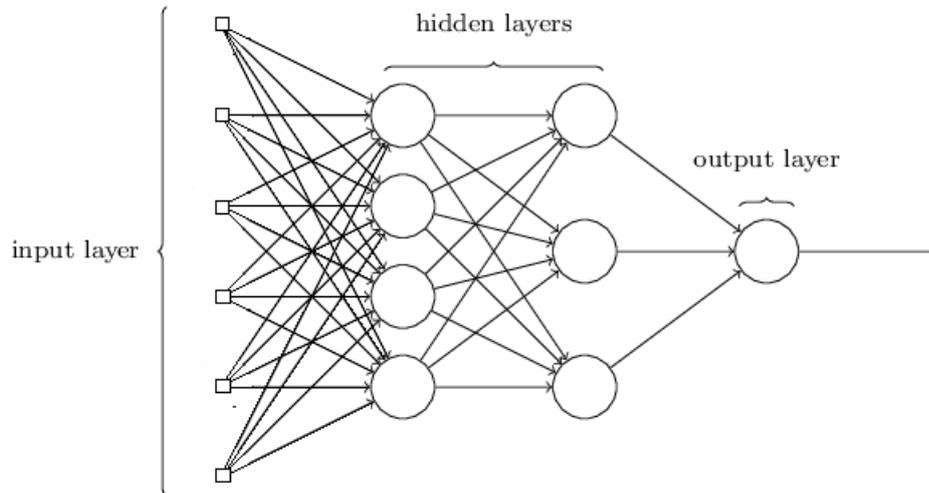
Fonte: (HAYKIN, 2001).

### 3.3 A REDE MLP

As redes neurais do tipo *Multilayer Perceptron* (MLP) apresentam uma camada de entrada, que não é composta de neurônios, uma ou mais camadas ocultas e uma camada de

saída, compostas de neurônios computacionais. Tal rede apresenta como característica a utilização de uma função de ativação, preferencialmente não-linear, neurônios ocultos e alta conectividade entre esses neurônios (HAYKIN, 2001). A estrutura de uma rede MLP pode ser vista na Figura 28.

Figura 28 – Perceptron Multicamadas (MLP)



Fonte: Adaptado de (DEEP LEARNING BOOK, 2020).

A utilização do treinamento supervisionado por *backpropagation* possibilita que esta rede seja utilizada em uma ampla variedade de aplicações e esse processo é realizado em duas etapas, propagação, ou passo para frente, e retropropagação, ou passo para trás. A seguir o algoritmo *backpropagation* é descrito detalhadamente.

No passo para a frente, ou propagação, os pesos sinápticos permanecem fixos durante a propagação do sinal por toda a rede. Ao final da propagação do sinal, a resposta real da rede é comparada a resposta desejada. No segundo passo, retropropagação, que começa na camada de saída, a diferença entre o sinal de saída e o sinal desejado, comumente chamado de rótulo em tarefas de classificação e de alvo em tarefas de modelagem, produz, normalmente, um erro de aproximação que é utilizado para o ajuste dos pesos sinápticos de todos os neurônios, considerando a contribuição de cada conexão sináptica, até se chegar aos pesos que conectam a camada de entrada à primeira camada oculta (HAYKIN, 2001).

Observando o neurônio da Figura 29, o sinal de erro  $e_j(n)$ , calculado no neurônio de saída  $j$ , na interação  $n$ , quando o  $n$ -ésimo exemplo de treinamento é apresentado, é dado por

$$e_j(n) = d_j(n) - y_j(n) \quad (3.29)$$

Em que  $d_j(n)$  é a resposta desejada para o neurônio  $j$  na interação  $n$ , e  $y_j(n)$  é o sinal funcional, que aparece na saída do neurônio  $j$  na interação  $n$ , resultante da propagação do sinal de entrada da rede através de todas as camadas. A energia instantânea do erro no neurônio  $j$  e

definida como  $\frac{1}{2}e^2(n)$ .

O valor instantâneo  $\xi(n)$  da energia total do erro é a soma de todas as energias instantâneas de todos os neurônios da camada de saída, como descrito pela Equação 3.30.

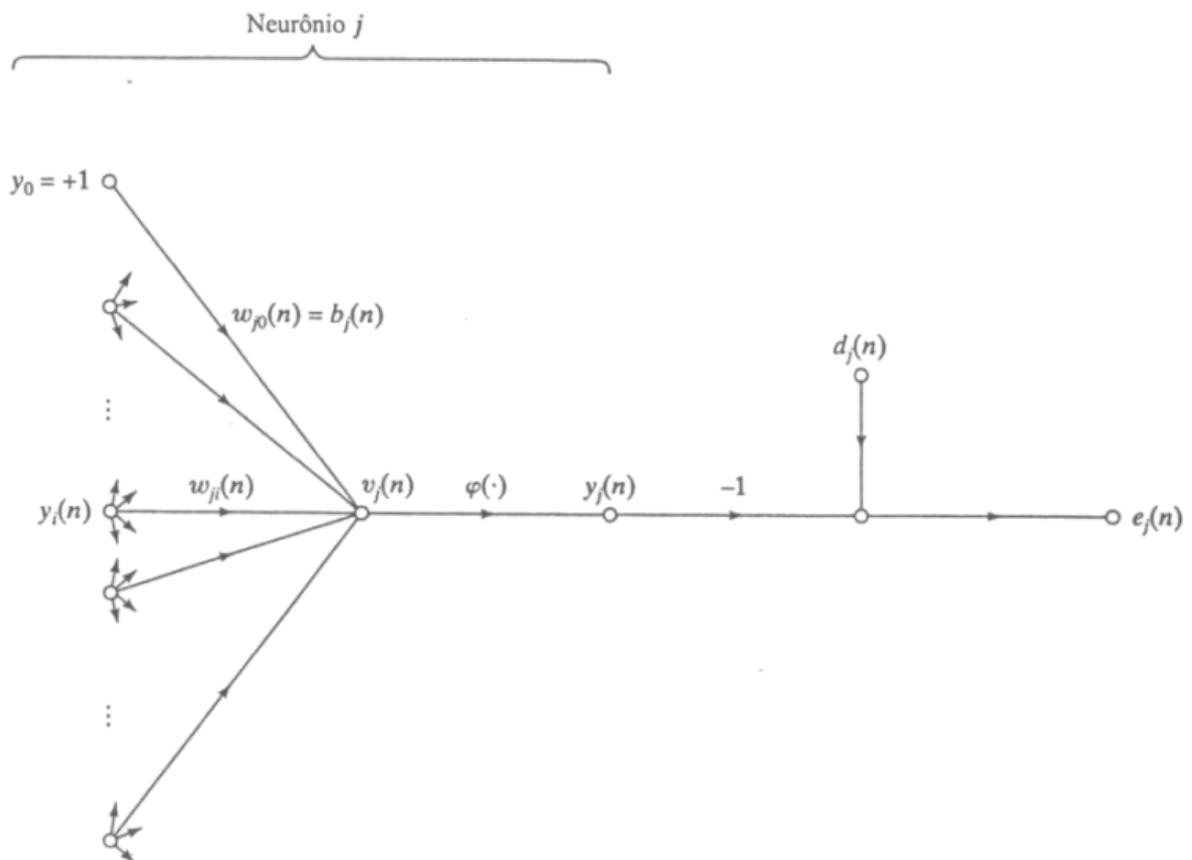
$$\xi(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (3.30)$$

Onde, o conjunto  $C$  inclui todos os neurônios da camada de saída.

Considerando  $N$  como o número total de exemplos utilizado no treinamento, a energia média do erro quadrático é obtida somando-se o  $\xi(n)$  para todas as  $N$  amostras, é dada pela Equação 3.31.

$$\xi_{med} = \frac{1}{N} \sum_{n=1}^N \xi(n) \quad (3.31)$$

Figura 29 – Fluxo de sinal no neurônio de saída  $j$



Fonte: (HAYKIN, 2001).

O campo local induzido  $v_j(n)$  de um neurônio que recebe como entrada os sinais funcionais dos neurônios de uma camada anterior, é calculado como mostrado na Equação 3.32

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)y_i(n) \quad (3.32)$$

Onde  $m$  é o número total de entradas menos, com exceção do *bias*, e  $w_{ji}(n)$  é o peso sináptico conectando a saída do neurônio  $i$  à entrada do neurônio  $j$ , na interação  $n$ , e  $y_i(n)$  é o sinal funcional que aparece na saída do neurônio  $i$ , na interação  $n$ . Assim, o sinal funcional que aparece na saída do neurônio  $j$  é dado por

$$y_j(n) = \varphi_j(v_j(n)) \quad (3.33)$$

O ajuste dos pesos sinápticos no algoritmo de retropropagação é proporcional a derivada parcial de  $\partial\xi(n)/\partial w_{ji}(n)$ , o qual é expresso como

$$\frac{\partial\xi(n)}{\partial w_{ji}(n)} = \frac{\partial\xi(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (3.34)$$

Diferenciando-se a Equação (3.30) em ambos os lados por  $e_j(n)$ , obtemos:

$$\frac{\partial\xi(n)}{\partial e_j(n)} = e_j(n) \quad (3.35)$$

Em seguida, derivando-se a Equação (3.29) em ambos os lados por  $y_j(n)$ , segue:

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (3.36)$$

Agora diferenciando a Equação (3.33) em ambos os lados por  $v_j(n)$ :

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad (3.37)$$

Onde, o apóstrofo indica a derivada em relação ao argumento.

Então, derivando-se (3.32) em ambos os lados por  $w_{ji}(n)$ :

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (3.38)$$

Substituindo-se as Equações (3.35) à (3.38) na Equação (3.34), resulta:

$$\frac{\partial\xi(n)}{\partial w_{ji}(n)} = -e_j(n)\varphi'_j(v_j(n))y_i(n) \quad (3.39)$$

O gradiente de correção dos pesos  $\Delta w_{ji}(n)$ , definida pela regra delta, é:

$$\Delta w_{ji}(n) = -\eta \frac{\partial\xi(n)}{\partial w_{ji}(n)} \quad (3.40)$$

Sendo  $\eta$  a taxa de aprendizagem e o sinal negativo indica a descida do gradiente no espaço de pesos, ou seja, a redução do valor de  $\xi(n)$ .

Por sua vez, ao substituir a Equação (3.39) em (3.40), tem-se:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (3.41)$$

Onde,  $\delta_j(n)$  é o gradiente local o qual é definido por:

$$\begin{aligned} \delta_j(n) &= -\frac{\partial \xi(n)}{\partial v_j(n)} \\ &= -\frac{\partial \xi(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \\ &= e_j(n) \varphi'_j(v_j(n)) \end{aligned} \quad (3.42)$$

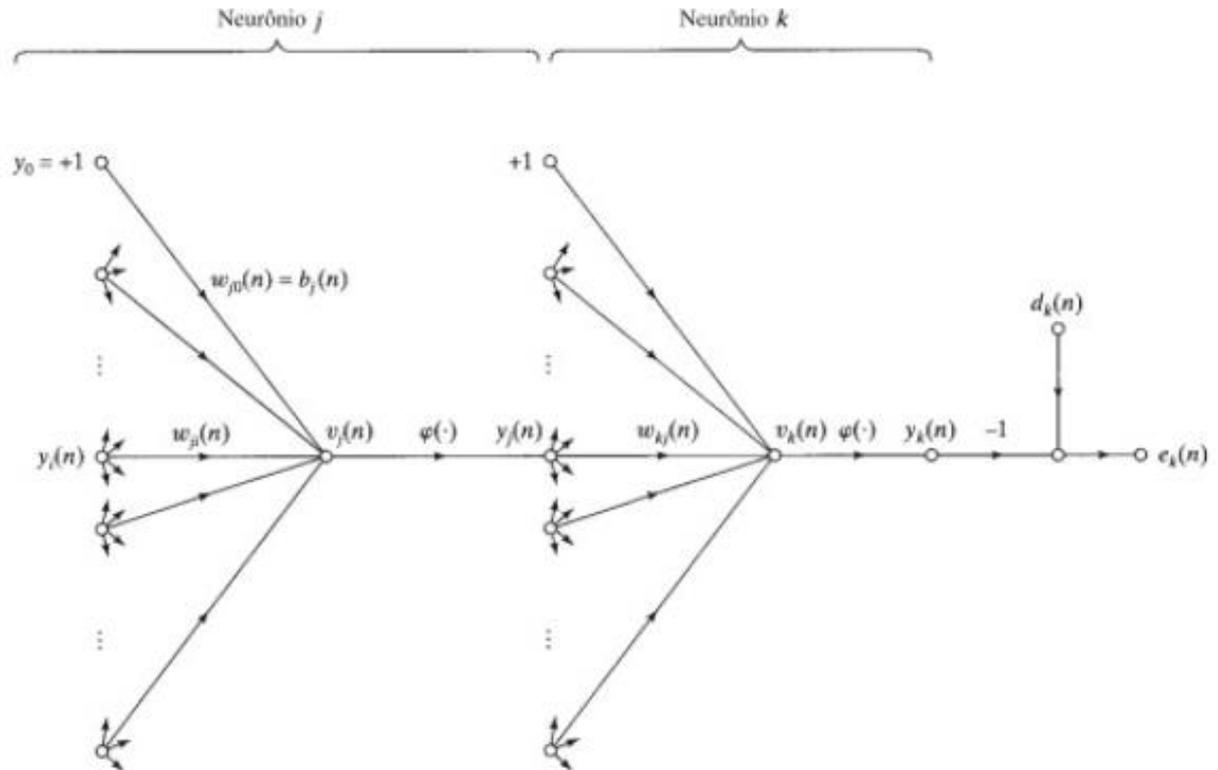
Assim, o gradiente local do erro  $\delta_j(n)$  de um neurônio intermediário é igual ao produto do sinal de erro  $e_j(n)$  associado aquele neurônio e a derivada da função de ativação  $\varphi'_j(v_j(n))$ .

