

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA**  
**ENGENHARIA ELÉTRICA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**Jerson dos Santos Carvalho**

**Metodologia para Detecção e Localização de Falhas em Rede Real de  
Distribuição considerando a Inserção de Veículos Elétricos**

Juiz de Fora  
2020

**Jerson dos Santos Carvalho**

**Metodologia para Detecção e Localização de Falhas em Rede Real de  
Distribuição considerando a Inserção de Veículos Elétricos**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica

Orientador: Prof. Dr. Leonardo Willer de Oliveira

Coorientador: Prof. Dr. Bruno Soares Moreira Cesar Borba

Juiz de Fora

2020

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF  
com os dados fornecidos pelo(a) autor(a)

Carvalho, Jerson dos Santos.

Metodologia para Detecção e Localização de Falhas em Rede Real de Distribuição considerando a Inserção de Veículos Elétricos / Jerson dos Santos Carvalho. – 2020.

117 f. : il.

Orientador: Leonardo Willer de Oliveira

Coorientador: Bruno Soares Moreira Cesar Borba

Dissertação (Mestrado) – Universidade Federal de Juiz de Fora, Engenharia Elétrica. Programa de Pós-Graduação em Engenharia Elétrica, 2020.

1. Falta de alta impedância. 2. Redes neurais artificiais. 3. Veículos elétricos. 4. Detecção. 5. Localização. I. Oliveira, Leonardo Willer de, orient. II. Borba, Bruno Soares Moreira Cesar, coorient. Título.

Jerson dos Santos Carvalho

**Metodologia para Detecção e Localização de Falhas em Rede Real de  
Distribuição considerando a Inserção de Veículos Elétricos**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica

Aprovada em 18 de Agosto de 2020

BANCA EXAMINADORA



---

Prof. Dr. Leonardo Willer de Oliveira - Orientador  
Universidade Federal de Juiz de Fora



---

Prof. Dr. Bruno Soares Moreira Cesar Borba -  
Coorientador  
Universidade Federal Fluminense



---

Prof. Dr. Madson Cortes de Almeida  
Universidade Estadual de Campinas



---

Prof. Dr. Bruno Henriques Dias  
Universidade Federal de Juiz de Fora

## AGRADECIMENTOS

Primeiramente agradeço a Deus por ter me propiciado saúde e força para conseguir completar esta etapa importante da minha vida.

Agradeço também aos meus pais e ao meu irmão que serviram como base em todos aspectos da minha vida até aqui e não mediram esforços para me ajudar em tudo que eu precisei. Muito obrigado pelo amor e paciência. Agradeço também à todos os outros membros da minha família pelo carinho e suporte em todos os momentos, me incentivando para que eu conquiste meus objetivos.

Agradeço também à todos os meus amigos que sempre estiverem dispostos a me ajudar de forma direta ou indireta na construção desta dissertação. Sem o apoio de vocês em todos os momentos nada disso seria possível.

Agradeço aos professores orientadores Leonardo Willer de Oliveira e Bruno Soares Moreira Cesar Borba pela paciência e orientação ao longo da construção desta dissertação. Muito obrigado por toda dedicação, disponibilidade e troca de conhecimento que obtive durante toda esta trajetória. Agradeço também à todos os professores que me auxiliaram nessa caminhada, muito obrigado, vocês agregaram muito para meu aprendizado e crescimento.

Por fim, agradeço ao Programa de Pós-Graduação de Engenharia Elétrica da Universidade Federal de Juiz de Fora por todo suporte fornecido para a elaboração deste trabalho.

## RESUMO

A presente dissertação de mestrado propõe uma aplicação de redes neurais artificiais (RNA) no problema de detecção e localização de defeitos de alta impedância de um sistema de distribuição de energia elétrica real com a presença de veículos elétricos (VE). Para isso, utilizou-se veículos elétricos com seus postos de carregamento e variou-se a curva de recarga diária dos veículos elétricos com o objetivo de avaliar o impacto nos problemas de detecção e localização de defeitos de alta impedâncias, na premissa de proteção adaptativa através da aplicação de RNA. Dentre as curvas existentes na literatura especializada escolheu-se três, com destaque especial para o tipo de recarga em que se considera o veículo elétrico tanto na condição de carregamento, quanto na condição de injeção de potência na rede de distribuição. Além das curvas de recarga, visando aumentar a aplicabilidade do método, variou-se também os patamares de carga, para a simulação de fluxo de potência via OpenDSS. Por fim, investigou-se diferentes tipos de topologias de instalação de medidores inteligentes instalados ao longo do sistema de distribuição de energia elétrica estudado e os resultados foram analisados através de métricas de avaliação e ferramentas da estatística descritiva. O estudo de caso considera uma rede elétrica real de uma concessionária de distribuição brasileira.

Palavras-chave: Falta de alta impedância. Redes neurais artificiais. Veículos elétricos. Detecção. Localização.

## ABSTRACT

The present master's thesis proposes an application of artificial neural networks in the problem of detecting and locating high impedance defects in a real electrical energy distribution system with the presence of electric vehicles. For this, electric vehicles with their charging stations were used and the daily charging curve of electric vehicles was varied in order to assess the impact on the problems of detecting and locating high impedance defects, on the premise of adaptive protection through application of RNA. Among the curves in the specialized literature, three were chosen, with special emphasis on the type of recharge in which the electric vehicle is considered, both in the charging condition and in the condition of power injection in the distribution network. In addition to the charging curves, in order to increase the applicability of the method, the load levels were also varied for the simulation of power flow via OpenDSS. Finally, we investigated different types of topologies for the installation of smart meters installed throughout the electrical energy distribution system studied and the results were analyzed using evaluation metrics and descriptive statistics tools. The case study considers a real electrical network from a Brazilian distribution concessionaire.

Keywords: High impedance fault. Artificial neural network. Electric vehicles. Location. Detection.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Esquema de funcionamento da recarga V2G. . . . .	17
Figura 2 – Mortes por choque elétrico discriminadas por tipo de edificação ou logradouro. . . . .	19
Figura 3 – Mortes totais nas redes de distribuição brasileiras - 2017. . . . .	20
Figura 4 – Veículo comum x Veículo elétrico. . . . .	21
Figura 5 – Marcos do desenvolvimento das RNA. . . . .	24
Figura 6 – Neurônio Biológico. . . . .	28
Figura 7 – Neurônio Matemático. . . . .	29
Figura 8 – Função sigmoide - propriedades. . . . .	32
Figura 9 – Função Sigmoide x Função Tanh. . . . .	33
Figura 10 – Overfitting x Underfitting. . . . .	35
Figura 11 – Exemplo de aplicação. . . . .	39
Figura 12 – Modo direto. . . . .	40
Figura 13 – Modo reverso. . . . .	40
Figura 14 – RNA simples. . . . .	41
Figura 15 – Taxa de aprendizagem pequena. . . . .	42
Figura 16 – Taxa de aprendizagem grande. . . . .	42
Figura 17 – Gradiente Descendente x Gradiente Descendente Estocástico. . . . .	43
Figura 18 – Sem <i>Momentum</i> x Com <i>Momentum</i> . . . . .	44
Figura 19 – Comparação entre otimizadores. . . . .	47
Figura 20 – Rede Multilayer Perceptron. . . . .	48
Figura 21 – Entrada de uma Rede Convolutacional. . . . .	49
Figura 22 – Convolução. . . . .	50
Figura 23 – Gurgel. . . . .	57
Figura 24 – Tesla Cybertruck. . . . .	58
Figura 25 – Recarga direta. . . . .	60
Figura 26 – Recarga no vale. . . . .	61
Figura 27 – Recarga controlada. . . . .	62
Figura 28 – Recarga V2G. . . . .	63
Figura 29 – Comportamento do perfil de tensão com o incremento da potência. . . . .	65
Figura 30 – Comportamento do perfil de tensão com o aumento da distância. . . . .	66
Figura 31 – Comportamento do desequilíbrio da tensão com o aumento da potência ativa requisitada pelo VE. . . . .	68
Figura 32 – Defeito do tipo em derivação. . . . .	72
Figura 33 – Modelo para cálculo da corrente de curto-circuito. . . . .	72
Figura 34 – Esquema da simulação. . . . .	74
Figura 35 – Arquitetura da RNA-detecção. . . . .	75

Figura 36 – Fluxograma do módulo de detecção para $MI_i$ . . . . .	78
Figura 37 – Arquitetura da RNA-localização. . . . .	82
Figura 38 – Fluxograma do módulo de localização. . . . .	83
Figura 39 – Alimentador de distribuição simplificado. . . . .	84
Figura 40 – Alimentador de distribuição com "Defeitos 1 e 2". . . . .	85
Figura 41 – Variação entre defeitos - Medidor 1. . . . .	86
Figura 42 – Variação entre defeitos - Medidor 3. . . . .	86
Figura 43 – Algoritmo proposto. . . . .	87
Figura 44 – Alimentador sob estudo. . . . .	89
Figura 45 – Curvas de recarga de VE. . . . .	91
Figura 46 – Acurácia - $RNA_i^d$ , Recarga V2G. . . . .	92
Figura 47 – Erro - $RNA_i^d$ , Recarga V2G. . . . .	92
Figura 48 – Acurácia - $RNA_m^d$ , Recarga V2G. . . . .	92
Figura 49 – Erro - $RNA_m^d$ , Recarga V2G. . . . .	92
Figura 50 – Acurácia - $RNA_f^d$ , Recarga V2G. . . . .	92
Figura 51 – Erro - $RNA_f^d$ , Recarga V2G. . . . .	92
Figura 52 – Acurácia - Detecção, Recarga V2G. . . . .	93
Figura 53 – Precisão - Detecção, Recarga V2G. . . . .	93
Figura 54 – Recall - Detecção, Recarga V2G. . . . .	94
Figura 55 – F1 - Detecção, Recarga V2G. . . . .	94
Figura 56 – Acurácia - $RNA_i^L$ , Recarga V2G. . . . .	95
Figura 57 – Erro - $RNA_i^L$ , Recarga V2G. . . . .	95
Figura 58 – Acurácia - $RNA_m^L$ , Recarga V2G. . . . .	95
Figura 59 – Erro - $RNA_m^L$ , Recarga V2G. . . . .	95
Figura 60 – Acurácia - $RNA_f^L$ , Recarga V2G. . . . .	95
Figura 61 – Erro - $RNA_f^L$ , Recarga V2G. . . . .	95
Figura 62 – Acurácia - Localização, Recarga V2G. . . . .	96
Figura 63 – Precisão - Localização, Recarga V2G. . . . .	96
Figura 64 – Recall - Localização, Recarga V2G. . . . .	97
Figura 65 – F1 - Localização, Recarga V2G. . . . .	97
Figura 66 – Acurácia - $RNA_i^d$ , Recarga direta. . . . .	99
Figura 67 – Erro - $RNA_i^d$ , Recarga direta. . . . .	99
Figura 68 – Acurácia - $RNA_m^d$ , Recarga direta. . . . .	99
Figura 69 – Erro - $RNA_m^d$ , Recarga direta. . . . .	99
Figura 70 – Acurácia - $RNA_f^d$ , Recarga direta. . . . .	99
Figura 71 – Erro - $RNA_f^d$ , Recarga direta. . . . .	99
Figura 72 – Acurácia - Detecção, Recarga direta. . . . .	100
Figura 73 – Precisão - Detecção, Recarga direta. . . . .	100
Figura 74 – Recall - Detecção, Recarga direta. . . . .	100

Figura 75 – F1 - Detecção, Recarga direta. . . . .	100
Figura 76 – Acurácia - $RNA_i^L$ , Recarga direta. . . . .	101
Figura 77 – Erro - $RNA_i^L$ , Recarga direta. . . . .	101
Figura 78 – Acurácia - $RNA_m^L$ , Recarga direta. . . . .	102
Figura 79 – Erro - $RNA_m^L$ , Recarga direta. . . . .	102
Figura 80 – Acurácia - $RNA_f^L$ , Recarga direta. . . . .	102
Figura 81 – Erro - $RNA_f^L$ , Recarga direta. . . . .	102
Figura 82 – Acurácia - Localização, Recarga direta. . . . .	103
Figura 83 – F1 - Localização, Recarga direta. . . . .	103
Figura 84 – Acurácia - $RNA_i^d$ , Recarga no vale. . . . .	104
Figura 85 – Erro - $RNA_i^d$ , Recarga no vale. . . . .	104
Figura 86 – Acurácia - $RNA_m^d$ , Recarga no vale. . . . .	104
Figura 87 – Erro - $RNA_m^d$ , Recarga no vale. . . . .	104
Figura 88 – Acurácia - $RNA_f^d$ , Recarga no vale. . . . .	104
Figura 89 – Erro - $RNA_f^d$ , Recarga no vale. . . . .	104
Figura 90 – Acurácia - Detecção, Recarga no vale. . . . .	105
Figura 91 – Precisão - Detecção, Recarga no vale. . . . .	105
Figura 92 – Recall - Detecção, Recarga no vale. . . . .	105
Figura 93 – F1 - Detecção, Recarga no vale. . . . .	105
Figura 94 – Acurácia - $RNA_i^L$ , Recarga no vale. . . . .	106
Figura 95 – Erro - $RNA_i^L$ , Recarga no vale. . . . .	106
Figura 96 – Acurácia - $RNA_m^L$ , Recarga no vale. . . . .	106
Figura 97 – Erro - $RNA_m^L$ , Recarga no vale. . . . .	106
Figura 98 – Acurácia - $RNA_f^L$ , Recarga no vale. . . . .	107
Figura 99 – Erro - $RNA_f^L$ , Recarga no vale. . . . .	107
Figura 100 – Acurácia - Localização, Recarga no vale. . . . .	107
Figura 101 – F1 - Localização, Recarga no vale. . . . .	107