Dessa forma a utilização de uma função de ativação derivável é obrigatória para realização do algoritmo *backpropagation*. E outro fator tão importante quanto este, é a identificação do erro  $e_j(n)$  na saída dos neurônios das camadas ocultas. A identificação do erro associado a cada neurônio na camada de saída pode ser obtida diretamente pela Equação (3.29), uma vez que cada neurônio tem uma resposta desejada associada ele. Os neurônios das camadas ocultas também contribuem para o erro de saída e cada um deve ser ajustado de acordo com sua contribuição.

Devido aos neurônios ocultos não terem uma resposta desejada associada, o sinal de erro associado a estes deve ser determinado recursivamente em termos dos sinais de erro de todos os neurônios aos quais ele está diretamente conectado, utilizando a mesma regra do gradiente descendente (HAYKIN, 2001).

Considere a imagem da Figura 30, onde é detalhado o fluxo de sinal funcional entre um neurônio na camada oculta  $j$  e um neurônio na camada de saída  $k$ .

Figura 30 – Fluxo de sinal entre o neurônio  $j$  e o neurônio  $k$



Fonte: (HAYKIN, 2001).

O gradiente local de erro do neurônio oculto  $j$  é dado pela Equação 3.43.

$$\begin{aligned} \delta_j(n) &= -\frac{\partial \xi(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \\ &= -\frac{\partial \xi(n)}{\partial y_j(n)} \varphi'_j(v_j(n)) \end{aligned} \quad (3.43)$$

Derivando-se a Equação (3.30) em relação ao sinal funcional  $y_j(n)$ , obtém-se:

$$\frac{\partial \xi(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (3.44)$$

Utilizando a regra da cadeia para a derivada parcial  $\partial e_k(n)/\partial y_j(n)$  e reescrevendo a Equação (3.44) na forma equivalente:

$$\frac{\partial \xi(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (3.45)$$

Notando que:

$$\begin{aligned} e_k(n) &= d_k(n) - y_k(n) \\ &= d_k(n) - \varphi_k(v_k(n)) \end{aligned} \quad (3.46)$$

Assim,

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi'_k(v_k(n)) \quad (3.47)$$

Consequentemente,

$$v_k(n) = \sum_{j=0}^m w_{kj}(n)y_j(n) \quad (3.48)$$

Da mesma forma,  $m$  representa o número total de entradas com exceção do *bias*. Derivando a Equação (3.48) em relação a  $y_j(n)$ , obtém-se

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (3.49)$$

Então substituindo os resultados das Equações (3.47) e (3.49) em (3.45):

$$\begin{aligned} \frac{\partial \xi(n)}{\partial y_j(n)} &= - \sum_k e_k(n) \varphi'_k(v_k(n)) w_{kj}(n) \\ &= - \sum_k \delta_k(n) w_{kj}(n) \end{aligned} \quad (3.50)$$

Finalmente substituindo a Equação (3.50) na (3.43), obtém-se:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (3.51)$$

Obtemos, portanto, a fórmula de retropropagação do gradiente local para o neurônio  $j$  da camada oculta.

O ajuste dos pesos busca minimizar os gradientes de erro local e a taxa de aprendizagem  $\eta$  no qual este parâmetro está intimamente ligada a velocidade de convergência da rede. Taxas de aprendizagem grandes promovem grandes mudanças nos pesos sinápticos e rápida descida no gradiente de pesos, mas isso tende a causar instabilidade na rede, ou seja, dificuldade de convergência. Já a utilização de uma taxa pequena promove pequenas mudanças nos pesos sinápticos e maior estabilidade, mas torna o processo de aprendizagem mais lento.

Para resolver esses dois extremos na escolha da taxa de aprendizagem, uma estratégia é adotar uma taxa de aprendizagem que decaia ao longo das épocas, ou pode-se inserir na Equação (3.41) o termo de momento. O termo de momento tem a função de trazer para a interação atual um certo nível de influência do gradiente descendente que foi calculado na interação anterior. A forma de melhorar a influência da taxa de aprendizado no processo de aprendizado da rede é adotar um fator de decaimento para essa taxa, que pode ser linear, mas usualmente é exponencial.

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) y_i(n) \quad (3.52)$$

Onde  $\alpha$  é a constante de momento e  $0 \leq |\alpha| < 1$ . Dessa forma, a diminuição dos gradientes de erro é acelerada nas interações iniciais de treinamento de rede e a convergência é estabilizada em interações posteriores.

O processo de aprendizagem exige a apresentação de várias épocas, onde, se a tarefa é de classificação ou otimização, o embaralhamento dos dados é obrigatório. Se a tarefa é modelagem ou identificação de sistemas os dados não podem ser embaralhados entre épocas, pois, a sequência dos dados é intricadamente relacionada a dinâmica do sistema, que deseja capturar o modelo através do treinamento da rede. O processo termina quando o critério de parada é alcançado. Usualmente uma métrica adotada como critério de parada é definido um valor máximo para o erro quadrático médio (EQM). Deseja-se que esse convirja para o menor valor possível, caracterizando a estabilização na evolução do aprendizado e boa captura do modelo. Uma boa métrica para quantificar essa convergência é a variância do erro ao longo das épocas. Nas tarefas de classificação e otimização, a apresentação dos dados em sequências aleatórias, a cada nova época, evita que a rede decore a sequência dos dados, em vez de aprender a lógica que modela os dados.

A aprendizagem pelo algoritmo de retropropagação pode acontecer de duas formas, dependendo de como os dados são apresentados. A forma mais usual é o modo sequencial, onde depois de cada exemplo (vetor) do conjunto de exemplos de uma época, os pesos sinápticos são ajustados pelo algoritmo. A outra forma se chama modo por lote, onde o ajuste dos pesos só acontece depois que todos os exemplos de uma época são apresentados (HAYKIN, 2001).

Após a definição de todos os parâmetros de treinamento, resta definir que critério usar para encerrar o treinamento. Um critério de parada satisfatório é que a norma do vetor gradiente da superfície de erro em relação ao vetor peso seja zero ou próximo de zero. Isso pode sinalizar localização de um mínimo local ou mínimo global na superfície de erro, e nada pode garantir a localização de um mínimo global se o problema não possuir solução deterministicamente definida. Outro critério de parada que pode ser usado para o encerramento do treinamento é quando a taxa de variação absoluta do erro quadrático médio por época se estabiliza em um valor suficientemente pequeno, geralmente entre 0,1% e 1% (HAYKIN, 2001).

## 4. METODOLOGIA PROPOSTA

### 4.1 INTRODUÇÃO

O classificador proposto nesse trabalho funciona em modo off-line e foi implementado através do *software* Matlab® (versão estudante). O qual foi utilizado tanto para implementar a transformada de Gabor quanto para projetar e treinar as redes MLP, treinadas pelo algoritmo *backpropagation* no modo sequencial, assim como para implementar o classificador final. O código utilizado para implementar algoritmo *backpropagation* foi desenvolvido pelo autor, sem a utilização das *Toolbox* internas do *software* Matlab®, e é apresentado no Anexo I.

O mesmo *software* foi utilizado para avaliar o desempenho do classificador projetado, aplicado na identificação de cargas residenciais em sobreposição em um único circuito. Utilizou-se o erro quadrático médio como métrica quantitativa de desempenho das redes treinadas e as curvas de aprendizado para avaliação qualitativa da convergência dos processos de aprendizagem. Ao final, montou-se a matriz de confusão para identificar a dificuldade do classificador em reconhecer cada classe.

### 4.2 DEFINIÇÃO DO PROBLEMA

Esse trabalho tem a proposta de desenvolver um classificador para identificar a assinatura elétrica de quatro tipos de cargas, que podem estar energizadas simultaneamente por um mesmo circuito. Para isso, é necessário utilizar uma técnica para identificar os instantes de entrada e saídas das cargas, para que se possa então separar os sinais individuais de cada nova carga que entrar no circuito. Esse processo está descrito a seguir.

Cargas elétricas invariavelmente apresentam os estágios transitório e estacionário. Mesmo cargas puramente resistivas, que podem ser consideradas constantes, tem alguma componente transitória nos instantes seguintes à energização. Um exemplo claro de estágio transitório é a partida de motores de indução, que podem alcançar até 9 vezes a corrente nominal nos instantes seguintes após a partida desta máquina.

Os estágios transitórios das cargas podem durar de milissegundo até segundos, dependendo das características eletromagnéticas e eletromecânicas da carga em questão. Os equipamentos podem apresentar um único evento transitório durante a partida ou este pode ainda apresentar eventos transitórios intermitentes durante o período de funcionamento. A influência que cada carga tem na rede a qual está conectada pode tornar a sua identificação um

desafio.

Considerando a característica transitória das cargas, esse trabalho propõe um método de monitoramento não intrusivo baseado em análise da variação de espectro de frequência no tempo, utilizando-se janelas de observações com amplitude de 31 milissegundos, para identificar a entrada ou saída de cargas no circuito monitorado, de forma a permitir um desacoplamento automático dos sinais de cada carga no sinal geral, assim como para extrair atributos do sinal de corrente que são utilizados para identificar a assinatura elétrica destas. A amplitude da janela foi definida com o valor citado, por apresentar uma boa relação de resolução no tempo e na frequência. Esses atributos são apresentados a um conjunto de redes neurais artificiais, onde cada rede é treinada para reconhecer a assinatura elétrica de corrente de uma das 4 cargas avaliadas.

Nesta pesquisa o classificador projetado utiliza redes neurais treinadas para identificar as seguintes cargas: um reator eletrônico com fator de potência 0,93, sob tensão de 220 V, alimentando duas lâmpadas fluorescentes de 20 W, ligadas em paralelo; duas lâmpadas incandescentes de 40 W e 220 V ligadas em série, um motor monofásico de 0.37 kW, operando em tensão de 220 V/60 Hz, com corrente nominal de 3.0 A, fator de potência de 0.99 e velocidade síncrona de 1800 rpm; e um motor de indução trifásico (MIT) de 1.1 kW, operando em tensão de 380 V/60 Hz, corrente nominal de 1.22 A, fator de potência de 0.69, 1800 rpm e rendimento de 67%.

Uma vez que o transitório de cargas pode ser identificado através da transformada de Gabor, esta pode ser usada para identificar a saída e entrada de cargas ao se monitorar a energia presente nos espectrogramas gerados sucessivamente em janelas de aquisição de 500 ms. Uma vez que a energia é registrada nos espectrogramas como o valor de pixels, comparando-se energia de um conjunto de colunas na matriz RGB, se for observada uma variação positiva significativa entre as observações conclui-se que houve uma entrada de carga, e se a variação for negativa conclui-se que houve uma saída de carga.

Assim, utilizando-se do método de desacoplamento de cargas em um sinal de corrente com sobreposição de cargas, como descrito anteriormente, e com o auxílio de redes neurais para identificar essas cargas será possível, portanto, obter a estratificação da conta de energia elétrica.

#### 4.3 METODOLOGIA DO TRABALHO

A primeira etapa metodologia adotada nesse trabalho consiste em utilizar a

transformada de Gabor para identificar os instantes entrada e a saída de cargas alimentadas simultaneamente por um circuito elétrico único. De posse dessa informação, calcula-se a diferença de corrente do circuito, antes e após a entrada da carga, de forma a extrair apenas o sinal de corrente específico da carga em análise. Então utilizam-se os parâmetros do espectrograma da transformada de Gabor, como atributos para o treinamento da rede MLP.

Adota-se a hipótese de que o surgimento repentino de nova frequência no sinal medido representa a entrada de uma nova carga, assim como o desaparecimento denuncia a saída de uma carga. Assim, o classificador deve ser capaz de reconhecer tanto as cargas que entram quanto as que saem.

Do conjunto de dados de treinamento apresentados sucessivamente a rede neural, esta deve apresentar a saída mais alta quando dados pertencentes a classe a que está sendo treinada é apresentado e valores baixos para dados de outras classes. Da mesma forma, na etapa de teste, espera-se que todas as redes apresentem saídas com valores baixos para dados de uma carga desconhecida. É utilizada uma rede neural para identificar cada uma das cargas avaliadas, pois o processo de aprendizado pode ser dificultado caso se busque projetar uma rede para modelar os quatro padrões de assinatura simultaneamente.

#### 4.3.1 Aquisição dos Dados

Para obter os dados dos equipamentos elétricos a serem identificados, utilizou-se um osciloscópio para se obter o sinal de corrente de cada carga, tendo sido adquirido 99 amostras para cada tipo de carga, com tempo de amostragem de  $2.0 \times 10^{-4}$  s e com janela de aquisição de 500 ms, a uma taxa de aquisição de 2,5kHz. A escolha dessa janela de aquisição foi feita com base na observação do tempo de transitórios de cada tipo de carga avaliada.

Para cada tipo de carga, foram adquiridas 99 amostras, totalizando, portanto, um banco de dados de 396 registros.

#### 4.3.2 Tratamento dos Dados

Mediu-se o sinal de corrente consumida pelas cargas em funcionamento na rede elétrica, tanto em regime transiente quanto em regime estacionário, em janelas de aquisição de 500 milissegundos. Esse sinal foi então submetido a Transformada de Gabor, para obtenção da distribuição temporal do espectro, na qual é utilizada como entrada para o treinamento da rede após o tratamento destes, como é detalhado a seguir.

Os espectrogramas obtidos pela transformada de Gabor são imagens RGB com

dimensões 632x1277, que foram redimensionadas para 5% do tamanho original, resultando em uma matriz de dimensões 32x64. A redução da matriz de dados é feita para reduzir o custo computacional do processo de aprendizagem, mas também pode acarretar na perda de informação relevante. Em seguida convertidas para escala de cinza, com os valores dos pixels normalizados entre [0 1]. Os dados das quatro cargas foram então vetorizados e rotulados na seguinte ordem, 1 para os dados do reator eletrônico, 2 para lâmpadas incandescente, 3 para motor de indução trifásico e 4 para motor de indução monofásico.

#### 4.3.3 Particionamento dos Dados

Os dados, após o tratamento descrito anteriormente, são particionados em um conjunto de treinamento e um de teste, sendo 80% dos dados destinados ao treinamento das redes e os 20% restantes para o teste de desempenho destas, que ocorre após o término de todas as épocas de treinamento de cada rede.