## LISTA DE TABELAS

Tabela 1 – Objetivo de crescimento da frota de veículos elétricos por países até 2020. . . . .	21
Tabela 2 – Exemplo de matriz confusão . . . . .	51
Tabela 3 – Matriz confusão da classificação de fraudes . . . . .	52
Tabela 4 – Variação percentual para diferentes impedâncias de defeito . . .	73
Tabela 5 – Variação percentual entre defeitos . . . . .	85
Tabela 6 – Detalhes sobre às barras de média tensão. . . . .	90
Tabela 7 – Tabela verdade exemplo . . . . .	97

## LISTA DE ABREVIATURAS E SIGLAS

RNA	Redes Neurais Artificiais
VE	Veículos Elétricos
SEP	Sistemas elétricos de potência
SIN	Sistema interligado nacional
ONS	Operador Nacional do Sistema
SDEE	Sistemas de distribuição de energia elétrica
GD	Geração Distribuída
V2G	Veículo-para-rede
EUA	Estados Unidos da América
AG	Algoritmos Genéticos
ANEEL	Agência Nacional de Energia Elétrica
COM	Component Object Model
MI	Medidor inteligente

## LISTA DE SÍMBOLOS

$n$	Número de entradas da RNA
$x_n$	Entrada da rede neural
$w_{kn}$	Peso sináptico do neurônio relacionado a entrada $n$
$y^{(k)}$	Saída do neurônio $k$
$x_i$	Neurônio de índice $i$
$f(x_i)$	Saída do neurônio de índice $i$
$a$	Constante multiplicativa
$K$	Número total de neurônios
$C$	Custo calculado pela função
$y$	Valor real da saída
$y'$	Valor predito da saída
$\sigma$	Função de ativação utilizada
$b$	Bias
$T$	Taxa de informação
$P(i)$	Probabilidade do evento $i$ ocorrer
$E$	Entropia
$t$	Iteração
$w_t$	Peso sináptico na iteração $t$
$\eta$	Taxa de aprendizagem
$g_t$	<i>Momentum</i> na iteração $t$
$\rho$	Fator de frenagem
$v_t^i$	Média móvel do gradiente ao quadrado na iteração $t$ do neurônio $i$
$w_t^i$	Peso na iteração $t$ do neurônio $i$
$\varepsilon$	Constante para evitar denominador igual a zero
$\beta$	Fator de frenagem
$\beta_1^t$	Primeiro fator de frenagem elevado à iteração $t$
$\beta_2^t$	Segundo fator de frenagem elevado à iteração $t$
$m_t^i$	Média móvel do gradiente na iteração $t$ do neurônio $i$
$\hat{m}_t^i$	Média móvel do gradiente corrigida na iteração $t$ do neurônio $i$
$\hat{v}_t^i$	Média móvel do gradiente ao quadrado corrigida na iteração $t$ do neurônio $i$
$VN$	Verdadeiro Negativo
$VP$	Verdadeiro Positivo
$FP$	Falso Positivo
$FN$	Falso Negativo
$P$	Precisão
$VP_1$	Verdadeiro Positivo da Classe 1
$VP_2$	Verdadeiro Positivo da Classe 2
$VP_m$	Verdadeiro Positivo da Classe $m$
$FP_1$	Falso Positivo da Classe 1

$FP_2$	Falso Positivo da Classe 2
$FP_m$	Falso Positivo da Classe m
$m$	Número de classes
$P_1$	Precisão da Classe 1
$P_2$	Precisão da Classe 2
$P_m$	Precisão da Classe m
$VP_3$	Verdadeiro Positivo da Classe 3
$VP_4$	Verdadeiro Positivo da Classe 4
$FP_3$	Falso Positivo da Classe 3
$FP_4$	Falso Positivo da Classe 4
$R$	Recall
$FN_1$	Falso Negativo da Classe 1
$FN_2$	Falso Negativo da Classe 2
$FN_m$	Falso Negativo da Classe m
$R_1$	Recall da Classe 1
$R_2$	Recall da Classe 2
$R_m$	Recall da Classe m
$\dot{I}_{abc}$	Fasores de corrente em sequência de fase ABC
$\dot{I}_{012}$	Fasores de corrente em sequência de fase 012
$a$	Operador que tem como valor $1\angle 120^\circ$
$a^2$	Equivale a $1\angle -120^\circ$
$FD\%$	Fator de desequilíbrio da tensão em porcentagem
$ \dot{V}_2 $	Módulo da tensão de sequência negativa
$ \dot{V}_1 $	Módulo da tensão de sequência positiva
$Z_f$	Impedância de falta
$\dot{V}_2$	Fasor de tensão de sequência negativa
$\dot{V}_1$	Fasor de tensão de sequência positiva
$\dot{V}_0$	Fasor de tensão de sequência zero
$\dot{I}_2$	Fasor de Corrente de sequência negativa
$\dot{I}_1$	Fasor de Corrente de sequência positiva
$\dot{I}_0$	Fasor de Corrente de sequência zero
$\dot{Z}_2$	Impedância complexa de sequência negativa
$\dot{Z}_1$	Impedância complexa de sequência positiva
$\dot{Z}_0$	Impedância complexa de sequência zero
$Z_{base}$	Impedância base escolhida do sistema
$I_{base}$	Corrente base escolhida do sistema
$I_{cc}$	Corrente de curto-circuito calculada
$ \dot{V}_0 $	Módulo da tensão de sequência zero
$ \dot{I}_2 $	Módulo da tensão de sequência Negativa
$ \dot{I}_1 $	Módulo da tensão de sequência Positiva
$ \dot{I}_0 $	Módulo da tensão de sequência zero
$\angle V_2$	Ângulo da tensão de sequência Negativa

$\angle \dot{V}_1$	Ângulo da tensão de sequência Positiva
$\angle \dot{V}_0$	Ângulo da tensão de sequência zero
$\angle \dot{I}_2$	Ângulo da corrente de sequência Negativa
$\angle \dot{I}_1$	Ângulo da corrente de sequência Positiva
$\angle \dot{I}_0$	Ângulo da corrente de sequência zero
$N_{entrada}$	Número de neurônios na camada de entrada
$N_{saida}$	Número de neurônios na camada de saída
$N_{oculta}$	Número de neurônios na camada oculta
$RNA_i^d$	RNA de detecção para o MI no início do alimentador
$RNA_m^d$	RNA de detecção para o MI no meio do alimentador
$RNA_f^d$	RNA de detecção para o MI no final do alimentador
$RNA_i^L$	RNA de localização para o MI no início do alimentador
$RNA_m^L$	RNA de localização para o MI no meio do alimentador
$RNA_f^L$	RNA de localização para o MI no final do alimentador
$N_p$	Número de patamares de carga do sistema
$N_h$	Número de período
$N_{tr}$	Número de tipos de recarga
$N_{bs}$	Número de barras da rede secundária de baixa tensão
$N_{BM}$	Número de barras de média tensão sob análise
$N_t$	Número de iterações
$N_a$	Número de amostras
$BM_{im}$	Barra de média tensão selecionada
$ip$	Patamar de carga
$it$	Iteração atual do estudo
$ia$	Amostra sob estudo
$ih$	Período estudado
$ib$	Barra de baixa tensão sob análise
$tr$	Tipos de recarga
$ve$	Presença ou não de veículo elétrico

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>16</b>
1.1	CONSIDERAÇÕES INICIAIS . . . . .	16
1.2	MOTIVAÇÃO . . . . .	17
1.3	REVISÃO BIBLIOGRÁFICA . . . . .	22
1.4	OBJETIVOS . . . . .	25
1.5	PUBLICAÇÕES DECORRENTES DO TRABALHO . . . . .	26
1.6	ESTRUTURA DO TRABALHO . . . . .	26
<b>2</b>	<b>REDES NEURAIS ARTIFICIAIS . . . . .</b>	<b>27</b>
2.1	ASPECTOS BÁSICOS . . . . .	27
2.2	FUNÇÃO DE ATIVAÇÃO . . . . .	30
2.2.1	<b>Função de Etapa Binária . . . . .</b>	<b>30</b>
2.2.2	<b>Função Linear . . . . .</b>	<b>31</b>
2.2.3	<b>Função Sigmoides . . . . .</b>	<b>31</b>
2.2.4	<b>Função Tanh . . . . .</b>	<b>32</b>
2.2.5	<b>Função ReLU . . . . .</b>	<b>33</b>
2.2.6	<b>Função Softmax . . . . .</b>	<b>34</b>
2.3	FUNÇÕES DE PERDA . . . . .	34
2.3.1	<b>Função de Custo Erro médio quadrático . . . . .</b>	<b>35</b>
2.3.2	<b>Função de Custo Entropia Categórica Cruzada . . . . .</b>	<b>36</b>
2.3.3	<b>Função de Custo de Entropia Binária Cruzada . . . . .</b>	<b>38</b>
2.4	OTIMIZADORES . . . . .	38
2.4.1	<b>Gradiente Descendente . . . . .</b>	<b>41</b>
2.4.2	<b>Gradiente Descendente Estocástico . . . . .</b>	<b>43</b>
2.4.3	<b>Gradiente Descendente Estocástico com Momentum . . . . .</b>	<b>44</b>
2.4.4	<b>AdaGrad . . . . .</b>	<b>44</b>
2.4.5	<b>RMSProp . . . . .</b>	<b>45</b>
2.4.6	<b>Adam . . . . .</b>	<b>46</b>
2.5	ARQUITETURAS DE REDES NEURAIS . . . . .	47
2.6	MÉTRICAS DE AVALIAÇÃO . . . . .	50
2.6.1	<b>Matriz Confusão . . . . .</b>	<b>50</b>
2.6.2	<b>Acurácia . . . . .</b>	<b>51</b>
2.6.3	<b>Precisão . . . . .</b>	<b>52</b>
2.6.4	<b>Recall . . . . .</b>	<b>54</b>
2.6.5	<b>F1 . . . . .</b>	<b>55</b>
<b>3</b>	<b>VEÍCULOS ELÉTRICOS . . . . .</b>	<b>56</b>
3.1	HISTÓRIA DOS VEÍCULOS ELÉTRICOS . . . . .	56
3.2	ESTRATÉGIAS DE RECARGA DE VEÍCULOS ELÉTRICOS . . . . .	59

3.2.1	<b>Carregamento sem controle</b> . . . . .	59
3.2.1.1	<i>Recarga direta</i> . . . . .	59
3.2.1.2	<i>Recarga no Vale</i> . . . . .	60
3.2.2	<b>Carregamento com controle</b> . . . . .	61
3.2.2.1	<i>Recarga V2G</i> . . . . .	62
3.3	<b>VEÍCULOS ELÉTRICOS NOS SISTEMAS DE DISTRIBUIÇÃO</b> . . .	64
3.3.1	<b>Perfil de tensão</b> . . . . .	64
3.3.2	<b>Desequilíbrio de tensão</b> . . . . .	66
4	<b>METODOLOGIA PROPOSTA</b> . . . . .	<b>69</b>
4.1	OBTENÇÃO E TRATAMENTO DE DADOS . . . . .	69
4.2	MÓDULO DE DETECÇÃO DE DEFEITOS . . . . .	74
4.3	MÓDULO DE LOCALIZAÇÃO DE DEFEITOS . . . . .	81
4.4	ALGORITMO PROPOSTO . . . . .	87
5	<b>ESTUDO DE CASO</b> . . . . .	<b>89</b>
5.1	DESCRIÇÃO DA REDE DE BÚZIOS . . . . .	89
5.2	DESCRIÇÃO DAS CONDIÇÕES DE SIMULAÇÃO . . . . .	90
5.3	RESULTADOS . . . . .	91
5.3.1	<b>Recarga V2G</b> . . . . .	91
5.3.2	<b>Recarga direta</b> . . . . .	98
5.3.3	<b>Recarga no vale</b> . . . . .	103
5.3.4	<b>Discussão dos Resultados</b> . . . . .	108
6	<b>CONCLUSÃO</b> . . . . .	<b>109</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>111</b>

# 1 INTRODUÇÃO

Neste primeiro capítulo, além das considerações iniciais, é feita uma revisão bibliográfica acompanhada da apresentação dos motivos que levaram à confecção deste trabalho. Por fim, também declara-se quais são os objetivos da dissertação.

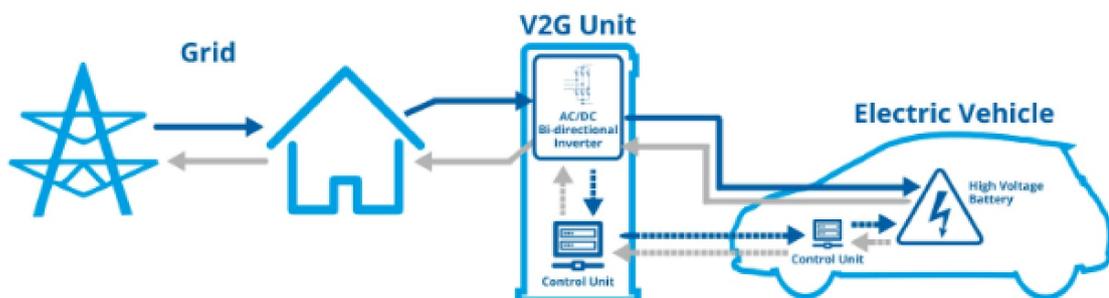
## 1.1 CONSIDERAÇÕES INICIAIS

Os sistemas elétricos de potência (SEP) são divididos basicamente em três grandes segmentos: geração, transmissão e distribuição. Na geração, observa-se a conversão da energia advinda de uma dada fonte primária para a forma elétrica, destacando-se no Brasil, a fonte hídrica, responsável por 66.6% da oferta interna nacional (EPE, 2019). De modo complementar, tem-se as usinas termoelétricas, despachadas pelo Operador Nacional do Sistema (ONS) no âmbito do Sistema Interligado Nacional (SIN) (SOUZA *et al.*, 2014), a fim de aumentar a segurança e a confiabilidade no suprimento de eletricidade. Por fim, as fontes renováveis foram responsáveis no ano de 2018 por 83.3% da oferta interna de energia elétrica no Brasil (EPE, 2019), destacando-se a energia eólica, principalmente na região Nordeste, e a fotovoltaica, cujo crescimento da potência fotovoltaica instalada foi cerca de 92% entre os anos de 2017 e 2018 (EPE, 2019). Após a etapa de geração, a energia elétrica é transportada até os centros consumidores pela rede básica de transmissão do SIN, cujas tensões estão no intervalo de  $230kV$  a  $800kV$ . Por fim, têm-se o segmento de distribuição que tem como principal atribuição realizar a entrega de energia elétrica ao consumidor final. Este serviço público deve ser realizado por concessionárias, permissionárias e autorizadas. Segundo dados da (ANEEL, 2019), existe um total de 109 agentes autorizados no Brasil. A maioria dos defeitos em SEP ocorrem no segmento de distribuição (GÖNEN, 2008). Dentre estes defeitos, pode-se citar um dos grandes desafios para a proteção em sistemas de distribuição de energia elétrica (SDEE): condutores energizados caídos ao solo. Este tipo de defeito pode, inclusive, implicar em perdas de vidas humanas devido ao contato acidental com o cabo caído. Na distribuição, há o agravante disto poder ocorrer em áreas urbanas, incluindo residenciais. Conforme as características do solo da região em que ocorre a queda de condutor, pode-se tratar de um defeito de alta impedância e, nesta situação, a detecção torna-se muito complexa para os equipamentos de proteção convencionais. Portanto, pesquisas e desenvolvimentos de estratégias e métodos para detecção de defeitos de alta impedância em redes de distribuição são promissoras e potenciais para a melhoria das condições de segurança destas redes. A localização do defeito também é uma importante resposta e requisito de sistemas de proteção, a fim de direcionar de forma efetiva as operações de reparo, restabelecimento e mitigação dos efeitos adversos de defeitos em linhas aéreas de distribuição com queda de cabo ao solo.

É importante destacar que o setor de distribuição está intimamente ligado aos

principais avanços tecnológicos dos últimos anos como, por exemplo, à inserção de geração distribuída (GD) e veículos elétricos em redes elétricas. Define-se como GD a geração próxima aos centros consumidores, que reduz ou posterga a necessidade de ampliação das redes elétricas. Os VEs, por sua vez, colaboram para a redução de emissão de gases poluentes na atmosfera e, portanto, para a diminuição de impactos ambientais decorrentes da queima de combustíveis fósseis em veículos automotores. Uma modalidade de operação de VE é conhecida como veículo-para-rede, do inglês *vehicle-to-grid* (V2G) (VARSHOSAZ *et al.*, 2019),(KASTURI; NAYAK; NAYAK, 2019), que consiste no carregamento direto em redes elétricas e, inclusive, no fornecimento da energia acumulada pelas baterias para as redes. Na Figura 1 é apresentado um esquemático que apresenta a tecnologia de recarga V2G de forma resumida. Observa-se primeiramente a rede de distribuição que alimenta as residências e consequentemente os pontos de recarga V2G. Nota-se na imagem que o ponto de recarga é formado por um inversor bidirecional que visa transformar as ondas de tensão e corrente para corrente contínua caso o sentido do fluxo no instante seja da rede de distribuição para o VE. Caso o sentido do fluxo seja o contrário, o inversor transformará o sinal elétrico do formato contínuo para alternado para que possa ser injetado na rede de distribuição.

Figura 1 – Esquema de funcionamento da recarga V2G.



Source: fleetcarma.com

Fonte: (RENEWABLES, 2018).

Neste cenário, pesquisas devem ser conduzidas visando avaliar a operação e/ou preparar o sistema de distribuição para inserção de VE. Uma avaliação importante é a de impacto da recarga de V2G na detecção e localização de defeitos em redes de distribuição.

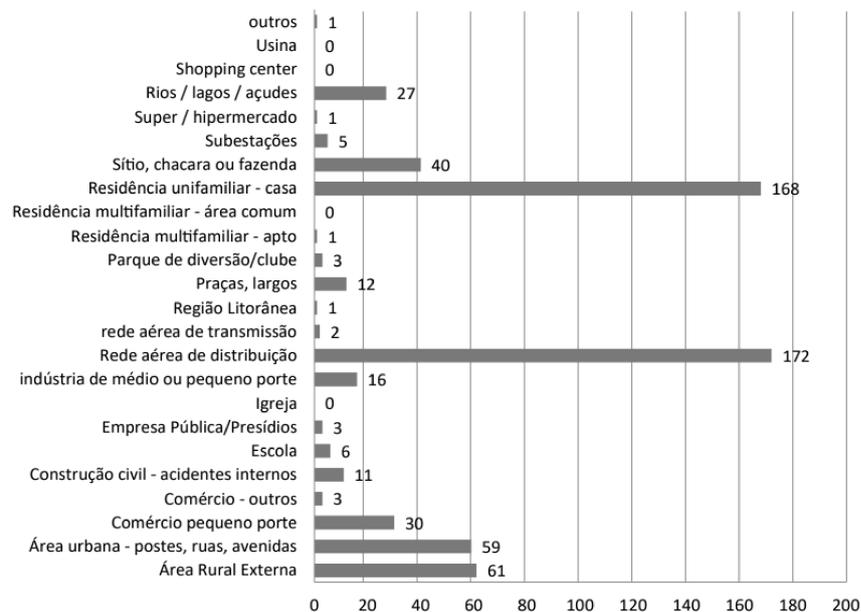
## 1.2 MOTIVAÇÃO

Conforme mencionado anteriormente, o principal desafio da proteção na atualidade é a identificação de defeitos de alta impedância, que podem ser classificados como ativos ou passivos. Com relação ao primeiro, entende-se como um defeito que causa um arco

elétrico, fenômeno decorrente da ruptura do dielétrico de um meio que é isolante (LEITE, 2017). Nesta situação, um defeito em derivação, ou *shunt*, ocorre quando há o contato de um condutor energizado com um ponto qualquer fora da linha de distribuição área, porém, sem o rompimento do cabo. Desta forma, pontos a jusante do defeito continuam a ser alimentados. Esse tipo de defeito é comum em acidentes envolvendo colisões de veículos automotores com poste da rede elétrica, em que a estrutura da rede é parcialmente danificada, provocando o contato de condutores energizados com o solo. Nos defeitos passivos, o condutor energizado se rompe sem qualquer indicação visual que é comum à formação de arco elétrico. Ou seja, defeitos passivos são de enorme risco para a população devido à ausência de arco elétrico e, conseqüentemente, redução ou ausência de ruído decorrente do defeito. Além disto, defeitos passivos assemelham-se à abertura de uma fase, em que não há um indicativo evidente de falha que chame a atenção da distribuidora quanto ao perfil de tensões e correntes na rede para análise de seus operadores (LEITE, 2017).

Apesar de ser um incidente que ocorre com baixa frequência se comparado com outros tipos de defeitos, faltas de alta impedância recebem maior preocupação, devido à dificuldade de detecção e às conseqüências relacionadas a riscos de lesões e perdas de vidas humanas. De forma geral, ocorreram 1424 acidentes de origem elétrica em 2018, o que representa um aumento de 2.67% se comparado com ano anterior (ELETRICIDADE, 2019). Na Figura 2, observa-se que acidentes com mortes na rede de distribuição aérea ocuparam o primeiro lugar no ano de 2018, com um total de 172 casos. Dentre estes acidentes, existem aqueles causados por descuido e falta de uso de equipamentos individuais de proteção por parte de trabalhadores, em sua maioria autônomos, que realizam serviços de construção e reparo próximos a rede elétrica de distribuição. No entanto, os cabos caídos ao solo também fazem parte desta categoria e exigem manutenção constante por parte das empresas distribuidoras de energia elétrica.

Figura 2 – Mortes por choque elétrico discriminadas por tipo de edificação ou logradouro.



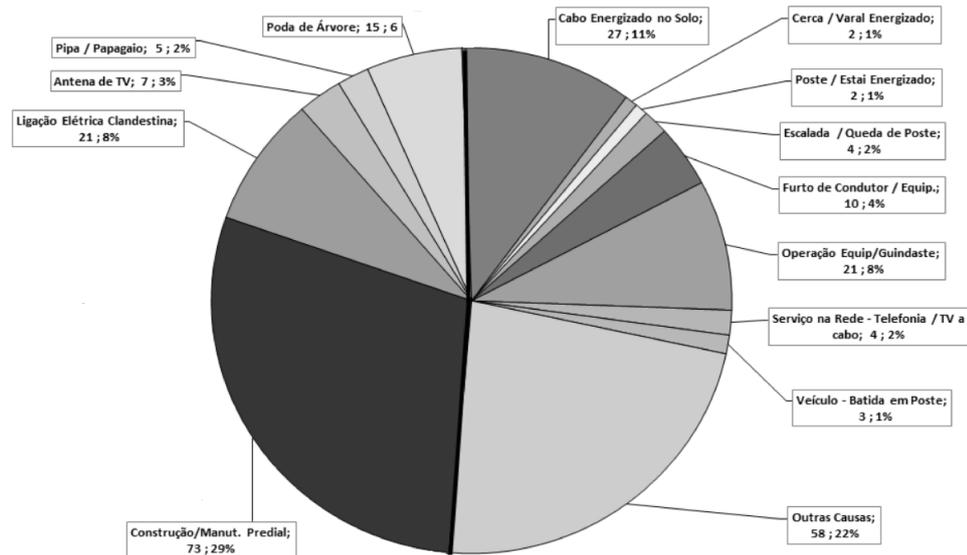
Fonte: (ELETRICIDADE, 2019).

Nota-se na Figura 3 que os acidentes com cabos caídos ao solo foram a terceira maior causa de mortes no setor de distribuição no ano de 2017, com 27 casos. Este dado estatístico reforça que as distribuidoras de energia elétrica devem se atentar e procurar uma agenda de maior prevenção e manutenção da rede elétrica sob sua responsabilidade. Além disto, é papel das distribuidoras e dos meios de comunicação promoverem campanhas educativas para instruir a população sobre como se comportar quando encontrar um cabo energizado rompido, pois, muitos acidentes ocorrem devido à falta de instrução e curiosidade das pessoas que arriscam suas vidas ao se aproximar de condutores energizados. Por fim, as distribuidoras também devem investir em tecnologias que tornem mais eficientes a detecção e a localização de faltas de alta impedância, objetivo do presente trabalho. Em (G1, 2018), pode-se encontrar relato de mortes devido a condutores energizados enterrados na areia, que se trata de um tipo de solo de alta impedância.

Segundo (LEITE, 2017), a corrente medida durante um defeito de alta impedância envolvendo cabo energizado caído em solo arenoso ou em asfalto é 0A. Assim, não há a mínima possibilidade desta corrente sensibilizar os relés de proteção contra sobrecorrente, fato agravado pela alta probabilidade de um cabo energizado cair em asfalto, já que a rede de distribuição é passada através de ruas e avenidas. Além disto, também há relatos de cabos energizados que caem em regiões que apresentam solo de areia silicosa. Com a queda, há a fundição do material, que adere à superfície do condutor. Após isto, caso o equipamento de proteção detecte e isole o defeito, proporciona um ambiente ideal para a solidificação da camada de material/condutor, que passa a agir como uma espécie

de isolante. Desta forma, se o alimentador de distribuição for dotado de religador, a energia elétrica é restaurada e o sistema volta a operar como se não houvesse defeito (KINDERMANN, 1992), porém, com a falta de alta impedância caracterizada e o solo energizado.

Figura 3 – Mortes totais nas redes de distribuição brasileiras - 2017.



Fonte: (ELÉTRICA, 2018).

O problema de detecção e localização de defeitos de alta impedância é bem conhecido na literatura especializada e ainda consiste em tema aberto para a investigação, no que se refere ao desenvolvimento de métodos eficazes. Adicionalmente, têm-se a inserção de veículos elétricos em redes de distribuição, que consiste em assunto atual e cuja participação tende a aumentar devido a questões ambientais e surgimento de novas tecnologias. De acordo com (AUTO-ESPORTE, 2019), até 2040, os veículos elétricos devem crescer de dois para 56 milhões de unidades. Atualmente, China, Europa e Estados Unidos (EUA) são responsáveis por 90% da produção mundial (HITECH, 2019), com crescimento pronunciado na Europa. Na Tabela 1, observa-se as metas ambiciosas dos chineses que pretendem, até 2020, multiplicar por quinze sua frota de VE. Todo o crescimento mostrado na Tabela 1 explica-se pelas metas de alguns países de terminarem com a produção de veículos movidos a combustíveis fósseis. A Alemanha, por exemplo, anunciou a proibição do uso de veículos com combustão interna até 2030, porém, há uma certa desconfiança mundial com esta meta devido à forte indústria automotiva do país (FGV, 2017). Entretanto, todo este movimento aponta para uma agenda de redução da emissão de gases poluentes e o aumento de eficiência no setor de transportes.