### 4.4 TREINAMENTO

#### 4.4.1 Seleção de Hiperparâmetros

Para o treinamento da rede MLP, pelo algoritmo de retropropagação, os dados de entrada, gerados pela transformada de Gabor e recondicionados pelas etapas de tratamento descritas anteriormente, são apresentados em sequência aleatória em cada uma das 120 épocas de treinamento e teste. A cada nova época os dados são reembaralhados e é realizada uma nova seleção de 80% de dados para treinamento e 20% para teste, seguido de nova rodada de treinamento e de teste. Ao término de cada época é contabilizado o EQM de cada rede neural, tanto para os dados de treinamento quanto para os de testes, e ao final de uma rodada o EQM global de todas as redes.

São treinadas quatro rede neurais, cada uma dedicada a identificar uma das quatro cargas consideradas. A arquitetura adotada para as 4 redes treinadas é a *feedforward* de apenas uma camada oculta, com 30 neurônios na camada oculta e 1 na camada de saída. Sendo número de neurônios obtido através da tentativa e erro. Adotou-se como função de ativação para todos os neurônios da camada oculta e da camada de saída a função tangente hiperbólica, e como bias o valor -1.

Os valores de inicialização dos pesos sinápticos, tanto da camada de entrada quanto da camada oculta, foram escolhidos de forma a gerar uma distribuição de probabilidade

gaussiana com média zero, no intervalo entre  $-0,5$  e  $+0,5$ , portanto, compatível com os limites do contradomínio da função de ativação dos neurônios. A faixa de distribuição desses valores, juntamente com a normalização dos dados na faixa de valores de  $-1$  a  $1$ , resulta em campo induzido local predominantemente dentro dos limites de linearidade da função de ativação, no início do treinamento. Isso diminui a probabilidade de saturação dos neurônios nas rodadas iniciais de treinamento, o que diminui as chances de estagnação prematura do processo de aprendizado.

A escolha da taxa de aprendizagem  $\eta$  é importante no desempenho do processo de treinamento. A escolha desse parâmetro pode impactar diretamente na convergência e a estabilidade do aprendizado. No início do treinamento é preferível que este tenha um valor mais elevado, para acelerar o aprendizado da rede, porém valores superiores a  $0,5$  usualmente geram problemas de estabilidade no aprendizado, para a maioria das aplicações. No entanto, se esse valor for mantido em todo o treinamento, o aprendizado pode não alcançar convergência em muitos casos. Assim, usualmente, bons resultados são alcançados adotando-se uma taxa de aprendizado inicial elevada, que reduz progressivamente a cada nova época, de forma a alcançar valores bem baixos nas épocas finais, o que confere velocidade de aprendizado nas épocas iniciais e estabilidade nas finais.

Neste trabalho adotou-se o valor  $0,039$  como o valor de taxa de aprendizado inicial, com decaimento exponencial até  $0,001$ , e o termo de momento foi definido com o valor fixo de  $0,22$ . O valor inicial da taxa de aprendizagem e o termo de momento, assim como o número de neurônios foi obtido através da tentativa e erro.

#### 4.4.2 Critério de Parada do Treinamento

Geralmente não é possível garantir que o algoritmo de retropropagação convergiu. Um dos critérios para considerar que o algoritmo convergiu é identificar que a variação do erro médio quadrático, por época, a qual deve ser suficientemente pequena, usualmente adotam-se valores entre  $0,1$  e  $1$  (HAYKIN, 2001).

Nesse trabalho o critério de parada adotado para a realização do treinamento, foi a realização de  $120$  épocas de treinamento e teste para cada rede neural, o número de épocas foi definido através da tentativa e erro. Para se adotar taxa de aprendizado com decaimento até um valor desejado, faz-se necessário se ter pré-estabelecido o número de épocas, mas isso pode levar muito tempo. Portanto, o critério de parada adotado foi o número de épocas.

As  $120$  épocas foram realizadas em  $10$  rodadas, para se obter o valor médio do

EQM, e ser possível uma avaliação estatística mais significativa do processo, uma vez que a inicialização dos pesos é aleatória.

#### 4.5 O CLASSIFICADOR

O classificador adota uma discriminante linear simples como regra de classificação, de forma que se a saída de apenas uma rede é igual ou superior a 0,0, o dado é atribuído a classe representada por esta rede, e o dado é atribuído a classe de rejeição, chamada de ‘carga desconhecida’, caso contrário. Vale ressaltar que a função de ativação adotada na saída das redes é a tangente hiperbólica, cujo contradomínio está entre  $[-1 +1]$ .

#### 4.6 TESTE DOS MODELOS (MATRIZ DE CONFUSÃO)

Como métrica principal para avaliar o desempenho das redes neurais é utilizado a EQM da última rodada de treinamento e de teste. O cálculo do EQM de treinamento é realizado ao final de cada época e o de teste ao final de todas épocas da rodada. Observar a evolução do EQM ao longo das épocas de treinamento permite avaliar a estabilidade e convergência do aprendizado rede. É interessante que essa avaliação seja feita também através da matriz de confusão, que fornece o resultado das classificações realizadas, tanto as corretas quanto as erradas, como é explicada mais à frente.

Os dados reservados para o teste dos modelos, são utilizados para verificar se o processo de aprendizagem foi satisfatório, e uma das formas de visualizar o desempenho do aprendizado é observar a matriz de confusão de múltiplas classes. Como é necessário identificar quatro cargas distintas, a matriz assume dimensão 5x5, visto que a classificação classe desconhecida também deve ser avaliada e é representada pela classe E. Na matriz, as colunas indicam as classes corretas e as linhas correspondem as classificações realizadas pela rede.

Assim, a matriz de confusão contabiliza a quantidade de acertos e erros de cada classe, indicando as classes as quais os modelos classificam com maior e menor precisão. Considere o exemplo de matriz de confusão de múltiplas classes apresentado na Tabela 1.

Tabela 1 – Matriz de confusão de múltiplas classes

Real		A	B	C	D	E
Predito	A	VP	FP	FP	FP	FP
	B	FP	VP	FP	FP	FP
	C	FP	FP	VP	FP	FP
	D	FP	FP	FP	VP	FP
	E	FP	FP	FP	FP	VP

Fonte: do autor.

Os valores verdadeiros positivos (VP) na matriz, indicam o número de vezes que dados pertencentes a classe foi corretamente identificada, e os valores falso positivo (FP) indicam o número de vezes que dados pertencentes a uma classe foram incorretamente classificados como sendo outro equipamento.

O ideal é que apenas a diagonal principal contenha valores positivos, enquanto todo o restante assuma valores zeros, o que indica uma classificação com 100% de taxa de acerto. Isso mostraria que todas as redes neurais estariam classificando corretamente os dados de teste.

Dessa forma, analisando os resultados de diferentes formas, é possível se concluir sobre o desempenho das redes neurais treinadas e, possivelmente, indícios do que se deve modificar para melhorar o desempenho.

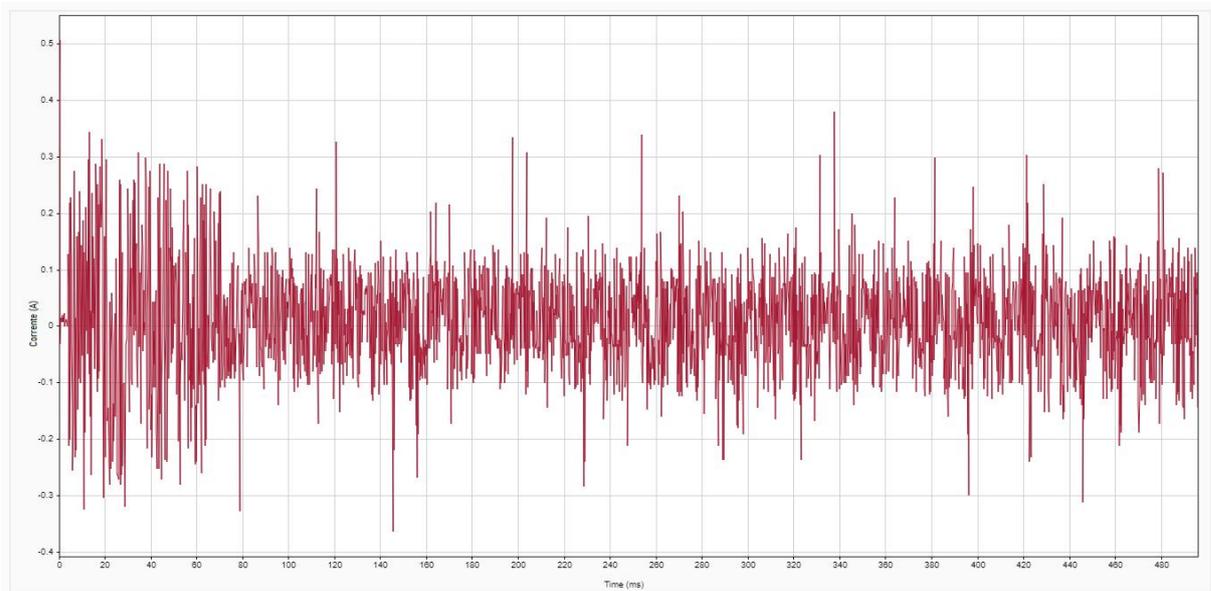
## 5. RESULTADOS

Neste capítulo são apresentados os resultados obtidos através do método descrito anteriormente. Com o objetivo de classificar as quatro cargas elétricas, sendo: um reator eletrônico com duas lâmpadas fluorescentes de 20 W em paralelo, duas lâmpadas incandescente de 40 W em série, motor de indução monofásico de 0,37 kW e motor de indução trifásico de 1,1 kW.

### 5.1 RESULTADOS NO TRATAMENTO DOS DADOS

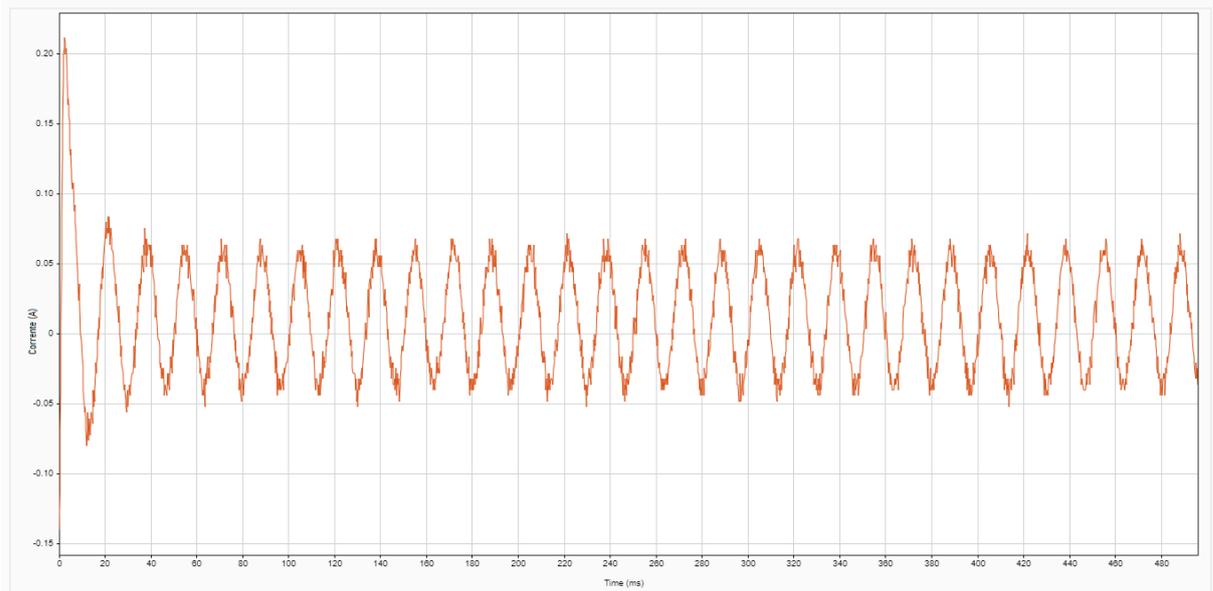
Uma amostra de sinal de corrente para cada carga em questão, obtidos através do osciloscópio, podem ser vistos nas Figura 31 a Figura 34. Cujas janelas de tempo de aquisição é de 500 ms e tempo de amostragem é de  $2.0 \times 10^{-4}$  s.

Figura 31 – Sinal de corrente do reator eletrônico com lâmpadas fluorescentes



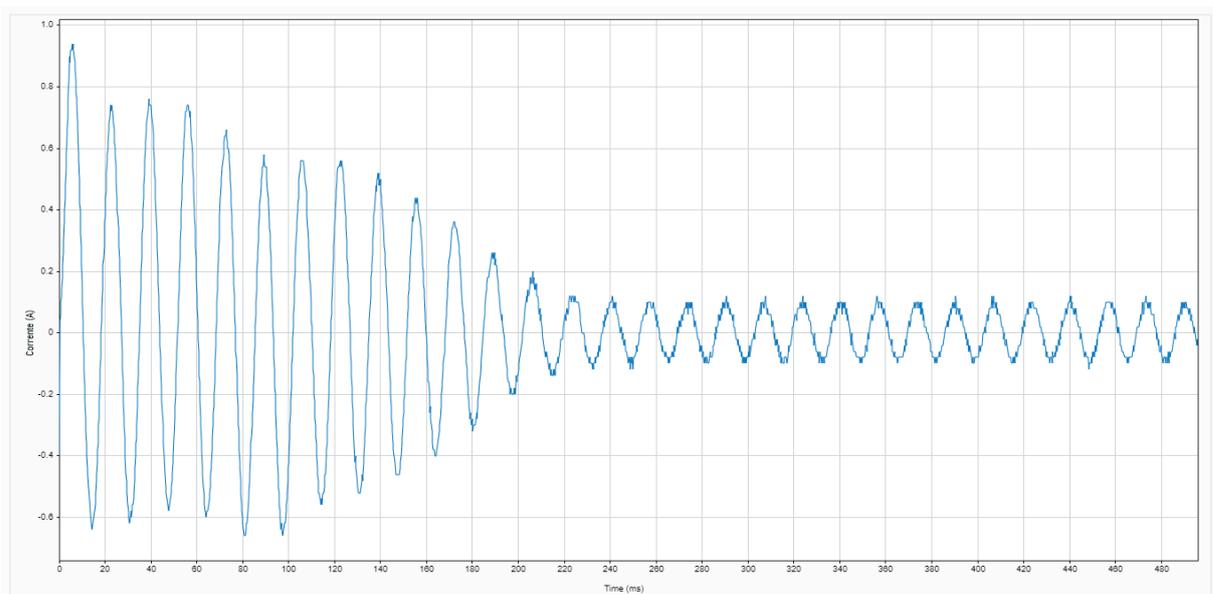
Fonte: do autor.