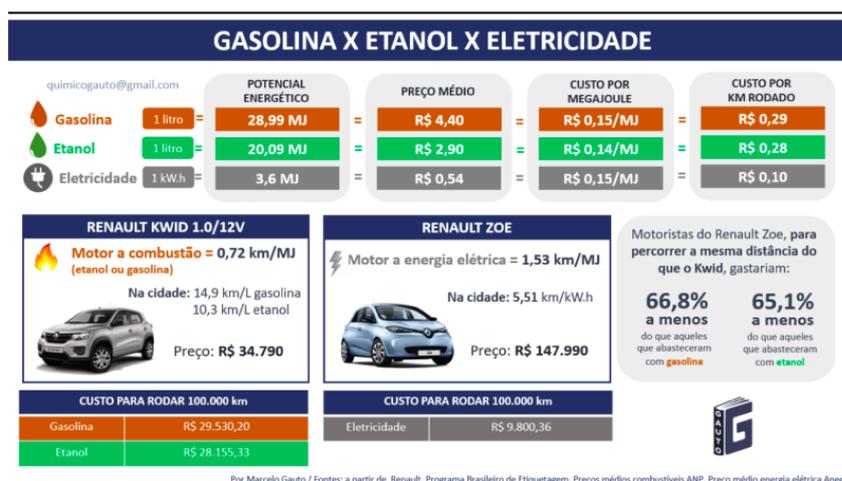
Tabela 1 – Objetivo de crescimento da frota de veículos elétricos por países até 2020.

Países	Frota de VE - 2015 (10 <sup>3</sup> )	Meta de crescimento - 2020 (10 <sup>3</sup> )
Áustria	5.3	200
China	312.3	4500
Dinamarca	8.1	200
França	54.3	2000
Alemanha	49.2	1000
Índia	6.0	300
Irlanda	2.0	100
Japão	126.4	1000
Holanda	87.5	300
Portugal	2.0	200
Coréia do Sul	4.3	200
Espanha	6.0	200
Reino Unido	49.7	1500
Estados Unidos	101.0	1200

Fonte: (FGV, 2017).

Por fim, observando a Figura 4, nota-se que os VE não são vantajosos apenas do ponto de vista ambiental, mas também economicamente. Em um comparativo com um veículo popular, o VE leva larga vantagem na maioria dos itens observados. No entanto, incentivos fiscais são necessários para alavancar a presença de VE entre as frotas de veículos automotores.

Figura 4 – Veículo comum x Veículo elétrico.



Fonte: (GAUTO, 2019).

Como defeitos de alta impedância em redes de distribuição de energia elétrica provocam, anualmente, dezenas de mortes, e a detecção e localização destes defeitos é difícil, consistindo em tema ainda aberto para a investigação, a pesquisa e o desenvolvimento de

métodos eficazes nestas tarefas são promissores. Além disto, a avaliação dos impactos da presença de V2G nos problemas de detecção e localização dos defeitos citados é importante para fomentar o desenvolvimento futuro de métodos que sejam capazes de lidar com esta presença, cuja tendência é ser cada vez mais representativa. Portanto, estes aspectos serviram como fatores motivacionais para a pesquisa da presente dissertação de mestrado.

### 1.3 REVISÃO BIBLIOGRÁFICA

Tratando-se de defeitos de alta impedância, a principal característica que se observa é o pequeno impacto nas correntes da rede elétrica. Os relés convencionais são projetados para operarem em uma faixa de correntes de *pick-up* bem maiores do que a corrente de um defeito de alta impedância. Assim, técnicas especializadas em detecção e localização de defeitos surgiram visando contornar esta limitação por parte dos equipamentos de proteção convencionais (AUCOIN; RUSSELL, 1987), (GAUTAM; BRAHMA, 2012) e (SREERAMA; SWARUP, 2017).

Nota-se que diversos fatores dificultam a obtenção da solução do problema descrito. Com as constantes alterações nas redes elétricas, metodologias de proteção adaptativa foram desenvolvidas (KEZUNOVIC, 2000) e (XU; CHOW, 2006). Com o aumento do uso da geração distribuída, aumenta-se a complexidade da rede elétrica e com a possibilidade do consumidor injetar o excedente de sua produção no sistema de distribuição, altera-se de forma significativa o planejamento, operação e manutenção da distribuidora. Por si só, a inserção da geração distribuída no SEP transforma o sistema elétrico, que conservadoramente tem topologia radial, para uma topologia em anel com mais de um sentido de corrente (SOUZA, 2012). Dessa forma, nota-se claramente uma alteração na rede de distribuição e a proteção adaptativa é vista como um dos principais métodos para solucionar este problema (KEZUNOVIC, 2009), (KEZUNOVIC, 2011) e (HE *et al.*, 2016). Entre as técnicas inteligentes de proteção adaptativa, pode-se citar Algoritmos Genéticos (AG) (ALVES; MACHADO; BERGÊ, 2010; PUJANTARA *et al.*, 2016), Lógica Nebulosa (MUSIEROWICZ *et al.*, 2005; ANGGRIAWAN *et al.*, 2019) e Redes Neurais Artificiais (MICHALIK *et al.*, 2006), (KEZUNOVIC; VASILIC, 2001) e (DARYANI; KARKEVANDI; USTA, 2019).

Há um interesse significativo pela utilização de redes neurais artificiais com o intuito de detecção e localização de defeitos em geral e, de forma mais específica, de defeitos de alta impedância. Estas aplicações datam de desde a década de 1950, porém, à época, faltavam avanços que possibilitassem às RNA alcançarem sua potencialidade atual. Basicamente, o que proporcionou a explosão da utilização de modelos baseados no cérebro humano foi uma confluência de dois fatores: i) o anseio dos *gamers* por poder computacional, que criou as placas de processamento gráfico e paralelo, permitindo a realização de operações matemáticas com grandes vetores e matrizes em tempos reduzidos;

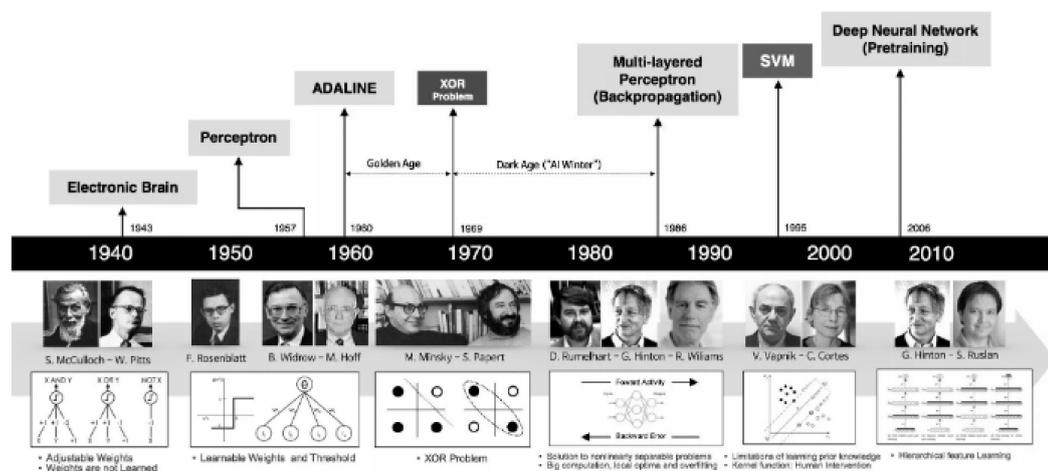
ii) *Big Data*, ou seja, um grande volume de dados gerado em alta velocidade e com enorme variedade, proporcionando a construção de modelos cada vez mais precisos. Desta forma, observa-se o substrato perfeito para o crescimento dos modelos de *machine learning*, o que foi observado na grande aplicabilidade destas técnicas nos últimos anos (ACADEMY, 2019).

Apesar da gama de aplicações de RNA, esta ferramenta já passou por períodos de baixo interesse, sendo até mesmo comparada com pseudociência. Um dos primeiros passos foi em 1943, onde o neurofisiologista Warren McCulloch e o matemático Walter Pitts escreveram um artigo explicando o funcionamento dos neurônios, baseando-se em uma experiência com circuitos elétricos (ACADEMY, 2019). Já em 1958, Frank Rosenblatt criou o Perceptron, um algoritmo especializado em reconhecimento de padrões que tinha uma RNA com duas camadas. Após isto, as RNA avançaram até meados de 1959, porém, a expectativa otimista quanto ao potencial de aplicação foi frustrada nas décadas seguintes, reduzindo o nível de investimentos e provocando o período denominado *AI Winter* (ACADEMY, 2019). Este período durou até 1982, onde o interesse pelas RNAs foi liderado por cientistas como John Hopfield que, com uma abordagem matemática, priorizou a criação de dispositivos úteis para a sociedade. No entanto, um grande crescimento de fato ocorreu a partir dos anos 2000, devido ao surgimento das placas gráficas e do *Big data*. Na Figura 5, observa-se os marcos do desenvolvimento das RNA, sendo os principais marcos (ACADEMY, 2019):

- 1943** O neurofisiologista Warren McCulloch e o matemático Walter Pitts criam um modelo de RNA baseado em circuitos elétricos;
- 1958** Frank Rosenblatt cria o Perceptron, um algoritmo especialista em reconhecimento de padrões;
- 1959** Bernard Widrow e Marcian Hoff desenvolveram o modelo de múltiplos elementos adaptativos linear, especialista em reconhecimento de padrões binários;
- 1969** Marvin Minsky e Seymour Papert provam que um único Perceptron não é capaz de aprender características de uma função *XOR*;
- 1986** As redes neurais artificiais de várias camadas foram desenvolvidas;
- 1995** Corinna Cortes e Vladimir Vapnik publicam um artigo sobre *Support-Vector Networks*, metodologia que auxiliou na evolução da classificação de modelos binários;
- 2006** A aprendizagem profunda ganha popularidade após o artigo de dois cientistas renomados na área, Geoffrey Hinton e Ruslan Salakhutdinov.

Além destes marcos, pode-se destacar inovações recentes que demonstraram o potencial das RNA como, por exemplo, o desenvolvimento da tecnologia *Depp Face*, em 2015, que se propõe a localizar fisionomias e identificar pessoas em fotografias. Além disto, em 2016, um algoritmo baseado em RNA venceu o grande campeão mundial de Go Lee Sedol em evento de ampla divulgação (ACADEMY, 2019). Com o advento das RNAs, a partir de um grande conjunto de dados, processadores robustos e velozes, e um algoritmo bem estruturado, algumas tarefas que só seriam realizadas por seres humanos podem ser feitas por computadores (ACADEMY, 2019).

Figura 5 – Marcos do desenvolvimento das RNA.



Fonte: (ACADEMY, 2019).

Já no âmbito de sistemas elétricos de potência, observa-se diversas aplicações de RNA, inclusive na área de detecção e localização de defeitos em rede elétricas. Entre estas aplicações, uma metodologia de detecção de defeitos envolvendo abertura de circuito pode ser encontrada em (HE *et al.*, 2018). Já em (TODOROV; GILEV, 2018), uma RNA é utilizada para a localização de trechos com defeitos em uma rede real de distribuição. Em (RESMI *et al.*, 2019), tem-se a aplicação de RNA para detecção, classificação e localização de defeitos em sistemas elétricos de transmissão.

Com relação à detecção de defeitos de alta impedância, em (SIROJAN *et al.*, 2018), utiliza-se uma abordagem baseada em RNA convolucionais para melhoria de eficiência neste processo. Nesta mesma linha e conceito de proteção adaptativa, em (LUCAS *et al.*, 2018), utiliza-se um modelo baseado em RNA para a detecção de faltas de alta impedância em um sistema com geração distribuída. Em (MOLOI; JORDAAN; HAMAM, 2018), aplica-se RNA para a localização e classificação de defeitos de alta impedância em um sistema real de distribuição.

Com relação ao impacto de V2G conectados a redes de distribuição, em (RAMADAN; ALI; FARKAS, 2018), avalia-se o impacto do carregamento destes veículos em uma

rede real, sob o ponto de vista da baixa tensão, ou seja, de unidades residenciais. Já em (SALAMA *et al.*, 2019), analisa-se quais são os efeitos para o sistema de distribuição de diferentes patamares de penetração e tipos de operação de veículos elétricos. Seguindo, em (CHITNIS; PANDIT; SHAIKH, 2018), aplica-se RNA para estimar nível de carregamento de uma bateria de VE. Reforçando a importância que os VEs podem ter para sistemas de distribuição futuros, em (MAHMUD; HOSSAIN; RAVISHANKAR, 2018), um VE é utilizado para controle da curva de carga. Por fim, em (NAGESHRAO; JACOB; WILKINS, 2017), otimiza-se a recarga de veículos elétricos em rede de distribuição, através da aplicação de RNA para previsão da curva de carga do dia seguinte.