Figura 32 – Sinal de corrente das lâmpadas incandescentes



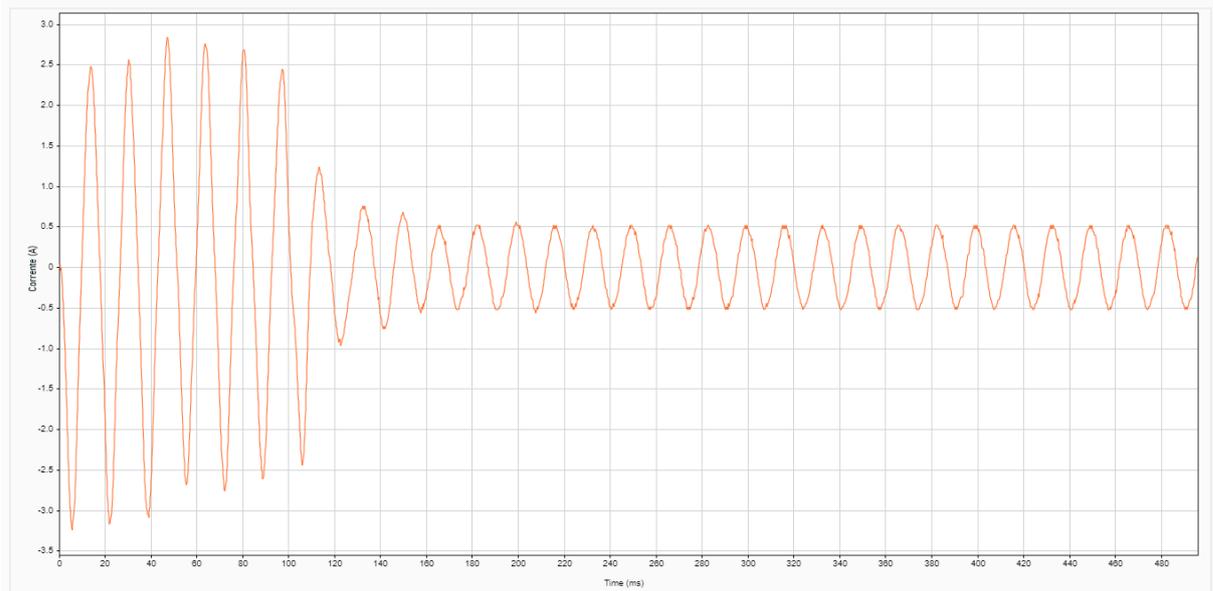
Fonte: do autor.

Figura 33 – Sinal de corrente de uma fase do MIT



Fonte: do autor.

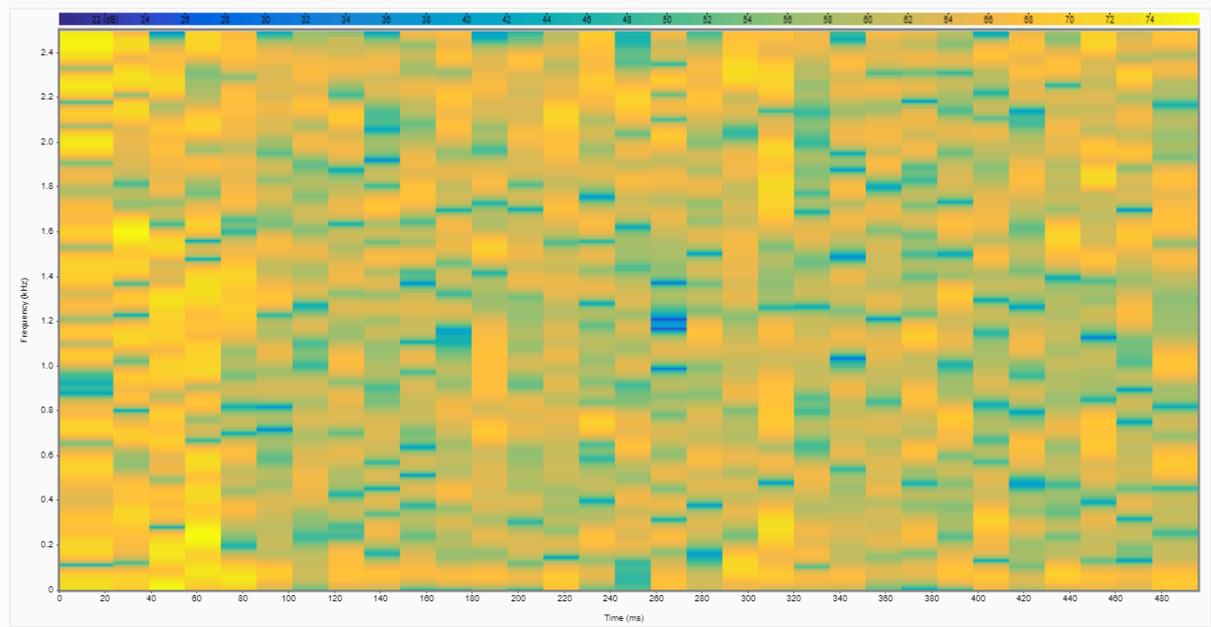
Figura 34 – Sinal de corrente do motor de indução monofásico



Fonte: do autor.

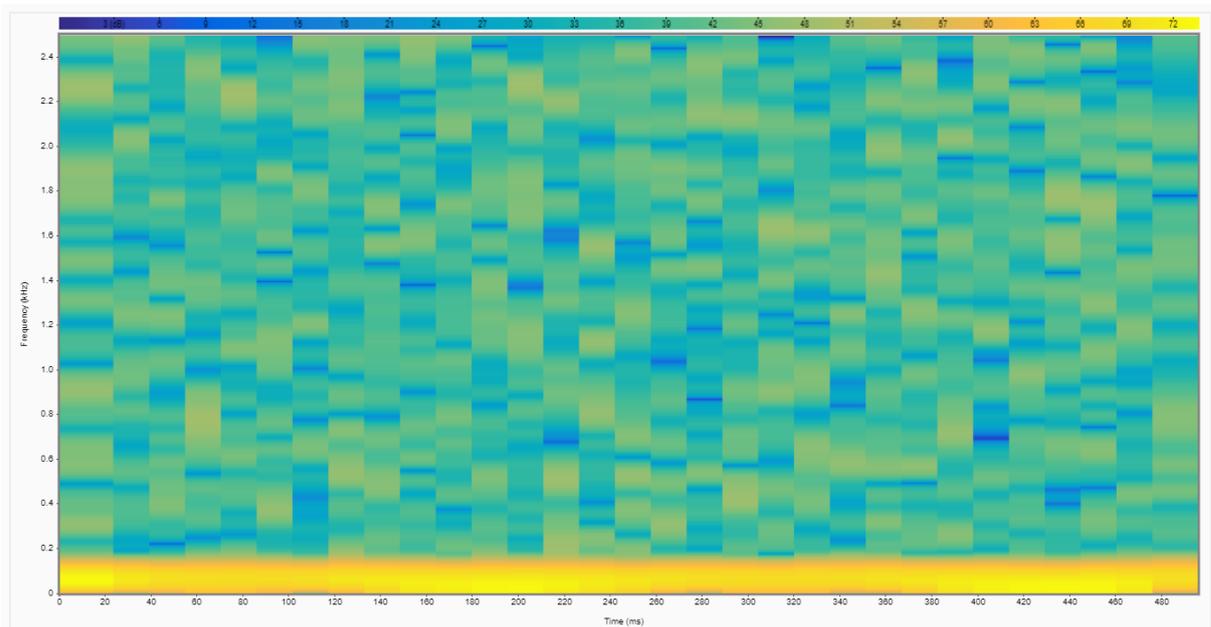
Após a análise dos dados de corrente, foram obtidos os espectrogramas em imagens RGB pela Transformada de Gabor, limitadas a frequência máxima de 2.5 kHz, janela de tempo de 500 ms, janela deslizante de 31 ms e uma sobreposição de janelas de 50%. O tamanho da janela deslizantes foi definido como tal, por apresentar o melhor equilíbrio entre a resolução em tempo e resolução na frequência para os sinais de corrente coletados. O limite da frequência foi escolhido de forma a ser compatível com a taxa de amostragem do sinal, conforme foi discutido na Seção 3.1, e a amplitude da janela de aquisição de forma a ser superior ao maior transitório das cargas em avaliação. Um exemplo de espectrograma obtido pela Transformada de Gabor para cada uma das cargas em questão pode ser identificado nas Figuras 35 a Figura 38.

Figura 35 – Espectrograma da corrente do reator eletrônico



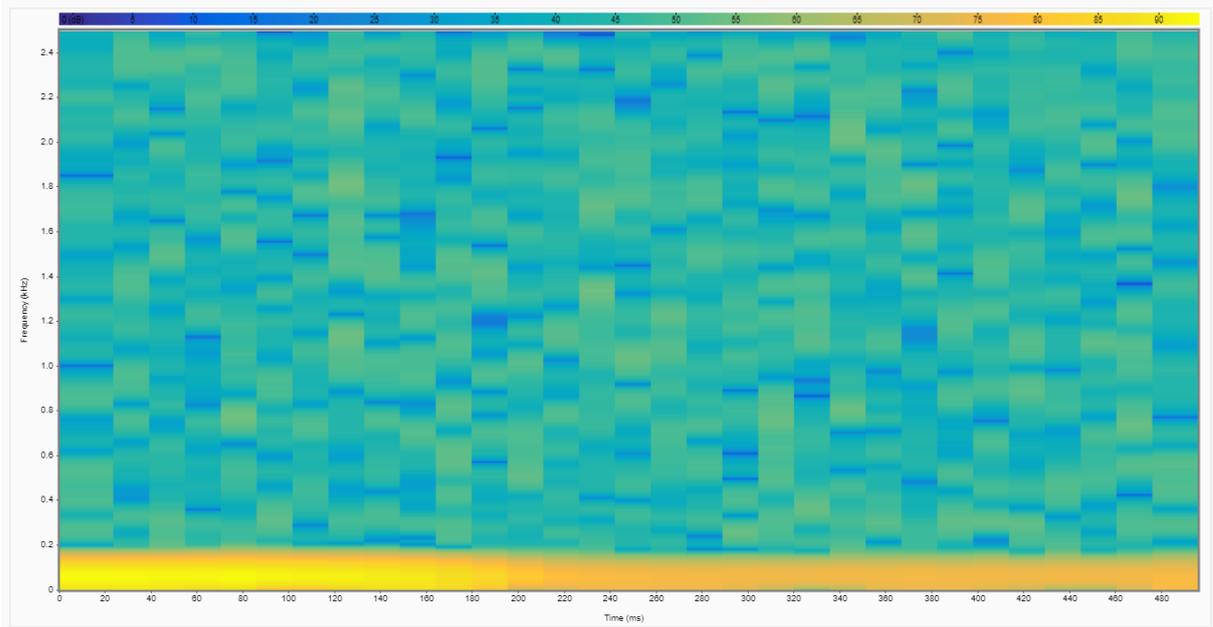
Fonte: do autor.

Figura 36 – Espectrograma da corrente das lâmpadas incandescentes



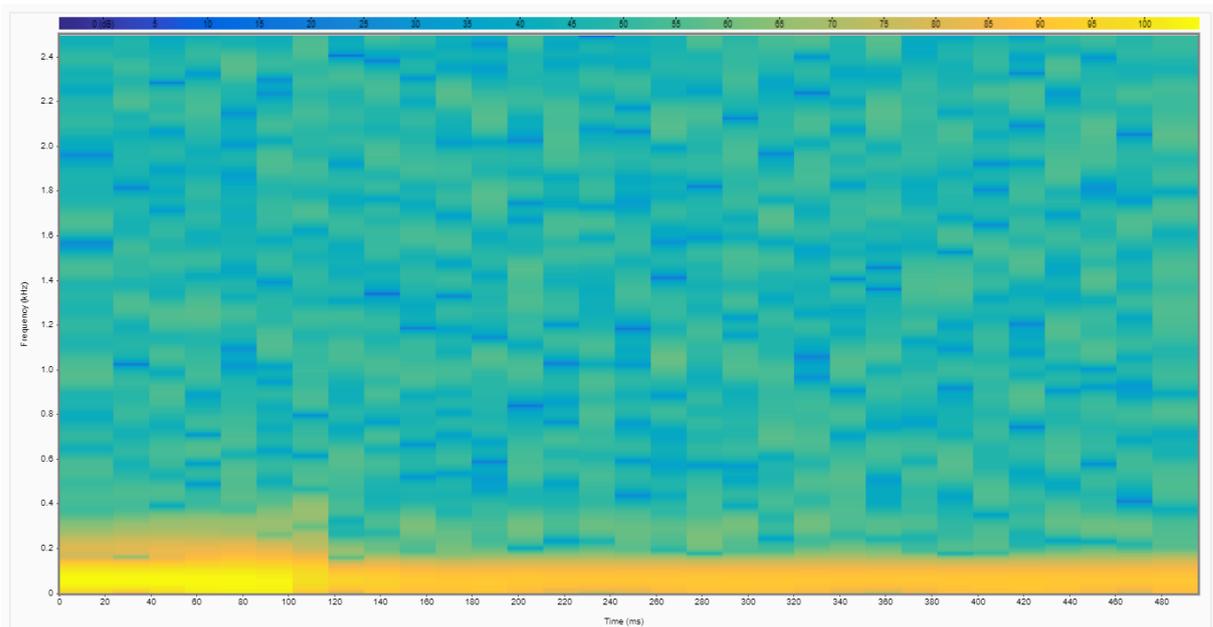
Fonte: do autor.

Figura 37 – Espectrograma da corrente do MIT



Fonte: do autor.

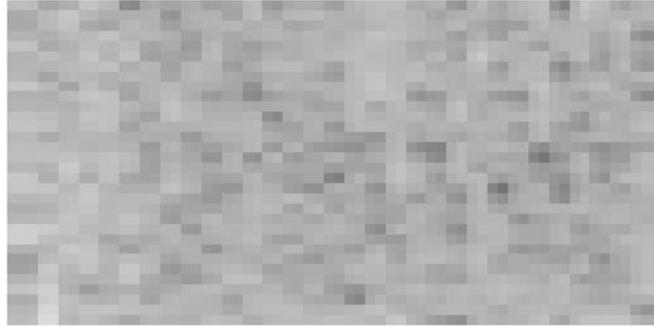
Figura 38 – Espectrograma da corrente do motor de indução monofásico



Fonte: do autor.

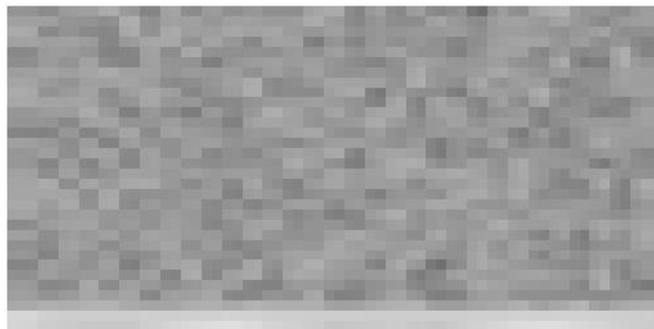
As imagens do espectro de frequência no tempo de cada equipamento, depois de convertidas para a escala de cinza e redimensionadas para 5% do tamanho original, podem ser vistas da Figura 39 a Figura 42.

Figura 39 – Espectrograma do reator eletrônico em escala de cinza e redimensionado para 5%



Fonte: do autor.

Figura 40 – Espectrograma das lâmpadas incandescentes em escala de cinza e redimensionado para 5%



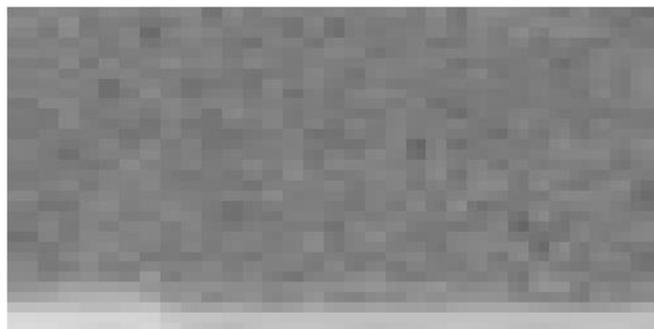
Fonte: do autor.

Figura 41 – Espectrograma do MIT em escala de cinza e redimensionado para 5%



Fonte: do autor.

Figura 42 – Espectrograma do motor de indução monofásico em escala de cinza e redimensionado para 5%



Fonte: do autor.

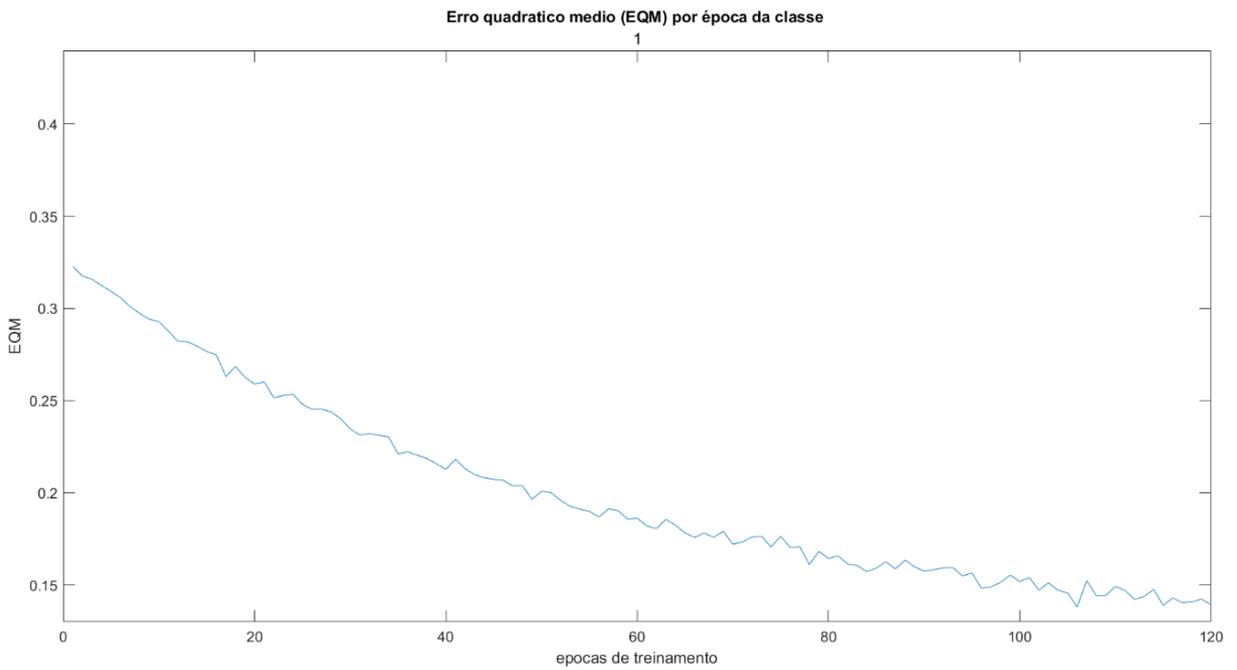
Por fim, estes dados são vetorizados, rotulados com suas respectivas classes e

normalizados para serem usados no treinamento, conforme foi descrito no Capítulo 4.

## 5.2 TREINAMENTO

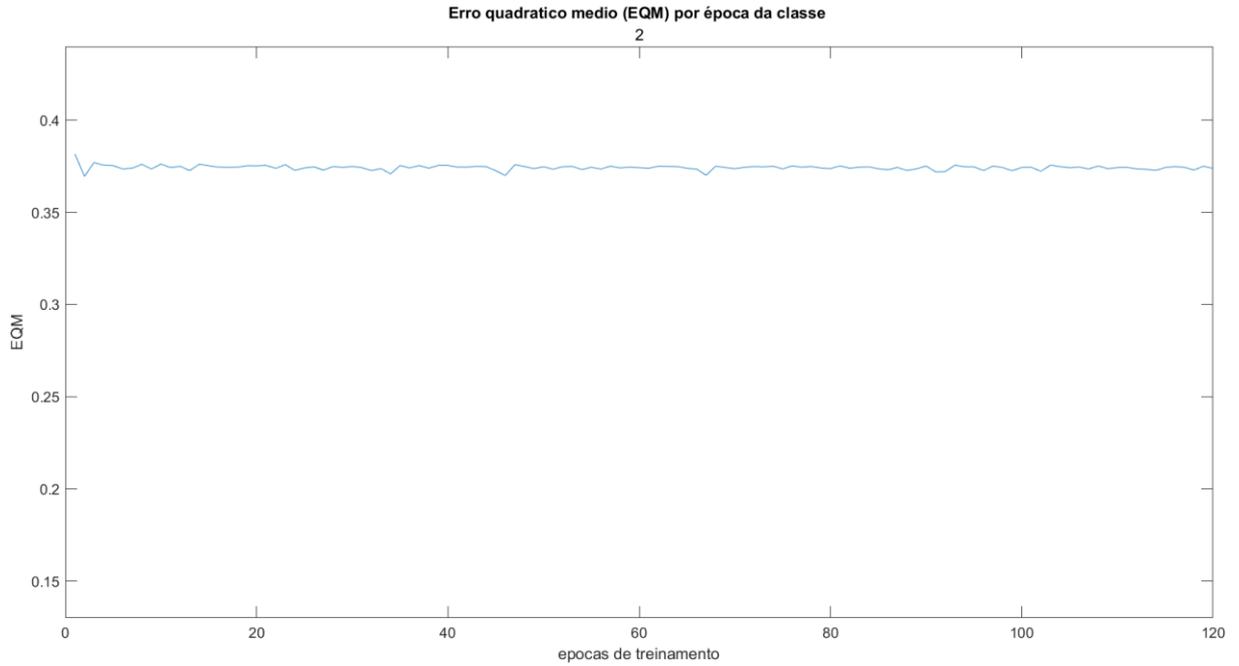
Nas Figuras 43 a 46 são apresentadas as curvas de evolução dos EQM ao longo das épocas, também chamadas de curvas de aprendizados, para cada rede, para os dados de treinamento. Limitou-se a realização de 120 épocas, uma vez que se observou que a utilização de mais épocas não contribuiu para melhorias significativas nos processos de aprendizado.

Figura 43 – EQM do treinamento para reator eletrônico



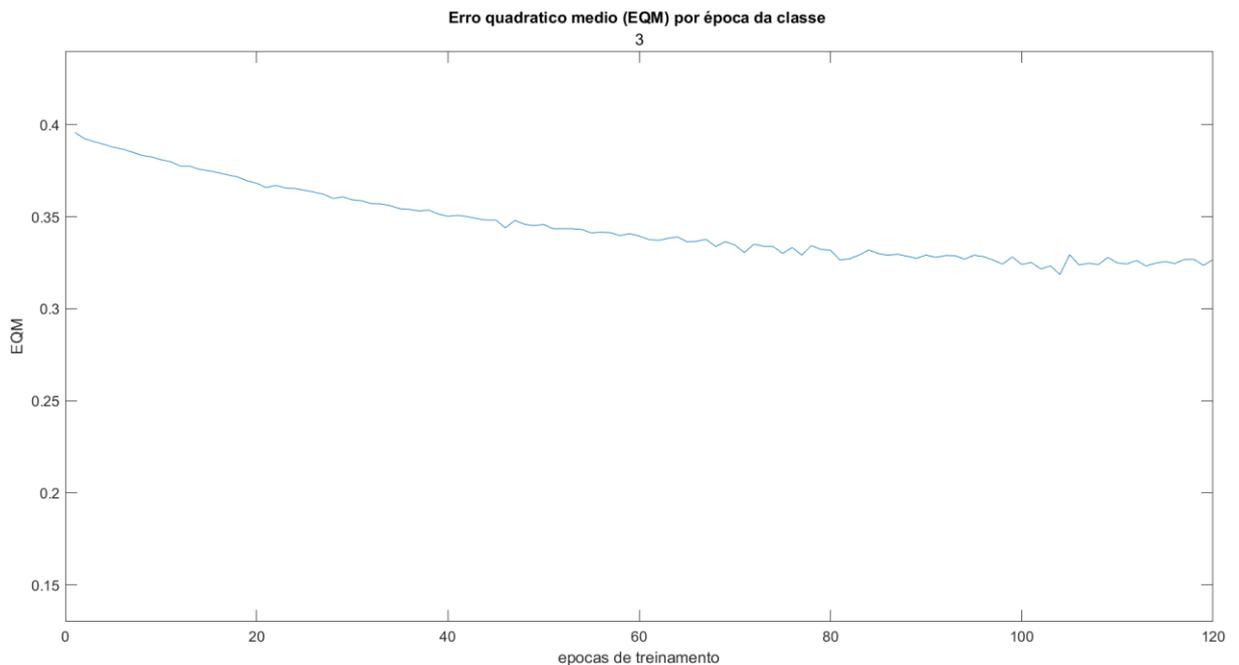
Observando a curva de aprendizado, percebe-se que esta apresentou rápida convergência e alcançou estabilidade. O EQM ao fim de 120 épocas é de aproximadamente 0,10.

Figura 44 – EQM do treinamento para lâmpadas incandescentes



Na etapa de treinamento da rede para identificação de lâmpadas incandescentes, observa-se que não houve uma convergência clara, mas que é estável. No entanto, o EQM é elevado, indicando a princípio que a rede não conseguiu identificar atributos relevantes nas amostras apresentadas que a ajudassem a identificar essa carga. Terminando com EQM de aproximadamente 0,38.

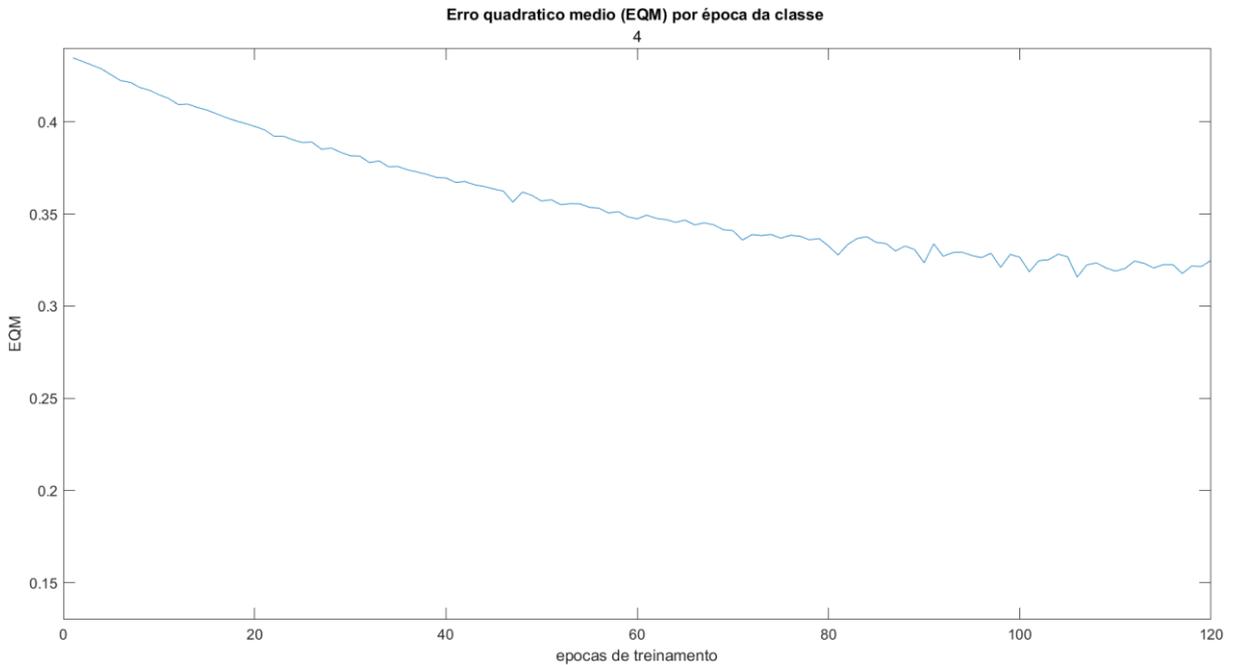
Figura 45 – EQM do treinamento para MIT



Assim como para o reator eletrônico com duas lâmpadas fluorescentes, a rede neural treinada ao identificar a assinatura elétrica do MIT, apresenta rápida convergência e

estabilidade. Terminando com EQM de aproximadamente 0,33 ao final do treinamento, como pode ser visto na Figura 45.