#### 1.4 OBJETIVOS

O presente trabalho propõe uma aplicação de sistema inteligente via redes neurais artificiais ao problema de detecção e localização de defeitos de alta impedância em uma rede real de uma concessionária brasileira, incluindo a presença de veículos elétricos e postos de carregamento. A aplicação leva em conta diferentes patamares de carregamento e curvas típicas de recarga de veículos elétricos para a realização de análises de defeito via fluxo de potência. Para estas simulações, utiliza-se o software recomendado pela Agência Nacional de Energia Elétrica (ANEEL) para estudos em redes de distribuição. Por fim, investiga-se o desempenho da aplicação para diferentes estratégias de alocação de medidores na rede elétrica de distribuição. Mais especificamente, os principais objetivos são:

- Modelagem e análise de defeitos de alta impedância em um sistema real de distribuição de uma concessionária brasileira utilizando o modelo de análise de redes OpenDSS, recomendado pela ANEEL;
- Investigar estratégias para o problema de detecção e localização de defeitos de alta impedância em rede de distribuição através de RNA, envolvendo as variáveis da rede real a serem utilizadas;
- Investigar estratégias para o problema de detecção e localização de defeitos de alta impedância em rede de distribuição através de RNA, envolvendo opções de alocação de medidores na rede real;
- Investigar o impacto da presença de veículo elétrico com recargas, V2G, direta e vale, considerando as curvas típicas de carregamento, no problema de detecção e localização de defeitos de alta impedância na rede real de distribuição utilizada.

## 1.5 PUBLICAÇÕES DECORRENTES DO TRABALHO

Os estudos referentes ao tema desta dissertação geraram um trabalho científico publicado em um congresso internacional:

dos Santos Carvalho, J., de Oliveira, L. W., Borba, B. S. M. C., de Oliveira, A. R., and Dias, B. H. (2019). An expert approach for location of high impedance faults in electrical distribution systems with electric vehicles. 13th Latin-American Congress on Electricity Generation and Transmission - CLAGTEE 2019.

## 1.6 ESTRUTURA DO TRABALHO

O presente trabalho apresenta um total de seis capítulos, sendo o primeiro capítulo introdutório. No segundo capítulo, faz-se uma retomada histórica sobre redes neurais artificiais, sendo descritos processo de aprendizagem e interação entre elementos. Já o terceiro capítulo é dedicado aos veículos elétricos, envolvendo desenvolvimento mundial, tecnologias de recarga, principais propriedades e impactos em sistemas de distribuição. O quarto capítulo mostra a metodologia utilizada nas simulações feitas. Já o quinto capítulo mostra os resultados encontrados e discute-se alguns pontos importantes e apresenta-se algumas interpretações dos resultados. Por fim, no capítulo 6, tem-se um resumo geral do trabalho seguido da discussão dos resultados de forma geral. Além disso, neste capítulo apresenta-se quais são as propostas de trabalhos futuros.

## 2 REDES NEURAIS ARTIFICIAIS

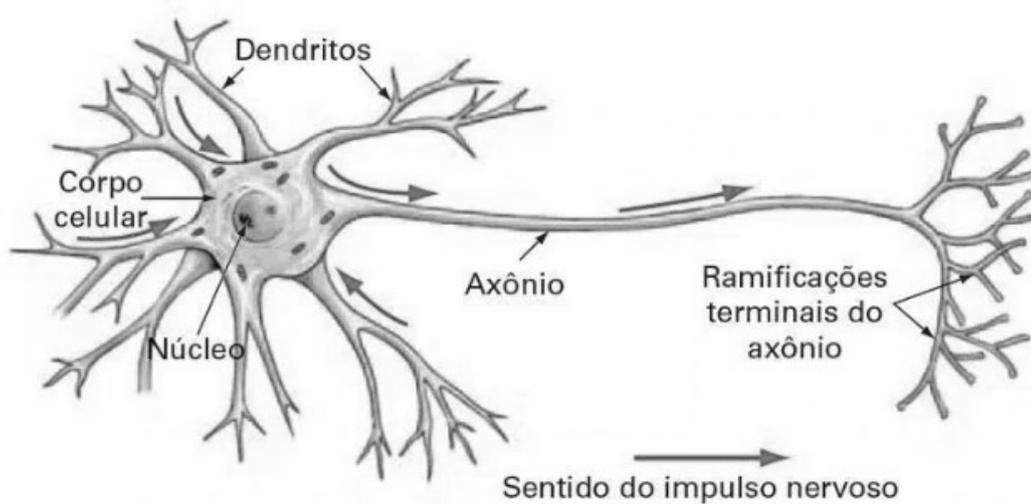
A história das redes neurais artificiais é antiga como já dito na seção 1.3 e cheia de altos e baixos. Tanto que, por questões de marketing, após os períodos de baixo interesse e descrença no assunto o nome teve que ser alterado. Assim, nomes como *Machine Learning* e inteligência artificial foram utilizados dependendo da época, porém vale salientar que os termos não são sinônimos. Outro embate importante que marca a história da inteligência artificial é a batalha ideológica que busca dar significado ao assunto *Machine Learning*. Uma vertente entende que inteligência esta intimamente ligado com a resolução de equações matemáticas e demonstração de teoremas. Dentre os resultados advindos dessa direção pode-se citar o solucionador de problemas gerais que, em suma, é capaz de solucionar qualquer problema que seja simbólico e formalizado. Pode-se citar alguns exemplos como, jogo do xadrez e resolução de problemas de geometria (PSR, 2019; TEIXEIRA; GONZALES, 1983). Por outro lado, tem-se a vertente que entende como inteligência a capacidade de emular o cérebro humano, por isso o nome redes neurais artificiais. O primeiro passo da evolução dessa direção aconteceu com o desenvolvimento do Perceptron, uma RNA de camada única capaz de tomar decisões baseado em evidências (ACADEMY, 2019; PSR, 2019). As duas primeiras abordagens das duas vertentes falharam e culminaram no que ficou conhecido como inverno da inteligência artificial. A primeira, era capaz de solucionar equações e demonstrar teoremas, no entanto, não era capaz de reconhecer objetos simples o que diminuiu o interesse pela tecnologia. A segunda, tinha capacidade limitada de tomar decisões sendo que um enorme tempo deveria ser despendido para a solução de uma tarefa extremamente simples. Esse comportamento arrefeceu também o interesse pelo o Perceptron.

### 2.1 ASPECTOS BÁSICOS

O neurônio é a parte mais básica do sistema nervoso humano. É através dele que ocorre a transmissão de informações o que de forma simples culmina em características como, capacidade de comunicação, alta curva de aprendizagem e reconhecimento de padrões através do processamento de sinais. Observa-se que o cérebro humano é formado por bilhões de neurônios conectados entre si, o que confere capacidade de aprendizagem enorme a qualquer ser humano. Atividades como reconhecimento de dígitos são realizadas com enorme maestria e num tempo mínimo, no entanto, essa facilidade é enganosa e as tarefas que são realizadas no centro do sistema nervoso são extremamente complexas. Essa falsa percepção de facilidade é consequência do fato que todas as etapas necessárias são realizadas de forma inconsciente e não há nenhum esforço consciente por parte do ser humano. Assim, vale salientar que o cérebro humano é uma maquina extremamente adaptada, para realizar funções complexas, que foi moldada através da evolução por centena de milhões de anos (NIELSEN, 2015).

Basicamente os neurônios são divididos em três partes fundamentais que podem ser observadas na Figura 6, corpo celular, axônios e dendritos. Primeiramente, ligados ao corpo celular estão os dendritos que são responsáveis pela recepção de informações vindas de outros neurônios. Um pouco mais extenso que os dendritos estão os axônios, que são responsáveis por transmitir a informação para outros neurônios através de um processo denominado sinapse (ACADEMY, 2019).

Figura 6 – Neurônio Biológico.



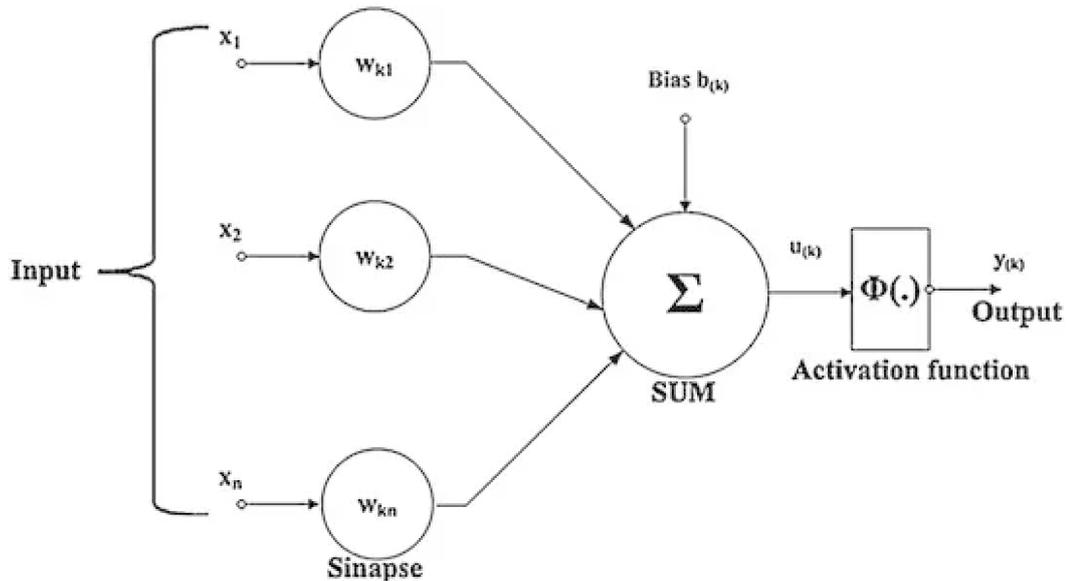
Fonte: (ACADEMY, 2019).

O caminho da informação no neurônio segue uma sequência lógica direcional. Primeiramente, o sinal elétrico vindo de sensores biológicos (visão, tato, olfato) chega pelos dendritos e é encaminhado até o corpo celular onde é processado no núcleo. Logo após, essa informação é enviada pelo axônio até o outro neurônio. É estabelecido um limiar de disparo, caso esse sinal elétrico seja superior ao limite ele segue pelo neurônio, caso contrário o sinal é descartado. O ponto de conexão entre o axônio de um neurônio e o dendrito de outro é chamado sinapse que tem como principal função controlar o fluxo de informação.

Com base no neurônio biológico, os pesquisadores desenvolveram um modelo matemático que é mostrado na Figura 7. Nesse modelo, observa-se que o papel da ligação entre os neurônios é representada pelas entradas que são denominadas  $x_n$  onde "n" representa o número de entradas. De forma semelhante ao componente biológico, observa-se que a depender das escolhas e das experiências anteriores algumas informações são mais importantes que as outras, assim, modelou-se a figura do peso sináptico que na Figura 7 tem o nome de  $w_{kn}$ . Após essa etapa inicial, tem-se o corpo celular que é dividido em um somatório seguido de uma função de ativação. Todas as entradas multiplicadas por seus pesos sinápticos são somadas e encaminhadas até uma função de ativação que tem como

principal função definir qual será a saída( $y_{(k)}$ ) do processo neurológico. Por fim, tem-se o bias que é um termo que é adicionado ao somatório com o intuito de proporcionar um maior grau de liberdade a função de ativação. Assim, se todas as entradas forem nulas, a saída pode ser diferente de zero o que é uma característica importante para determinadas aplicações.

Figura 7 – Neurônio Matemático.



Fonte: (ACADEMY, 2019).

Com objetivo de ilustrar de forma simples o processo de um neurônio matemático pode-se usar um perceptron. Considerando três entradas para a tomada de decisão de ir a um show, a saber, i) condições climáticas, ii) companhia, iii) transporte até o evento. Vale salientar que o perceptron só aceita entradas binárias, assim, a representação das condições devem ser 0 ou 1, sendo 0 o pior caso e 1 a melhor condição. Como é um evento a céu aberto, assim, as condições climáticas é considerado o mais importante dentre as três condições e, dessa forma, pode-se dar os seguintes pesos sinápticos,  $w_1 = 3$ ,  $w_2 = 2$  e  $w_3 = 2$ . Por fim, com o papel semelhante a função de ativação tem-se um limite que para este exemplo é 5. Assim, realizando as operações matemáticas observa-se que a saída é 1 sempre que o tempo for bom, caso contrário, a saída é nula. Esse comportamento não depende das condições referentes ao transporte e companhia (NIELSEN, 2015). Assim, variando-se os pesos sinápticos pode-se observar uma diferença na saída. O mesmo ocorre no neurônio biológico onde já se descobriu através de pesquisas científicas que o processo de aprendizagem se dá por reforço, ou seja, aquele caminho neurológico que é mais utilizado tem um maior peso sináptico e por consequência gera um processo de aprendizagem maior. Por fim, observa-se que a base para qualquer processo em inteligência artificial é o neurônio

biológico que forneceu, através de pesquisas sobre seu comportamento, um vasto leque de possibilidade e aprendizagem.

## 2.2 FUNÇÃO DE ATIVAÇÃO

O principal objetivo de um função de ativação é adicionar não linearidade ao processo, assim, permitindo a modelagem de problemas mais complexos que são mais comuns no mundo real. O processo natural em um neurônio é unidirecional, como já foi visto. Assim, as entradas são somadas e multiplicadas pelos pesos sinápticos fazendo assim um combinação linear. O objetivo principal de uma rede neural é encontrar a melhor configuração de pesos e bias, baseado no erro, que faça com que a saída atenda aos requisitos da aplicação que estamos desenvolvendo. Assim, observa-se que é desejável que pequenas mudanças nos pesos produzam pequenas variações na saída facilitando o processo de aprendizagem, no entanto, não é o que ocorre se a RNA é formada por apenas perceptrons. Pequenas variações nos pesos podem satisfazer a questões pontuais da aplicação, no entanto, de forma global pode-se ter um resultado insatisfatório. Dessa forma, entra em questão a figura da função de ativação que tem como propósito definir se a informação deve ser considerada ou descartada. Esse processo se da por intervalo de valores, não importando a amplitude do número que foi recebido. Assim, pequenas variações nos pesos podem produzir grandes amplitudes que serão tratadas na função de ativação e traduzidas para representar uma saída no final do processo que ocorre em um neurônio. Existem diversos tipos de funções de ativação e a escolha depende da aplicação de RNA que se esteja trabalhando. As principais funções de ativação que são utilizadas na maioria das aplicações da atualidade são mostradas nas próximas subseções.

### 2.2.1 Função de Etapa Binária

Dentre as funções de ativação estudadas a *Binary Step Function* é mais básica e de simples entendimento, no entanto, não há grande aplicabilidade pois ela não se adequa aos problemas do mundo real. Basicamente, essa função de ativação define se o neurônio será ou não ativado baseando-se num limite definido. Esse comportamento é bem semelhante ao relatado no problema exemplo da seção 2.1. A definição matemática é mostrada na equação (2.1).

$$\begin{aligned} f(x_i) &= 1 \text{ se } x \geq 0 \\ f(x_i) &= 0 \text{ se } x \leq 0 \end{aligned} \tag{2.1}$$

Em que:

$x_i$       Neurônio de índice i;  
 $f(x_i)$    Saída do neurônio de índice i.

Assim, observa-se que se a aplicação é um classificador binário e que deseja-se dizer sim ou não para uma determinada classe, a função de ativação em questão é adequada. No entanto, como já dito a maioria das aplicações são mais complexas e possuem mais classes para decisão.

### 2.2.2 Função Linear

De forma semelhante a função de ativação *Binary Step Function* tem-se a função linear que é definida como mostrado na (2.2).

$$f(x_i) = x_i a \quad (2.2)$$

Em que:

$a$  Constante multiplicativa.

Além de ser uma função de ativação extremamente simples observa-se dois principais problemas que inviabilizam na maioria dos casos a aplicação da função de ativação linear. O processo de treinamento de uma rede neural é dependente de derivadas que permite que o erro decresça a cada época do processo. No entanto, uma característica da função linear é que sua derivada é constante independente da entrada, assim, não se tem uma decréscimo do erro e a taxa de aprendizagem não aumenta. Vale dizer que o problema semelhante ocorre na função de ativação da subseção 2.2.1, no entanto, como é uma constante sua derivada é sempre nula. Outro importante problema da abordagem linear é que a cada camada da rede neural há uma transformação linear, no entanto, há uma transformação linear que liga a entrada na saída sem precisar passar pelas etapas intermediárias, dessa forma, o processo de aprendizagem fica prejudicado.

### 2.2.3 Função Sigmoidal

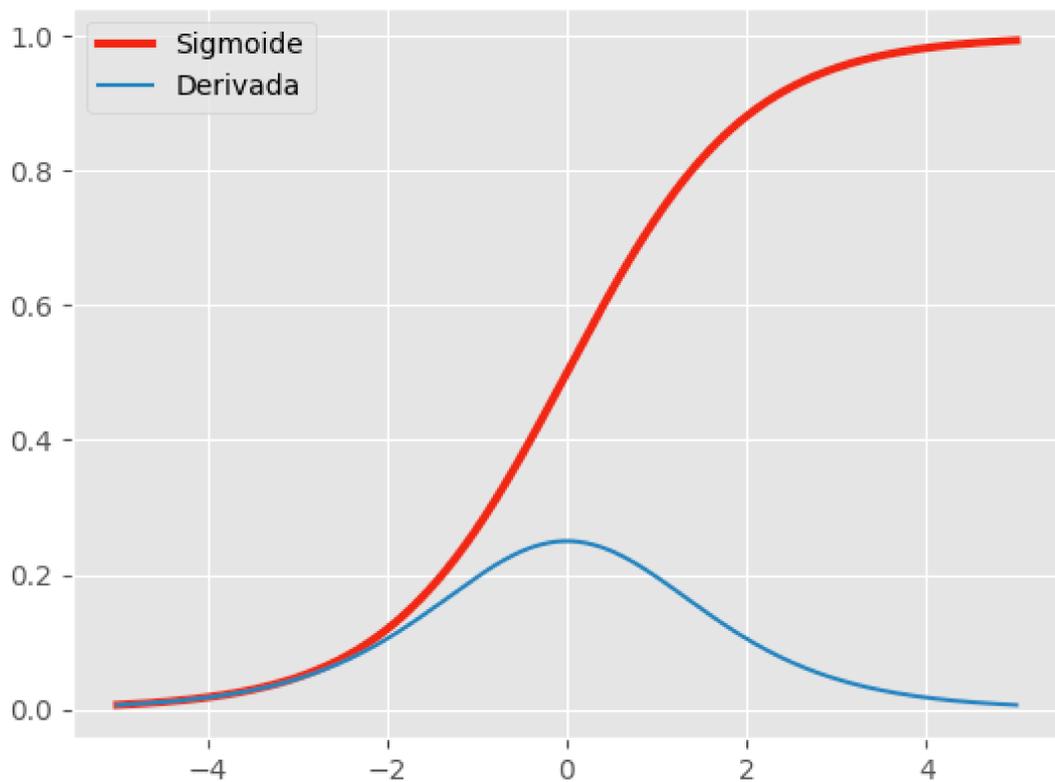
Com uma maior aplicabilidade em relação as outras duas funções anteriores, a função sigmoide apresenta uma característica interessante que a diferencia e aumenta seu uso, a não linearidade. Definida através da equação (2.3), observa-se que uma propriedade desta função é que sua saída se encaixa no intervalo entre 0 e 1. Além disso, nota-se que de forma contrária às duas funções anteriormente apresentadas não há problemas com diferenciação, pois, a função é contínua e diferenciável, portanto, pode-se atualizar e há alteração nos pesos a cada iteração do processo de treinamento fazendo com que o erro calculado pela função de custo diminua. Por outro lado, observa-se outro problema que ocorre em certas aplicações que o gradiente é extremamente pequeno ou nulo. Esse problema ocorre em ocasiões em que a função foge do intervalo entre -5 e 5 (FACURE, 2019) o que é mostrado na Figura 8, assim, nota-se que as atualizações dos pesos sinápticos

são insignificantes ou até mesmo nulas o que provoca um processo de treinamento lento ou até mesmo inviável.

$$f(x_i) = \frac{1}{1 + e^{-x_i}} \quad (2.3)$$

Além disso, observando a Figura 8 e a partir da equação (2.3), observa-se que a função tende a levar o valor da sua saída para os extremos. Essa propriedade é importante para aplicações de classificação porque tem-se uma diferença muito grande entre as saídas em cada iteração permitindo a correta seleção das classes. Por fim, nota-se também que esse tipo de função de ativação não é simétrico em relação a origem e em determinadas aplicações essa característica pode não ser desejável.

Figura 8 – Função sigmoide - propriedades.



Fonte: (FACURE, 2019).

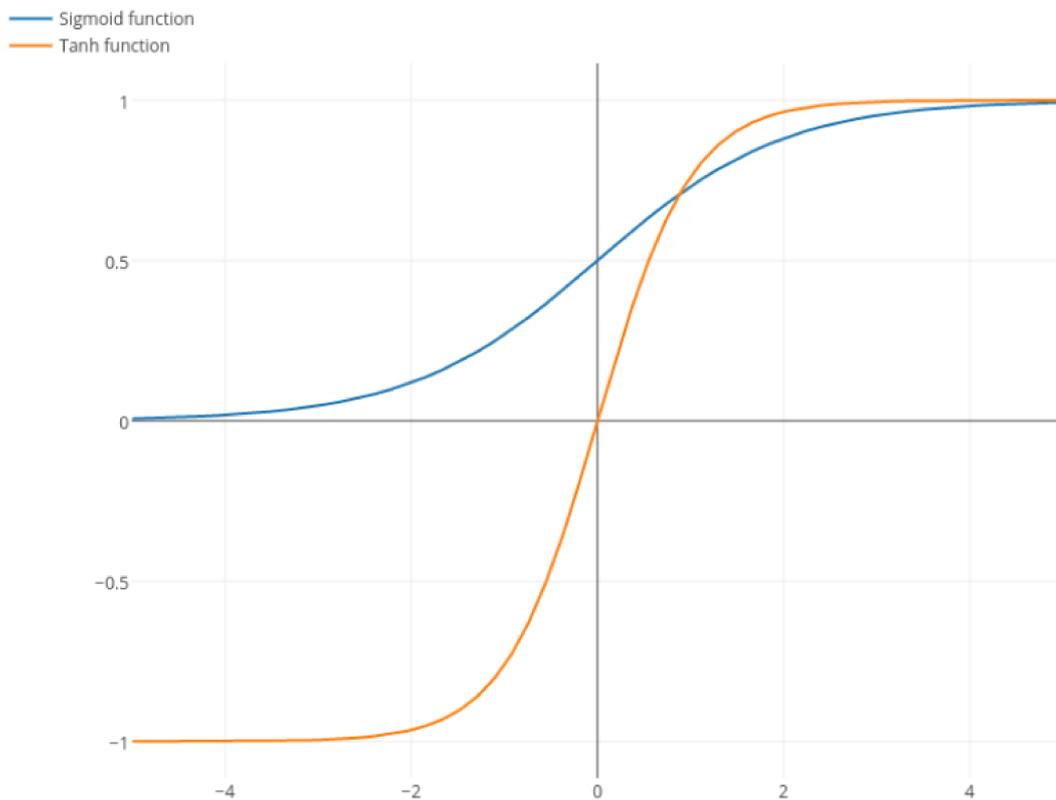
#### 2.2.4 Função Tanh

Todas as propriedades que foram apresentadas na subseção 2.2.3 ainda são válidas nessa função de ativação. Além disso, define-se a função matematicamente como o apresentado na equação (2.4).

$$f(x_i) = \frac{2}{1 + e^{-x_i}} - 1 \quad (2.4)$$

No entanto, ao se observar a Figura 9 nota-se a diferença básica entre as duas funções de ativação. Como nem sempre é desejável que as saídas de um neurônio de uma camada interna tenham um mesmo sinal, é importante uma simetria em relação a origem e esse adicional que a função tanh tem em relação a função sigmoide.

Figura 9 – Função Sigmoide x Função Tanh.



Fonte: (BHARDWAJ, 2019).

### 2.2.5 Função ReLU

A função unidade linear retificada definida através da equação (2.5) é a mais utilizada nas aplicações na atualidade. Uma das principais vantagens dessa função de ativação é que ela não ativa todos os neurônios ao mesmo tempo. Esse comportamento tem impacto direto no tempo gasto para o processo de aprendizagem. Para ilustrar, se hipoteticamente a entrada da função de ativação for menor que zero, a saída da função *relu* é nula e esse neurônio em questão não é ativado. Dessa forma, a RNA se torna esparsa e a eficiência computacional global aumenta de forma exponencial. Vale também dizer que apesar de ser uma das funções de ativação mais utilizadas, na maior parte das aplicações a função *relu* é usada em camadas ocultas e não nas extremidades da RNA.

$$f(x_i) = \max(0, x_i) \quad (2.5)$$

### 2.2.6 Função Softmax

A função de ativação *softmax* é geralmente utilizada em problemas de classificação e é definida através da equação (2.6).

$$f(x_i) = \frac{e^{x_i}}{\sum_{i=1}^K e^{x_i}} \quad (2.6)$$

Em que:

$K$  Número total de neurônios.

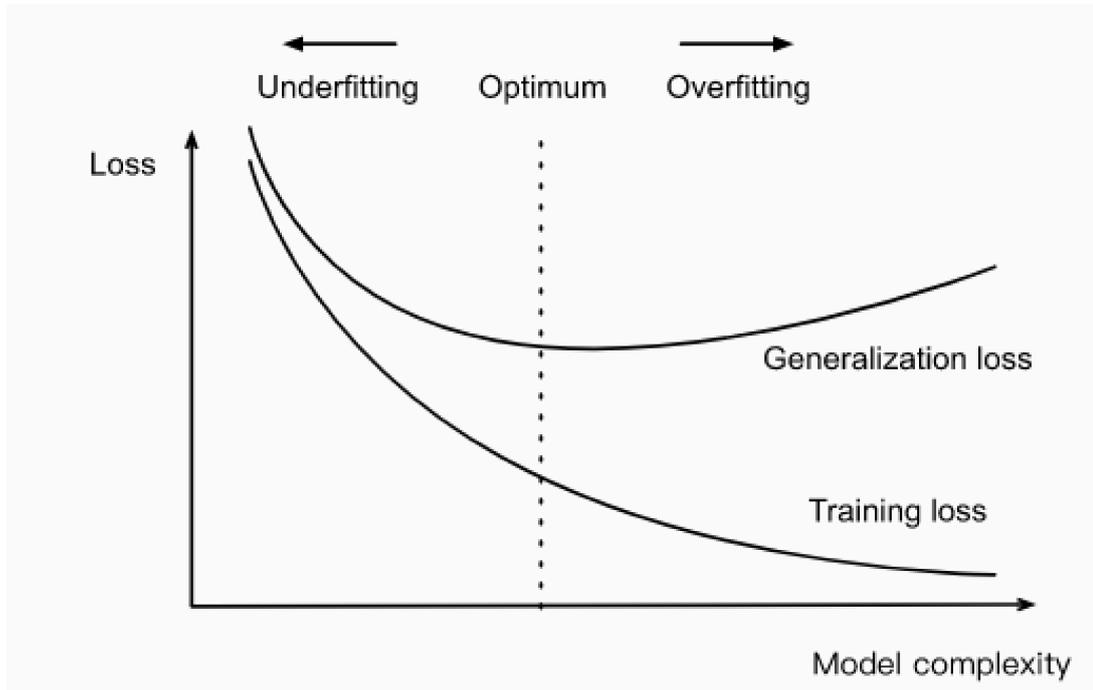
Ao se analisar a equação (2.6), nota-se que uma saída é dependente de todas as outras. Além disso, basicamente na (2.6) ocorre a transformação da entrada para valores entre 0 e 1 e a divisão dessa etapa pela soma de todas as entradas da função, assim, pode-se interpretar cada resposta da função *softmax* como probabilidade de uma entrada pertencer a uma classe em específico. Dessa forma, nota-se que esse tipo de função é aplicado geralmente a problemas de classificação onde se pode obter a probabilidade para diferenciar as classes de cada *input* do neurônio.