Figura 46 – EQM do treinamento para motor de indução monofásico



Fonte: do autor.

A convergência na etapa de treinamento da rede para identificação de motor monofásico de indução foi rápida e apresentou boa estabilidade, principalmente nas épocas iniciais. Não sendo tão estável, no entanto, nas épocas finais de treinamento. O EQM dessa rede nas épocas finais é de aproximadamente 0,33.

Terminado o processo de treinamento, encerra-se a etapa de atualização de pesos. Então, na sequência, vem a etapa de teste, da qual utiliza dados ainda desconhecidos pela rede, com a proposta de avaliar a capacidade de generalização da RNA.

Somente as curvas de aprendizado não garantem que as redes conseguiram capturar os modelos das assinaturas elétricas de cada carga. As curvas de aprendizado devem ser vistas como um indicador inicial de que os modelos construídos capturaram bem a dinâmica das assinaturas das cargas avaliadas. Deve-se observar, também a taxa de acerto alcançada para dados que não foram utilizados no treinamento, no caso, os dados de testes.

Também, faz-se necessário avaliar o aprendizado com outras métricas, como a taxa de acerto média e o desvio padrão desta. A taxa de acerto média das redes neurais foi de 56,3750% e o desvio padrão foi de 11,8065% para os dados de teste.

Por tais valores, pode-se ver que, embora a convergência esteja boa para três das classes, os modelos não atingiram um bom desempenho quando foram solicitadas a identificar as cargas com os dados de teste. Uma outra forma de avaliar quantitativamente o desempenho

do classificador é construir a matriz de confusão, como é descrito na seção seguinte.

### 5.3 MATRIZ DE CONFUSÃO

Para visualizar o desempenho das redes neurais quando utilizados os dados de teste, foi construído uma matriz de confusão de múltiplas classes, que contabiliza simultaneamente o somatório das classificações de todas as redes, como descrito anteriormente. Vale pontuar que não foram utilizados dados desconhecidos para testar os modelos.

Tabela 2 – Matriz de confusão

	Real	Reator ele.	Incandescente	MIT	Monofásico	Desconhecida
Predito	Reator ele.	21	3			
	Incandescente		11			
	MIT		2	20	17	
	Monofásico					
	Desconhecida		1			5

Fonte: do autor.

É possível observar que a rede treinada para identificar o reator eletrônico com lâmpadas fluorescentes identificou corretamente todas as 21 amostras dessa classe, presente no conjunto de testes, o que mostra que realmente o processo de aprendizado foi satisfatório. Esse resultado já era esperado, uma vez que é possível notar que essa classe de carga é a única que apresenta componentes de alta frequência no espectrograma, o que torna relativamente simples a tarefa de diferenciação dessa carga das outras.

A rede neural treinada para identificar lâmpadas incandescentes mostra um resultado esperado, uma vez que a curva de aprendizado dessa rede apresentou a pior convergência entre as cargas avaliadas. Das 17 amostras dessa carga no conjunto de teste, 4 foram classificadas como lâmpadas fluorescentes e 2 como motor de indução, enquanto as outras 11 amostras foram classificadas corretamente.

Na identificação de motores de indução trifásico mostrou boa convergência no treinamento e das 20 amostras dessa classe no conjunto de treinamento, todas as 20 foram identificadas corretamente pela rede neural, mostrando que a rede extraiu informações suficientes dos espectrogramas para distinguir essa carga das demais avaliadas. Já a rede neural treinada para identificar motor de indução monofásico, apresentaram os resultados mais divergentes, uma vez que se esperava um bom desempenho devido a estabilidade e convergência da curva de aprendizagem. Das 22 amostras de teste dessa classe, todas foram classificadas incorretamente como sendo motor trifásico de indução, mas esse resultado é de certa forma esperado, uma vez que o motor monofásico também é um motor de indução, e só

foram adquiridas leituras de apenas uma fase do motor trifásico, o que torna os dados de treinamento e teste dessas duas classes muito parecidos.

## 6. CONCLUSÃO

### 6.1 RESUMO DAS CONTRIBUIÇÕES DESTE TRABALHO

Ferramentas que possam fornecer aos consumidores residenciais uma conta de energia estratificada podem ajudar o consumidor a reduzir o seu consumo de energia, sem a necessidade de se reduzir o conforto, através da criação de hábitos de consumo de energia mais eficientes, uma vez que os clientes podem ver diretamente o impacto que cada equipamento tem em sua fatura.

Para isso, a criação de uma ferramenta de monitoramento não intrusivo, que permite realizar a estratificação da conta de energia com apenas um instrumento de medição, o que reduz significativamente o custo, tem o maior potencial de penetração no mercado. Além disso, ferramentas não intrusivas tendem a ser bem mais aceitas pelos consumidores por não ter impacto direto na instalação interna de residências.

As técnicas de monitoramento não intrusivo são várias, e podem utilizar diferentes parâmetros das cargas que se deseja identificar, como foi mostrado nas pesquisas apresentadas anteriormente.

Assim, o trabalho apresenta uma das abordagens, na qual pode-se ser utilizada no desenvolvimento de sistemas de monitoramento de cargas e estratificação da conta de energia. A utilização de imagens de espectro de frequência no tempo, se mostra uma poderosa ferramenta na identificação de fenômenos elétricos. Vale ressaltar que se trata de uma rede rasa, com apenas uma camada oculta, e o ajuste nos parâmetros de obtenção dos espectrogramas ou aumento na frequência de aquisição do sinal de corrente podem fornecer dados mais significativos para o treinamento das redes neurais.

Os resultados da classificação se mostraram satisfatórios, para a configuração de rede utilizada, identificando corretamente três das classes e se pode melhorar os resultados para o motor monofásico utilizando-se outro atributo ou ainda obtendo-se o sinal de corrente das três fases do motor de indução trifásico. Para a implementação em um sistema de reconhecimento de cargas, espera-se que a precisão seja superior, assim, porém necessita ser aprimorado. Outras pesquisas com outros métodos de reconhecimento de cargas como a de Xiao *et al.* (2019) alcançou precisão de até 90% e a de Wu *et al.* (2018) conseguiu precisão de 96%. Logo, ajustes em algumas etapas são necessárias para melhorar o desempenho, como a utilização de uma rede neural com mais camadas ocultas por exemplo, mas isso implica também no aumento do custo computacional.

## 6.2 CONSIDERAÇÕES GERAIS O MÉTODO PROPOSTO

A utilização de imagens de espectro de frequência no tempo tem grande potencial em identificar eventos em um circuito elétrico. Juntamente com o método de monitoramento não intrusivo, é possível implementar a estratificação das faturas de energia a custo reduzido e com bom desempenho.

## 6.3 CONSIDERAÇÕES FINAIS

O trabalho buscou contribuir com os estudos na área de identificação de cargas sobrepostas, através de redes neurais artificiais utilizando os atributos de regimes transitórios e estacionários extraídos do sinal de corrente elétrica das cargas, contribuindo com esta linha de pesquisa na qual é de grande importância no desenvolvimento de aplicações que podem estar presentes nas *smart grids*, e podem ajudar os usuários residenciais a adotarem hábitos de consumo mais eficiente.

## 6.4 SUGESTÕES DE TRABALHOS FUTUROS

Uma alternativa a Transformada de Gabor, que poderia extrair melhor os atributos do espectro transitório dos sinais de corrente, seria a Transformada Wavelet. Embora a Transformada de Gabor represente um avanço na representação do espectro de sinais, ela tem a limitação de manter constantes a resolução no domínio do tempo e da frequência extraída, durante toda a janela de aquisição do sinal. Assim, a janela deslizante, se não possuir a largura ideal, pode não ser capaz de detectar frequências de curta duração e alta frequência por exemplo, que são característicos do estado transitório. Com a Transformada Wavelet é possível analisar sinais em diferentes escalas, não infringindo o princípio da Incerteza de Gabor-Heisenberg (DE OLIVEIRA, H. M., 2007).

Outra possibilidade é o uso de outras redes neurais artificiais, treinadas por outros algoritmos de aprendizagem. Além disso, utilizar apenas uma rede neural profunda para identificar simultaneamente as cargas avaliadas.

No trabalho foi utilizado uma janela gaussiana para construir os espectrogramas dos sinais de corrente das cargas, mas podem ser utilizadas outras janelas deslizantes para essa tarefa. Além de ser possível utilizar outros métodos de extração de características e outros sinais de atributos das cargas, como tensão, potência ativa, reativa e aparente, taxa de distorção harmônica, entre outros, ou ainda a combinação de mais de um destes. O que pode resolver o problema do classificador distinguir entre um MIT e um motor de indução monofásico.

## REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). **Matriz energética cresce 383,66 MW em março e 682,61 MW no primeiro trimestre de 2021**. Brasília, 2021.

Disponível em: [https://www.aneel.gov.br/sala-de-imprensa-exibicao-2/-/asset\\_publisher/zXQREz8EVIZ6/content/id/21866628](https://www.aneel.gov.br/sala-de-imprensa-exibicao-2/-/asset_publisher/zXQREz8EVIZ6/content/id/21866628). Acesso em: 25 de jul. 2021.

\_\_\_\_\_. **Perdas de Energia Elétrica na Distribuição**. Brasília, 2019. 21 p. Disponível em: <https://www.aneel.gov.br/documents/654800/18766993/Relat%C3%B3rio+Perdas+de+Energia+Edi%C3%A7%C3%A3o+1-2019.pdf/b43e024e-5017-1921-0e66-024fa1bed575>. Acesso em: 10 mar. 2020.

AVANCINI, D. B.; RODRIGUES, J. J. P. C.; MARTINS, S. G. B.; RABÊLO, R. A. L.; AL-MUHTADI, J.; SOLIC, P. Energy meters evolution in smart grids: A review. **Journal of Cleaner Production**, v. 217, p. 702-715, 2019. ISSN 0959-6526. DOI:

10.1016/j.jclepro.2019.01.229. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0959652619302501>. Acesso em: 10 mar. 2020.

BANCO NACIONAL DE DESENVOLVIMENTO ECONÔMICO E SOCIAL (BNDES). **Redes elétricas inteligentes (smart grid): oportunidade para adensamento produtivo e tecnológico local**. Brasília, 2013. 42 p. Disponível em:

[https://web.bndes.gov.br/bib/jspui/bitstream/1408/2927/1/RB%2040%20Redes%20el%C3%A9tricas%20inteligentes\\_P.pdf](https://web.bndes.gov.br/bib/jspui/bitstream/1408/2927/1/RB%2040%20Redes%20el%C3%A9tricas%20inteligentes_P.pdf). Acesso em: 15 mar. 2020.

BATTAGLIN, P. D.; BARRETO, G. Revisitando a História da Engenharia Elétrica. **Revista de Ensino de Engenharia**, v. 30, n. 2, p. 49-58, 2011. ISSN 0101-5001. DOI:

10.15552/2236-0158/abenge.v30n2p49-58. Disponível em: <http://revista.educacao.ws/revista/index.php/abenge/article/view/103>. Acesso em: 10 mai. 2020.

BEZERRA, S. G. T. A. **Reservoir Computing com Hierarquia para Previsão de Vazões Médias Diárias**. 76 p. (Dissertação de Mestrado, Engenharia da Computação) - Universidade de Pernambuco, Recife, 2016. Disponível em:

[https://www.researchgate.net/publication/307578398\\_Reservoir\\_Computing\\_com\\_Hierarquia\\_para\\_Previsao\\_de\\_Vazoes\\_Medias\\_Diarias](https://www.researchgate.net/publication/307578398_Reservoir_Computing_com_Hierarquia_para_Previsao_de_Vazoes_Medias_Diarias). Acesso em: 21 jan. 2021.

BIANSOONGNERN, S.; PLANGKLANG, B. Nonintrusive load monitoring (NILM) using an Artificial Neural Network in embedded system with low sampling rate. **2016 13th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)**. IEEE, 2016. p. 1-4. ISBN 978-1-4673-9749-0. DOI: 10.1109/ECTICon.2016.7561398. Disponível em:

<https://ieeexplore.ieee.org/document/7561398>. Acesso em: 15 mar. 2020.

CAVALCANTE, N. W.F; FRANCO, C.; ALMEIDA, V.; FREITAS, F. D.; TAVARES, E. Smart Grid na América Latina: Caso Ampla de Inovação no Setor Elétrico. **Revista de Administração Contemporânea**. 2019, v. 23, n. 3, p. 416-435. ISSN: 1982-7849. DOI:

10.1590/1982-7849rac2019170128. Disponível em: <https://www.scielo.br/j/rac/a/kn9Ph7CnfNVWBtg4SsBdCZf/?lang=pt>. Acessado em: 20 set. 2020.