## 2.3 FUNÇÕES DE PERDA

O problema de treinamento de uma rede neural artificial se aproxima de um problema de otimização onde se deseja encontrar pesos sinápticos e bias ótimos que minimizem o erro calculado através de uma função de perda. Essa função basicamente calcula qual é o erro entre a saída da RNA e o que se espera no conjunto de treinamento. Dessa forma, pode-se medir de forma eficiente a qualidade do treinamento e encontrar problemas que possam ocorrer durante essa importante etapa. Para ilustrar pode-se observar a Figura 10 onde ocorre um problema denominado *overfitting*. Geralmente esse problema ocorre quando se modela a RNA com um número excessivo de neurônios na camada oculta. Assim, a rede neural artificial deixa de aprender durante o processo de treinamento e torna-se especialista no conjunto de treinamento. Assim, se novos dados, diferentes dos usados na etapa de treinamento, forem apresentados ao modelo seu desempenho será insatisfatório, ou seja, a RNA perde sua capacidade de generalização. Por outro lado, outro problema um pouco menos comum é a falta de ajuste do modelo aos dados durante o processo de treinamento, denominado *underfitting*. Esse problema é mostrado na Figura 10 e ocorre basicamente quando não se escolhe um número épocas ideal que permita o treinamento ajustado da RNA aos dados. Além disso, esse fenômeno também pode ocorrer se o número de neurônios na camada oculta não for o suficiente para o treinamento do modelo, dessa forma, o modelo não é capaz de capturar padrões nos dados e assim perde a capacidade de generalização. Geralmente, quando ocorre *overfitting* uma saída é diminuir o número de épocas do treinamento evitando assim o ajuste excessivo

ao conjunto de treinamento. Assim, para acompanhar o processo de aprendizagem e garantir que não ocorra falta de ajuste durante a redução do número de épocas utiliza-se a validação cruzada. Métodos de otimização como AG podem ser utilizados com o objetivo de encontrar os parâmetros ótimos para a RNA para que não ocorra fenômenos como *overfitting* e *underfitting*. Dessa forma é importante a função de custo para monitorar esses problemas e ajustar melhor a RNA.

Figura 10 – Overfitting x Underfitting.



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

Assim, observa-se que a figura da função de custo é extremamente importante e existem algumas que são utilizadas nas aplicações da atualidade. É importante escolher a função conforme sua aplicação e, dessa forma, garantir a melhor qualidade do treinamento. As principais funções de custo são mostradas nas próximas subseções.

### 2.3.1 Função de Custo Erro médio quadrático

A mais simples das funções utilizadas denomina-se custo quadrático e é definida pela equação (2.7). Geralmente utilizada em problemas de regressão, orienta-se que seja utilizada como primeira abordagem em qualquer problema, alterando-se para outro tipo caso seja necessário.

$$C = \frac{1}{2n} \sum_{i=0}^n ||y(x_i) - y'(x_i)||^2 \quad (2.7)$$

Em que:

- $n$  Número de entradas do treinamento;
- $C$  Custo calculado pela função;
- $y$  Valor real da saída;
- $y'$  Valor da saída.

Um dos problemas dessa função de custo ocorre quando os termos que se quer otimizar da RNA são definidos de forma aleatória para inicializar o processo. Se essa escolha faça com que a função de custo fique muito longe do que se é esperado, as derivadas se tornam muito pequenas e o processo se torna lento (ACADEMY, 2019). Para ilustrar essa ocorrência, na equação (2.7), define-se um número de entradas igual a 1. Além disso, sabe-se que o valor da saída pode ser expandido através da equação (2.8).

$$y'(x_1) = \sigma(wx_1 + b) \quad (2.8)$$

Em que:

- $\sigma$  Função de ativação utilizada;
- $w$  Pesos sinápticos;
- $b$  Bias.

Por fim, define-se que se caso a entrada for 1 a saída deve ser 0. Dessa forma, ao se fazer as derivadas parciais em relação aos pesos sinápticos e ao bias, tem-se as expressões contidas nas equações (2.9) e (2.10).

$$\frac{\partial C}{\partial w} = \sigma(wx_1 + b) \frac{\partial \sigma(wx_1 + b)}{\partial w} \quad (2.9)$$

$$\frac{\partial C}{\partial b} = \sigma(wx_1 + b) \frac{\partial \sigma(wx_1 + b)}{\partial b} \quad (2.10)$$

Considerando a função de ativação sigmoide definida na subseção 2.2.3, observa-se que para valores distantes de 0, que é a nossa saída ideal, a derivada dessa função de ativação se torna cada vez mais próxima de zero. Dessa forma, as expressões (2.9) e (2.10) se tornam pequenas e o processo de treinamento se torna lento ou inviável.

### 2.3.2 Função de Custo Entropia Categórica Cruzada

Primeiramente deve-se entender o que é entropia do ponto de vista da teoria de *Machine Learning* e não um fenômeno físico. O conceito foi desenvolvido por um engenheiro electricista em 1948 que desejava enviar informações com o menor número de bits. Além disso, era uma restrição do problema a não perda de informações durante o processo. De forma qualitativa, pode-se definir como entropia a taxa média de informação produzida num processo estocástico. Assim, como exemplo, considerando o lançamento de uma

moeda viciada com 99% de chance de cair cara e 1% de chance de cair coroa, a taxa de informação pode ser calculada para as duas situações através da expressão (2.11). Assim, para o caso da cara, o resultado seria 0.0144 bits. Por outro lado, no caso da coroa a taxa de informação seria 6.64 bits. O resultado é o esperado porque o fenômeno de lançamento de moeda ser coroa é menos provável nessa ocasião, dessa forma, quando ocorre fornece mais informação (THOMAS, 2019).

$$T = -\log_2(P(i)) \quad (2.11)$$

Em que:

$T$  Taxa de informação;  
 $P(i)$  Probabilidade do evento  $i$  ocorrer.

No entanto, entropia é a taxa média de informação, dessa forma, deve-se calcular o valor esperado ou médio que é definido através da expressão (2.12) (THOMAS, 2019).

$$E = -\sum_{i=1}^n P(i) \log_2(P(i)) \quad (2.12)$$

Em que:

$E$  Entropia.

Considerando a aplicação em que se necessita a classificação de várias classes que é a situação em que é mais utilizada essa função de custo futuro. Além disso, se a função de ativação *softmax* for utilizada a saída da última camada será a probabilidade de se pertencer a determinada classe, dessa forma, substituindo essa informação na expressão (2.12), tem-se a equação (2.13).

$$E = -\sum_{i=1}^n y(x_i) \log_2(y(x_i)) \quad (2.13)$$

No entanto, do ponto de vista de *Machine Learning* para o treinamento da RNA, deve-se ter uma função de custo que compare o real do previsto. Dessa forma, define-se a função de custo entropia cruzada que tem a forma da equação (2.14) (CODE, 2019). Assim, observando a equação (2.14), nota-se que idealmente o termo dentro do logaritmo seria  $y(x_i)$ , no entanto, como é um processo de treinamento e há um erro e o valor previsto foi  $y'(x_i)$  que se comparado com o ideal fornecerá um erro.

$$C = -\sum_{i=1}^n y(x_i) \log_2(y'(x_i)) \quad (2.14)$$

Assim, a função de custo entropia categórica cruzada deve ser utilizada para problemas de diversas classes onde todas elas são independentes entre si. Geralmente se utiliza em conjunto na última camada da RNA uma função de ativação *softmax*, assim, como essa função de ativação possui soma igual a 1, se a probabilidade de uma classe aumentar as restantes devem necessariamente diminuir, facilitando o processo de treinamento e aumentando a eficiência da rede neural artificial.

### 2.3.3 Função de Custo de Entropia Binária Cruzada

No caso do problema de duas classes, tem-se uma situação particular da função de custo de entropia categórica cruzada. Nesse caso, é verdade a expressão

$$y(x_1) = 1 - y(x_2) \quad (2.15)$$

Assim, a expressão (2.14), após simplificações torna-se igual a (2.16).

$$C = -y(x_1) \log_2(y'(x_1)) - (1 - y(x_1)) \log_2(1 - y'(x_1)) \quad (2.16)$$

De forma a comprovar a vantagem das função de custo futuro de entropia cruzada em relação a função de erro quadrático médio, primeiramente deve-se derivar a expressão (2.16) em relação aos pesos sinápticos e ao bias. Além disso, deve-se levar em conta a equação (2.8) e definir como função de ativação para essa explanação a sigmoide, assim, chega-se a expressão (2.17) de derivada em relação aos pesos sinápticos (ACADEMY, 2019).

$$\frac{\partial C}{\partial w} = x_i(\sigma(wx_i + b) - y(x_1)) \quad (2.17)$$

Dessa forma, ao se observar a expressão (2.17) nota-se que a derivada é controlada basicamente pelo termo  $\sigma(wx_i + b) - y(x_1)$  que nada mais é que o erro. Assim, quanto maior o erro, maior é a derivada o que aumentando a velocidade de aprendizagem. Assim, observa-se a vantagem desse métodos de entropia cruzada em relação ao de erro quadrático médio. A aplicabilidade da função de custo de entropia binária cruzada é diversa, no entanto, pode-se citar como problemas principais aqueles em que se tenha duas classes independentes apenas ou problemas denominados *multi-label* como por exemplo a identificação de objetos numa foto.

## 2.4 OTIMIZADORES

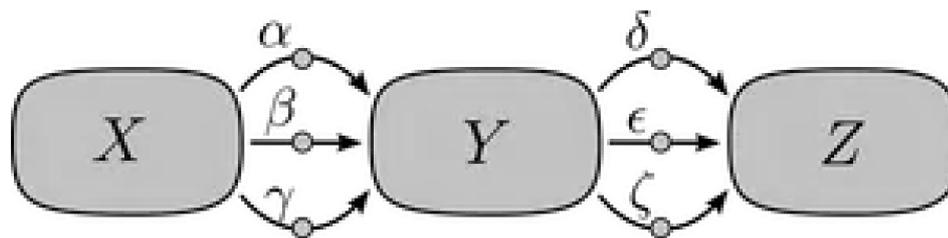
Definida a função de custo que serve para verificar o andamento e qualidade do treinamento, além de ser importante na atualização dos componentes da RNA a cada época. O próximo passo é encontrar um ponto de mínimo da função de custo para que se observe

saídas bem próximas do que se espera, como consequência, quando se otimiza a função de custo encontra-se os melhores pesos sinápticos e bias possíveis da RNA. Dessa forma, se ocorreu um processo de aprendizagem de qualidade e problemas como os relatados em 2.3 não ocorreram, a RNA adquiriu poder de generalização e pode ser apresentada a dados de entrada que ainda não teve contato para testar sua eficiência.

Assim, deve-se ter atenção na escolha do otimizador que melhor se enquadre na aplicação que se está trabalhando para garantir os melhores resultados. Além disso, um passo importante no processo dos otimizadores é o cálculo do gradiente que nada mais é que uma derivada que mostra a direção que se encontra o ponto de ótimo da função analisada. No entanto, dependendo da aplicação de RNA estudada, o cálculo do gradiente da forma tradicional se torna inviável e uma metodologia mais eficiente e computacionalmente tratável deve ser aplicada, essa técnica é denominada *backpropagation*.

Para entender o problema, usa-se como exemplo que uma aplicação em que se queira descobrir como uma variável 'z' muda com alguma perturbação em outra variável 'x' como ilustrado na Figura 11.

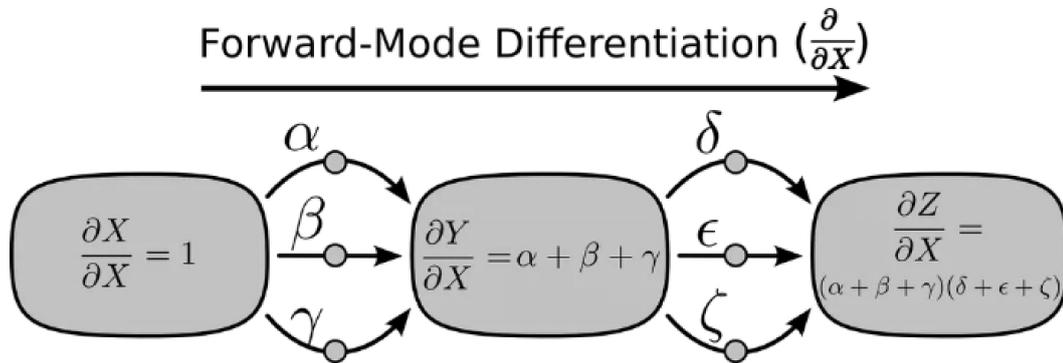
Figura 11 – Exemplo de aplicação.