DAKI, H.; EL HANNANI, A.; AQQAL, A.; HAIDINE, A.; DAHBI, A. Big Data management in smart grid: concepts, requirements and implementation. **Journal of Big Data**, SpringerOpen, v. 4, n. 1, p. 13, 2017. ISSN 2196-1115. DOI: 10.1186/s40537-017-0070-y. Disponível em: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-017-0070-y>. Acesso em: 10 mar. 2020.

DANTAS, G. A.; CASTRO, N. J.; DIAS, L.; ANTUNES, C. H.; VARDIERO, P.; BRANDÃO, R.; ROSENAL, R.; ZAMBONI, L. Public policies for smart grids in Brazil. **Renewable and Sustainable Energy Reviews**. Elsevier Ltd, v. 92, p. 501-512, 2018. ISSN 1364-0321. DOI: 10.1016/j.rser.2018.04.077. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1364032118303071>. Acesso em: 20 set. 2020.

DE CASTRO, N.; CASTRO, G.; FERREIRA, D.; FERREIRA, D.; TOMMASSO, F.; MORAIS, R. **Impactos Sistêmicos da Micro e Minigeração Distribuída**. Rio de Janeiro: 2018. n. 79. 64 p. ISBN 978-85-93305-46-7. Disponível em: [http://www.gesel.ie.ufrj.br/app/webroot/files/publications/46\\_tdse79.pdf](http://www.gesel.ie.ufrj.br/app/webroot/files/publications/46_tdse79.pdf). Acesso em: 10 mar. 2020.

DE CASTRO, N.; GOUVÊA, A. R.; MOSZKOWICZ, M. **Desafios das distribuidoras de energia elétrica frente à difusão dos recursos energéticos distribuídos**. Agência CanalEnergia. Rio de Janeiro, 2019. Disponível em: [http://www.gesel.ie.ufrj.br/app/webroot/files/publications/34\\_castro206.pdf](http://www.gesel.ie.ufrj.br/app/webroot/files/publications/34_castro206.pdf). Acesso em: 10 mar. 2020.

DEEP LEARNING BOOK. **Capítulo 2 – Uma Breve História das Redes Neurais Artificiais**. Disponível em: <https://www.deeplearningbook.com.br/uma-breve-historia-das-redes-neurais-artificiais/>. Acesso em: 06 mar. 2020.

\_\_\_\_\_. **Capítulo 9 – A Arquitetura das Redes Neurais**. Disponível em: <https://www.deeplearningbook.com.br/a-arquitetura-das-redes-neurais/>. Acesso em: 05 mar. 2020.

DING, J. **Time Frequency Analysis Tutorial: Gabor Feature and its Application**. Disponível em: <https://core.ac.uk/display/103377581>. Acesso em: 05 mar. 2020.

DRANKA, G. G.; FERREIRA, P. Towards a smart grid power system in Brazil: Challenges and opportunities. **Energy Policy**, Elsevier Ltd, v. 136, p. 16, 2020. ISSN 0301-4215. DOI: 10.1016/j.enpol.2019.111033. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0301421519306202?via%3Dihub>. Acesso em: 23 set. 2020.

EMPRESA DE PESQUISA ENERGÉTICA (EPE). **Anuário Estatístico de Energia Elétrica 2020 ano base 2019**. Rio de Janeiro, 2020. 256 p. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-160/topico-168/Anu%C3%A1rio%20Estat%C3%ADstico%20de%20Energia%20El%C3%A9trica%202020.pdf>. Acesso em: 09 out. 2020.

\_\_\_\_\_. **Cenários de Demanda para o PNE 2050 Relatório Parcial 2**. Rio de Janeiro, 2018.

34 p. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-227/topico-202/Cen%C3%A1rios%20de%20Demanda.pdf>. Acesso em: 10 mar. 2020.

\_\_\_\_\_. **Sistemas de Armazenamento em Baterias: Aplicações e Questões Relevantes para o Planejamento**. Rio de Janeiro, 2019. 36 p. Disponível em: [https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-441/EPE-DEE-NT-098\\_2019\\_Baterias%20no%20planejamento.pdf](https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-441/EPE-DEE-NT-098_2019_Baterias%20no%20planejamento.pdf). Acesso em: 07 out. 2020.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 1 ed. O'Reilly, 2017.

GHASEMPOUR, A. Internet of Things in Smart Grid: Architecture, Applications, Services, Key Technologies, and Challenges. **Inventions**, MDPI, v. 4, n. 1, p. 22, 2019. ISSN 2411-5134. DOI: 10.3390/inventions4010022. Disponível em: <https://www.mdpi.com/2411-5134/4/1/22>. Acesso em: 10 mar. 2020.

GLOROT, X; BORDES, A; BENGIO, Y. Deep Sparse Rectifier Neural Networks. **Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics**, PMLR. v. 15, p. 315-323, 2011. Disponível em: <http://proceedings.mlr.press/v15/glorot11a.html>. Acesso em: 20 mar. 2020

HAYKIN, S. **Redes neurais: princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001.

INTERNATIONAL ELECTROTECHNICAL COMMISSION (IEC). **IEC Smart Grid Standardization Roadmap**. 1.0. ed. Genebra, 2010. 136 p. Disponível em: <http://www.itrco.jp/libraries/IEC-SmartgridStandardizationRoadmap.pdf>. Acesso em: 10 mar. 2020.

\_\_\_\_\_. **Smart Grid: Background**. Disponível em: <https://www.iec.ch/smartgrid/background/>. Acesso em: 10 mar. 2020.

\_\_\_\_\_. **Smart Grid: Challenges**. Disponível em: <https://www.iec.ch/smartgrid/challenges/>. Acesso em: 20 set. 2020.

JOÃO, B. D. N.; DE SOUZA, C. L.; SERRALVO, F. A. A systematic review of smart cities and the internet of things as a research topic. **Cadernos EBAPE.BR**, Rio de Janeiro, v. 17, n. 4, p. 1115-1130, 2019. ISSN 1679-3951. DOI: 10.1590/1679-395174442x. Disponível em: <https://www.scielo.br/j/cebape/a/mBqjGxPSbRKPpXcS99z8LrD/?lang=en>. Acesso em: 20 mar. 2020.

KABALCI, Y. A survey on smart metering and smart grid communication. **Renewable and Sustainable Energy Reviews**, Elsevier Ltd, v. 57, p. 302-318, 2016. ISSN 1364-0321. DOI: 10.1016/j.rser.2015.12.114. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1364032115014975?via%3Dihub>. Acesso em: 20 mar. 2020.

KIRWAN, C.; ZHIYONG, F. **Smart Cities and Artificial Intelligence**. Elsevier Ltd, 2020. 284 p. ISBN 978-0-12-817024-3. DOI: 10.1016/C2018-0-01594-7. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/C20180015947>. Acesso em: 10 mai. 2020.

KOVÁCS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações**. 4 ed. São Paulo: Livraria da Física, 2006. 174 p. ISBN 85-88325-14-4.

KUMAR, P.; FOUFOULA-GEORGIU, E. **Wavelets in Geophysics**. 1 ed. v. 4. Academic Press, 1994. p. 1-43. ISBN 0-12-262850-0.

MINISTÉRIO DE MINAS E ENERGIA (MME). **Relatório do Grupo Temático Abertura de Mercado**. Brasília, 2019. 42 p. Disponível em: <https://www.gov.br/mme/pt-br/assuntos/secretarias/secretaria-executiva/modernizacao-do-setor-eletrico/arquivos/pasta-geral-publicada/abertura-de-mercado.pdf>. Acesso em: 10 mar. 2020.

\_\_\_\_\_. **Relatório Smart Grid**. Brasília, 2010. 232 p. Disponível em: <http://antigo.mme.gov.br/documents/36148/342584/RELAT%C3%93RIO+SMART+GRID/cf509d1b-b503-5eda-5392-97738fe6f45a>. Acesso em: 10 mar. 2020.

MÜLLER, M.; ZALKOW, F. **Fundamentals of Music Processing: Audio, Analysis, Algorithms, Applications**. 483 p. Springer, 2015. ISBN: 978-3-319-21944-8. Disponível em: [https://www.audiolabs-erlangen.de/resources/MIR/FMP/C2/C2\\_STFT-Window.html](https://www.audiolabs-erlangen.de/resources/MIR/FMP/C2/C2_STFT-Window.html). Acesso em: 23 jan. 2021.

NETO, A. B.; BONINI, C. S. B. REDES NEURAIAS ARTIFICIAIS: APRESENTAÇÃO E UTILIZAÇÃO DO ALGORITMO PERCEPTRON EM BIOSISTEMAS. **BIOENG**, v. 4, n. 2, p. 87-95. 2010. DOI: 10.18011/bioeng2010v4n2p87-95. Disponível em: <https://seer.tupa.unesp.br/index.php/BIOENG/article/view/95/95>. Acesso em: 21 jan. 2021.

ORNELAS, G. C.; SILVA, M. V.; MILANEZI, J.; COSTA, J. P. C.; MARANHÃO, J. P. A.; DEUS, F. E.; GALDO, G. D. First step towards a smart grid communication architecture for the brazilian federal district. **IFAC-PapersOnLine**, v. 49, n. 30, p. 251-256, 2016. ISSN 2405-8963. DOI: 10.1016/j.ifacol.2016.11.120. Disponível em: <http://www.sciencedirect.com/science/article/pii/S2405896316325587>. Acesso em: 10 mar. 2020.

ROSS, R.; BANDIM, C. J.; SOLANO, O.; OLIVEIRA, M.; DUBOC, W. **Projeto Consgrid: Resumo e Principais Realizações**. Rio de Janeiro, 2017. 42 p. Disponível em: [http://antigo.mme.gov.br/documents/36144/472967/Relatorio\\_Tecnico\\_Consgrid.pdf/72fe7cff-0b2a-119f-a62d-0b54cc5447e4](http://antigo.mme.gov.br/documents/36144/472967/Relatorio_Tecnico_Consgrid.pdf/72fe7cff-0b2a-119f-a62d-0b54cc5447e4). Acesso em: 10 mar. 2020.

SALEEM, Y.; CRESPI, N.; REHMANI, M. H.; COPELAND, R. Internet of Things-Aided Smart Grid: Technologies, Architectures, Applications, Prototypes, and Future Research Directions. **IEEE Access**, v. 7, p. 62962-63003, abr 2019. ISSN 2169-3536. DOI: 10.1109/ACCESS.2019.2913984. Disponível em: <https://ieeexplore.ieee.org/document/8701687/>. Acesso em: 10 mar. 2020.

SHI, X.; MING, H.; SHAKKOTTAI, S.; XIE, L.; YAO, J. Nonintrusive load monitoring in residential households with low-resolution data. **Applied Energy**, Elsevier Ltd, v. 256, p.

113283, out 2019. ISSN 0306-2619. DOI: 10.1016/j.apenergy.2019.05.086. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0306261919309407>. Acesso em: 10 mar. 2020.

SILVERTHORN, D. S. Neurônios: propriedades celulares e de rede. *In: SILVERTHORN, D. S. FISILOGIA HUMANA Uma Abordagem Integrada*. 7 ed. artmed. 2017. p. 226-273. ISBN 9780321981226.

SIROJAN, T.; PHUNG, T.; AMBIKAI RAJAH, E. Intelligent edge analytics for load identification in smart meters. **2017 IEEE Innovative Smart Grid Technologies - Asia (ISGT-Asia)**. IEEE, 2017. p. 1-5. ISBN 978-1-5386-4950-3. DOI: 10.1109/ISGT-Asia.2017.8378414. Disponível em: <https://ieeexplore.ieee.org/document/8378414/>. Acesso em: 10 mar. 2020.

SOUSA, T. C.; VELOSO, A. F. S.; OLIVEIRA, R. G.; RODRIGUES, A. A.; OLIVEIRA, D. L.; GALLAS, A. J. G.; SOBRAL, J. V. V. Identificação de assinaturas de cargas de eletrodomésticos residenciais em Smart Meters usando Inteligência Artificial e IoT: Implementação e testbed. **Revista de Informática Aplicada**, v. 14, n. 1, p. 70-81, set. 2018. ISSN 2179-2518. DOI: 10.13037/ria.vol14n1.221. Disponível em: [https://seer.uscs.edu.br/index.php/revista\\_informatica\\_aplicada/article/view/6964](https://seer.uscs.edu.br/index.php/revista_informatica_aplicada/article/view/6964). Acesso em: 10 mar. 2020.

STOJKOSKA, B. L. R.; TRIVODALIEV, K. V. A review of internet of things for smart home: Challenges and solutions. **Journal of Cleaner Production**, Elsevier Ltd, v. 140, p. 1454-1464, jan 2017. ISSN 09596526. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S095965261631589X>. Acesso em: 15 mar 2020.

SUN, Q.; LI, H.; MA, Z.; WANG, C.; CAMPILLO, J.; ZHANG, Q.; WALLIN, F.; GUO, J. A Comprehensive Review of Smart Energy Meters in Intelligent Energy Networks. **IEEE Internet of Things Journal**. vol. 3, nº. 4, p. 464-479, ago. 2016. DOI: 10.1109/JIOT.2015.2512325. Disponível em: <https://ieeexplore.ieee.org/document/7365417>. Acesso em: 10 mar. 2020.

TEIXEIRA, J. F. **O QUE É INTELIGÊNCIA ARTIFICIAL**, 3. ed. e-galáxia, 2019. ISBN 9788584742615.

WANG, S.; LI, R.; EVANS, A.; LI, F. Regional nonintrusive load monitoring for low voltage substations and distributed energy resources. **Applied Energy**, Elsevier Ltd, v. 260, p. 114225, fev 2020. ISSN 0306-2619. DOI: 10.1016/j.apenergy.2019.114225. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0306261919319129>. Acesso em: 10 mai. 2020.

WELIKALA, S.; DINESH, C.; EKANAYAKE, M. P. B.; GODALIYADDA, R. I.; EKANAYAKE, J. A real-time non-intrusive load monitoring system. **2016 11th International Conference on Industrial and Information Systems (ICIIS)**. IEEE, 2016. p. 850-855. ISBN 978-1-5090-3818-3. DOI: 10.1109/ICIINFS.2016.8263057. Disponível em: <https://www.researchgate.net/publication/322649281>. Acesso em: 10 mar. 2020.

WILLIAMS, S.; SHORT, M. Electricity demand forecasting for decentralised energy mangement. **Energy and Built Environment**, Elsevier Ltd, v. 1, n. 2, p. 178-186, abr 2020. ISSN 2666-1233. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2666123320300076>. Acesso em: 10 mar. 2020.

WORLD ENERGY COUNCIL (WEC). **Innovation Insights Brief 2019 ENERGY INFRASTRUCTURE Affordability Enabler or Decarbonisation Constraint?**. Londres, 2019. 33 p. Disponível em: <https://www.worldenergy.org/assets/downloads/Innovation-Insights-Brief-Energy-Infrastructure-Affordability-Enabler-or-Decarbonisation-Constraint.pdf>. Acesso em: 10 mar. 2020.

WU, X.; HAN, X.; LIU, L.; QI, B. A Load Identification Algorithm of Frequency Domain Filtering Under Current Underdetermined Separation. **IEEE Access**, Institute of Electrical and Electronics Engineers Inc., v. 6. p. 37094-37107, jun. 2018. ISSN 2169-3536. DOI: 10.1109/ACCESS.2018.2851018. Disponível em: <https://ieeexplore.ieee.org/document/8398198/>. Acesso em: 10 mar. 2020.

XIAO, Y.; HU, Y.; HE, H.; ZHOU, D.; ZHAO, Y.; HU, W. Non-Intrusive Load Identification Method Based on Improved KM Algorithm. **IEEE Access**, Institute of Electrical and Electronics Engineers Inc., v. 7, p. 151368-151377, 2019. ISSN 2169-3536. DOI: 10.1109/ACCESS.2019.2948079. Disponível em: <https://ieeexplore.ieee.org/document/8873557/>. Acesso em: 10 mar. 2020.

## ANEXO I

O código das figuras a seguir mostram o processo de carregamento e tratamento dos dados, definição dos hiperparâmetros e criação das redes MLP para cada identificar as cargas estudadas.

Figura AI – Etapa de carregamento e tratamento dos dados

```

10 % Carrega DADOS
11 %=====
12 nflo=99; %Número de dados de cargas do tipo lâmpada florecene
13 ninc=99; %Número de dados de cargas do tipo lâmpada incandescente
14 ntri=99; %Número de dados de cargas do tipo motor trifásico
15 nmono=99; %Número de dados de cargas do tipo motor monofásico;
16
17 %Florescente Classe 1
18 for k = 1:nflo
19     D = imread(strcat('C:\Users\Wanderson\OneDrive\Documents\TCC\Data\Florescente\Flu1_',num2str(k),'.png'));
20     D1(:,:,k) = rgb2gray(imresize(D,0.05));
21     Dados(:,:,k) = mat2gray(D1(:,:,k));
22 end
23
24 %Incandescente Classe 2
25 for k = 1:ninc
26     D = imread(strcat('C:\Users\Wanderson\OneDrive\Documents\TCC\Data\Incandescente\Incl_',num2str(k),'.png'));
27     D1(:,:,k+nflo) = rgb2gray(imresize(D,0.05));
28     Dados(:,:,k+nflo) = mat2gray(D1(:,:,k+nflo));
29 end
30
31 %Motor de Indução Trifásico Classe 3
32 for k = 1:ntri
33     D = imread(strcat('C:\Users\Wanderson\OneDrive\Documents\TCC\Data\MIT\Tril_',num2str(k),'.png'));
34     D1(:,:,k+nflo+ninc) = rgb2gray(imresize(D,0.05));
35     Dados(:,:,k+nflo+ninc) = mat2gray(D1(:,:,k+nflo+ninc));
36 end
37
38 %Motor Monofásico Classe 4
39 for k = 1:nmono
40     D = imread(strcat('C:\Users\Wanderson\OneDrive\Documents\TCC\Data\M_Mono\Mono1_',num2str(k),'.png'));
41     D1(:,:,k+nflo+ninc+ntri) = rgb2gray(imresize(D,0.05));
42     Dados(:,:,k+nflo+ninc+ntri) = mat2gray(D1(:,:,k+nflo+ninc+ntri));
43 end

```

Figura AII – Vetorização e adição de rótulos

```

45 %VETORIZAÇÃO
46 dados=zeros(size(Dados,1)*size(Dados,2),size(Dados,4));
47 for k=1:size(Dados,3)
48     D1=[];
49     for i=1:size(Dados(:,k),1)
50         D1=[D1; Dados(i,:,k)'];
51     end
52     dados(:,k)=D1;
53 end
54
55 nc = 4; %número de classes
56 ndc = [99 99 99 99]; %número de dados por classe [n° classe 1 n° classe 2 ...]
57
58 Dn1=dados/(size(Dados,1)*size(Dados,2)); % Normalização dos dados
59
60 x=1;
61 for j=1:sum(ndc)
62     %Rótulos
63     if j>sum(ndc(1:x))
64         x=x+1;
65     end
66     Dn1(size(D1,1)+1,j)=x;
67 end

```

Figura AII – Seleção de hiperparâmetros

```

69 - [LinD ColD]=size(Dn1);
70
71 % Define tamanho dos conjuntos de treinamento/teste (hold out)
72 - ptrn=0.8; % Porcentagem usada para treino
73
74 % DEFINE ARQUITETURA DA REDE
75 %=====
76 - Ne = 120; % No. de epocas de treinamento
77 - Nr = 10; % No. de rodadas de treinamento/teste
78 - Nh = 30; % No. de neuronios na camada oculta
79 - No = 1; % No. de neuronios na camada de saida
80
81 - eta=0.039; % Passo inicial de aprendizagem
82 - mom=0.22; % Fator de momento

```

Figura AIV – Início do treinamento e criação das redes neurais

```

85 %% Início do Treino
86 - for r=1:Nr % LOOP DE RODADAS TREINO/TESTE
87 - Rodada=r
88
89 - I=randperm(ColD);
90 - Dn=Dn1(1:LinD-1,I); %
91 - alvos=Dn1(LinD,I); % Embaralha saidas desejadas tambem p/ manter correspondencia com vetor de entrada
92
93 %Treina uma rede para cada classe
94 - J=floor(ptrn*ColD);
95
96 % Vetores para treinamento e saidas desejadas correspondentes
97 - P = Dn(:,1:J); T1 = alvos(:,1:J);
98 - [lP cP]=size(P); % Tamanho da matriz de vetores de treinamento
99
100 % Vetores para teste e saidas desejadas correspondentes
101 - Q = Dn(:,J+1:end); T2 = alvos(:,J+1:end);
102 - [lQ cQ]=size(Q); % Tamanho da matriz de vetores de teste
103
104 % Inicia matrizes de pesos
105 - for i=1:nc
106 - WW(:,i)=1*(-0.2+(rand(Nh,lP+1))); % Pesos entrada -> camada oculta
107 - WW_old(:,i)=WW(:,i); % Necessario para termo de momento
108
109 - MM(:,i)=1*(-0.2+(rand(No,Nh+1))); % Pesos camada oculta -> camada de saida
110 - MM_old(:,i) = MM(:,i); % Necessario para termo de momento
111 - end

```

Figura AV – Treinamento das redes neurais

```

112 - for nuc=1:nc %Número da classe - Uma rede para cada classe
113 -     Classe=nuc,
114 -
115 -     %%% ETAPA DE TREINAMENTO
116 -     for t=1:Ne % Inicia LOOP de épocas de treinamento
117 -         Epoca=t;
118 -
119 -         I=randperm(cP); P=P(:,I); Tl=Tl(:,I); % Embaralha vetores de treinamento
120 -
121 -         EQ=0; % Erro quadrático
122 -         HID1=[];
123 -         for tt=1:cP % Inicia LOOP de iteracoes em uma epoca de treinamento
124 -             % CAMADA OCULTA
125 -             X = [-1; P(:,tt)]; % Constroi vetor de entrada com adicao da entrada x0=-1
126 -             Ui = WW(:, :,nuc) * X; % Ativacao (net) dos neuronios da camada oculta - SATURANDO AQUI
127 -             Zi = (1-exp(-Ui))./(1+exp(-Ui)); % Saída entre [-1 e +1] (função tangente hiperbólica)
128 -             HID1=[HID1 Zi];
129 -
130 -             % CAMADA DE SAIDA
131 -             Z = [-1; Zi]; % Constroi vetor de entrada DESTA CAMADA com adicao da entrada y0=-1
132 -             Uk = MM(:, :,nuc) * Z; % Ativacao (net) dos neuronios da camada de saida
133 -             Yk = (1-exp(-Uk))./(1+exp(-Uk)); % Saída entre [-1 e +1] (função tangente hiperbólica)
134 -
135 -             % CALCULO DO ERRO DE TREINAMENTO
136 -             if Tl(:,tt)==nuc;
137 -                 Rl=1;
138 -             else
139 -                 Rl=-1;
140 -             end
141 -             Ek = Rl - Yk; % erro entre a saida desejada e a saida da rede
142 -             EQ = EQ + 0.5*sum(Ek.^2); % soma do erro quadratico de todos os neuronios p/ VETOR DE ENTRADA
143 -
144 -             %%% CALCULO DOS GRADIENTES LOCAIS
145 -             Dk = 1-Yk.^2; % derivada da tangente hiperbólica
146 -             DDK = Ek.*Dk; % gradiente local (camada de saida)
147 -
148 -             Di = 1-Zi.^2; % derivada da tangente hiperbólica
149 -             DDi = Di.*(MM(:,2:end,nuc)'.*DDk); % gradiente local (camada oculta)
150 -
151 -             % AJUSTE DOS PESOS - CAMADA DE SAIDA
152 -             MM_aux(:, :,nuc)=MM(:, :,nuc);
153 -             MM(:, :,nuc) = MM(:, :,nuc) + eta*(exp(1/(1.4427*1))-1)*DDk*Z' + mom*(MM(:, :,nuc) - MM_old(:, :,nuc));
154 -             MM_old(:, :,nuc)=MM_aux(:, :,nuc);
155 -
156 -             % AJUSTE DOS PESOS - CAMADA OCULTA
157 -             WW_aux(:, :,nuc)=WW(:, :,nuc);
158 -             WW(:, :,nuc) = WW(:, :,nuc) + eta*(exp(1/(1.4427*1))-1)*DDi*X' + mom*(WW(:, :,nuc) - WW_old(:, :,nuc));
159 -             WW_old(:, :,nuc)=WW_aux(:, :,nuc);
160 -         end % Fim do loop de treinamento
161 -         %HID1, pause;
162 -
163 -         EQM(t,nuc)=EQ/cP; % MEDIA DO ERRO QUADRATICO POR EPOCA
164 -     end

```

Figura VI – Etapa de generalização

```

165 - %%% ETAPA DE GENERALIZACAO %%%
166 - EQ2=0; HID2=[];
167 - conf=zeros(cQ,nc);
168 - for tt=1:cQ
169 -     % CAMADA OCULTA
170 -     X=[-1; Q(:,tt)]; % Constroi vetor de entrada com adicao da entrada x0=-1
171 -     Ui = WW(:, :,nuc) * X; % Ativacao (net) dos neuronios da camada oculta
172 -     Zi = (1-exp(-Ui))./(1+exp(-Ui)); % Tangente hiperbólica;
173 -     % CAMADA DE SAIDA
174 -     Z=[-1; Zi]; % Constroi vetor de entrada DESTA CAMADA com adicao da entrada y0=-1
175 -     Uk = MM(:, :,nuc) * Z; % Ativacao (net) dos neuronios da camada de saida
176 -     Yk = (1-exp(-Uk))./(1+exp(-Uk)); %Saída entre [-1 e +1] (função tangente hiperbólica)
177 -     OUT2(nuc,tt)=Yk; % Armazena saida da rede
178 -
179 -     % CALCULO DO ERRO DE TESTE
180 -     if T2(:,tt)==nuc;
181 -         R2=1;
182 -     else
183 -         R2=-1;
184 -     end
185 -     Ek2 = R2 - Yk; % erro entre a saida desejada e a saida da rede
186 -
187 -     % ERRO QUADRATICO GLOBAL (todos os neuronios) POR VETOR DE ENTRADA
188 -     EQ2= EQ2 + 0.5*sum(Ek2.^2);
189 - end % Fim de uma época
190 - EQM2(nuc)=EQ2/cQ
191 - %Resultado - Dados de Treinamento
192 - figure; plot(EQM(:,nuc)); axis([0 Ne 0.13 0.44]); % Plota Curva de Aprendizagem
193 - xlabel('épocas de treinamento'); ylabel('EQM');
194 - title('Erro quadratico medio (EQM) por época da classe ',num2str(nuc))

```

Figura VII – Matriz de confusão e taxa de acerto média

```

197 % MEDIA DO ERRO QUADRATICO COM REDE TREINADA (USANDO DADOS DE TESTE)
198 EQM2=EQ2/cQ
199
200 % CALCULA TAXA DE ACERTO
201 mconf=zeros(nc,nc); % Matriz multiclases 4x4
202 count_OK=0;
203 for t=1:cQ, % De 1 até o número de colunas dos dados de teste, 80
204     OUT2_max=find(OUT2(:,t)==max(OUT2(:,t))); % Índice do neurônio cuja saída é a maior
205     mconf(OUT2_max,T2(t))=mconf(OUT2_max,T2(:,t))+1;
206     if T2(:,t)==OUT2_max, % Conta acerto se os dois índices coincidem
207         count_OK=count_OK+1;
208     end
209 end
210 % Taxa de acerto global
211 Tx_OK(r,:)=100*(count_OK/cQ)
212 end % FIM DO LOOP DE RODADAS TREINO/TESTE
213 mconf
214 Tx_media=mean(Tx_OK), % Taxa media de acerto global
215 Tx_std=std(Tx_OK), % Desvio padrao da taxa media de acerto

```