Fonte: (ACADEMY, 2019).

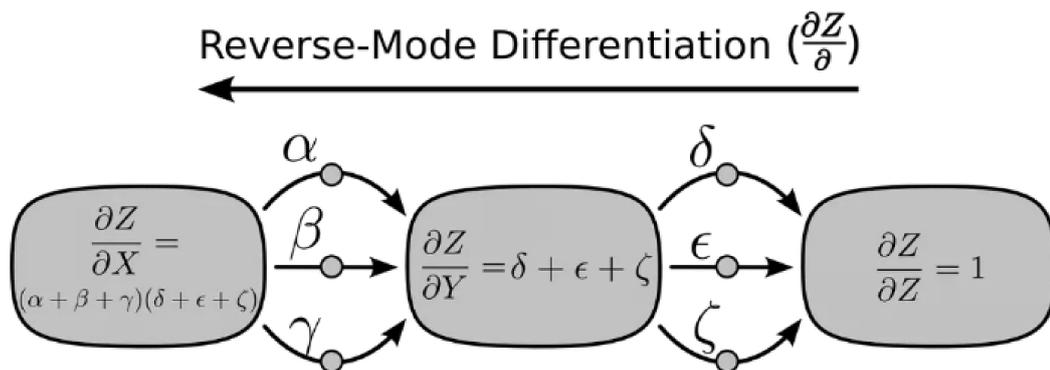
Existem basicamente dois algoritmos que são abordados e apresentados nas Figuras 12 e 13. No modo direto, começa-se em uma entrada do grafo computacional e segue-se em direção ao final. Em cada vértice soma-se todas as entradas daquele ponto, fazendo com que tenha-se como resultado de que forma aquele ponto varia quando uma pequena perturbação é dada na entrada. O mesmo processo ocorre até o final do grafo. Por outro lado, com o algoritmo apresentado na Figura 13 inicia-se a análise do final do grafo até o início parando em cada vértice e somando cada entrada originada desse nó. De forma resumida, no modo direto aplica-se o operador  $\frac{\partial}{\partial x}$  a cada nó. Por outro lado, o segundo método aplica o operador  $\frac{\partial z}{\partial}$  a cada vértice. Esse conceito do modo reverso tem aplicações em diversas áreas, no entanto, em sistemas de potência é notável sua aplicabilidade no planejamento da operação de sistemas hidrotérmicos (SOUZA *et al.*, 2014).

Figura 12 – Modo direto.



Fonte: (ACADEMY, 2019).

Figura 13 – Modo reverso.



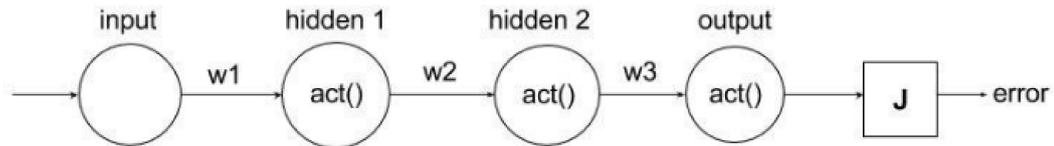
Fonte: (ACADEMY, 2019).

Um fato importante a se observar é que como o modo reverso nos fornece a derivada da nossa saída em relação a qualquer entrada, de forma contrária ao que ocorre do modo direto que calcula apenas a derivada em relação a uma entrada por vez. Assim, em aplicações de RNA com diversos nós, o modo reverso fornece uma metodologia eficiente do ponto de vista computacional para o cálculo do gradiente.

O processo de treinamento de uma RNA é composto basicamente por duas etapas que se repetem até que se tenha uma saída satisfatória. Primeiramente, encontra-se uma maneira de atribuir pesos a cada nó da RNA. Essa escolha interfere diretamente no processo de aprendizagem e nos resultados e há trabalhos que focam exclusivamente nessa parte do processo de aprendizagem. Feito isso, propaga-se a entrada pela RNA efetuando-se multiplicações de vetores e matrizes e aplicando funções de ativação até a saída da RNA. Essa etapa é denominada *Forward Pass*. Feito isso, tem-se uma saída para a RNA que é comparada com o valor real através de uma função de custo e verifica-se se é

satisfatório o resultado. Caso contrário, continua-se o processo de aprendizagem através da etapa que denomina-se *Backpropagation*. Para ilustrar tem-se uma RNA simples na Figura 14 onde  $w_1$ ,  $w_2$  e  $w_3$  representam os pesos sinápticos e  $J$  o erro calculado através de uma função de erro. Assim, utilizando o conceito de *Backpropagation* tem-se a equação (2.18) que calcula o gradiente do erro em relação ao primeiro peso sináptico.

Figura 14 – RNA simples.



Fonte: (ACADEMY, 2019).

$$\frac{\partial error}{\partial w_1} = \frac{\partial error}{\partial output} \times \frac{\partial output}{\partial hidden_2} \times \frac{\partial hidden_2}{\partial hidden_1} \times \frac{\partial hidden_1}{\partial w_1} \quad (2.18)$$

Assim, explicado como funciona o processo de *Backpropagation* que é utilizado para calcular o gradiente na maioria dos otimizadores convexos, pode-se apresentar os que são mais utilizados em diferentes aplicações. Vale salientar que o processo de *Backpropagation* nada mais é que uma forma mais eficiente do ponto de vista computacional para realizar o cálculo dos gradientes que são uma peça fundamental para os otimizadores nas redes neurais artificiais.

#### 2.4.1 Gradiente Descendente

O gradiente descendente consiste basicamente em, após a etapa de *Forward Pass*, calcular a derivada através do processo reverso e atualizar os pesos. A atualização dos pesos é realizada através da (2.19) e repetida até que o critério de parada seja satisfeito.

$$w_{t+1} = w_t - \frac{\partial error}{\partial w_t} \eta \quad (2.19)$$

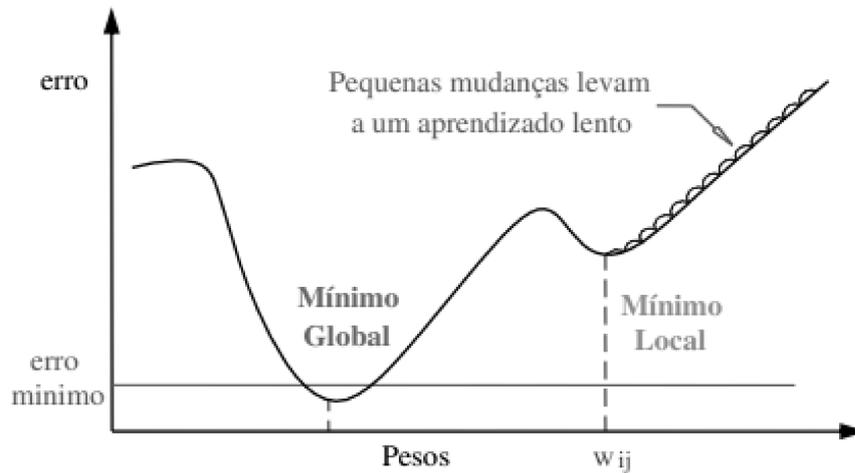
Em que:

- $t$  Iteração;
- $w_t$  Peso sináptico na iteração  $t$ ;
- $\eta$  Taxa de aprendizagem.

A taxa de aprendizagem é um importante fator a ser definido no processo de treinamento da RNA. É um fator que é definido no intervalo entre '0' e '1' e nota-se que a depender do número escolhido problemas podem ocorrer. Primeiramente, se esse número

for pequeno, observa-se que o gradiente descendente pode encontrar um mínimo local e não conseguir se encaminhar até o mínimo global que é o objetivo, como mostrado na Figura 15. Além disso, nota-se que um pequeno valor de  $\eta$ , provoca uma lentidão no processo de treinamento.

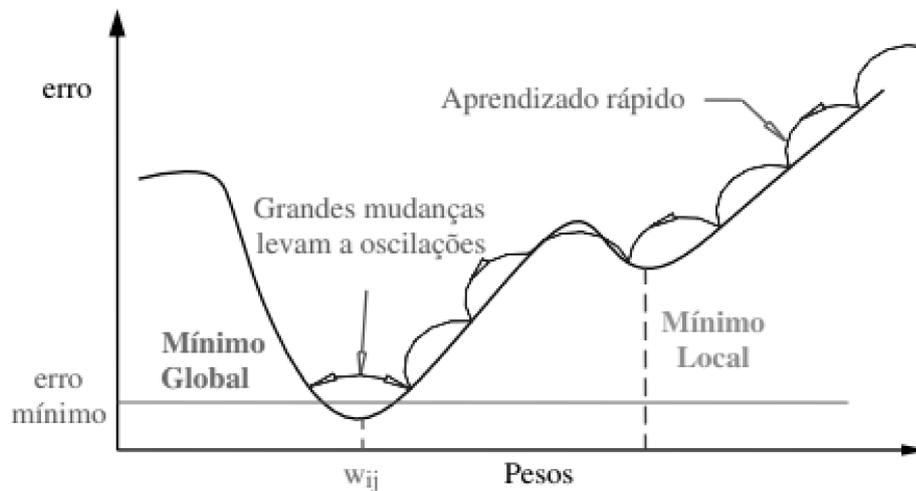
Figura 15 – Taxa de aprendizagem pequena.



Fonte: (SANCHEZ, 2018).

Por outro lado, um  $\eta$  grande o aprendizado é mais rápido, no entanto, pode ocorrer um problema que é mostrado na Figura 16 em que o algoritmo fica variando em torno do mínimo global mas não consegue encontrar esse ponto.

Figura 16 – Taxa de aprendizagem grande.



Fonte: (SANCHEZ, 2018).

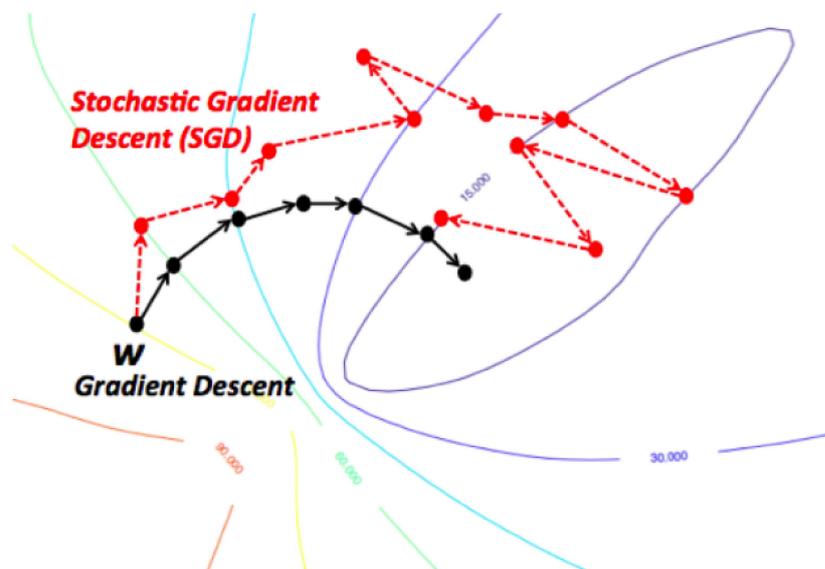
Um problema grave do gradiente descendente fica mais aparente para conjuntos de

treinamento grandes, o que se tornou comum com a era do *Big Data*. Quando o conjunto de treinamento tem um número expressivo de dados, observa-se uma lentidão desacerbada no processo de treinamento. Por exemplo, a base de treinamento de um classificador pode consistir de um banco de dados de imagens que facilmente pode superar *1TB*. Assim, como o gradiente descendente depende de todas as amostras do conjunto de treinamento, há uma limitação computacional de memória no processo de treinamento da RNA.

#### 2.4.2 Gradiente Descendente Estocástico

Com intuito de melhorar o desempenho computacional da RNA durante o processo de treinamento, criou-se esse otimizador que é bem semelhante ao gradiente descendente. No otimizador apresentado na subseção 2.4.1, a cada época utiliza-se todas as amostras de treinamento e calcula-se o erro acumulado através de uma função de custo. A partir daí realiza-se o processo reverso e atualiza-se os pesos da RNA. Assim, nota-se que a cada iteração todas as amostras do treinamento são necessárias o que impacta diretamente no tempo de treinamento e na eficiência computacional. De forma contrária, o gradiente descendente estocástico seleciona uma amostra aleatória do conjunto de treinamento e o que era feito com todas as instâncias do conjunto é realizado com apenas uma amostra reduzindo assim o tempo de aprendizagem (PONTI; COSTA, 2018). Um dos problemas do gradiente descendente estocástico é que como escolhe-se amostras aleatórias do conjunto de treinamento e não o conjunto inteiro, tem-se uma aproximação grosseira e o processo de convergência da RNA não é suave como ocorre no gradiente descendente como é mostrado na Figura 17. Assim, a depender da taxa de aprendizagem, pode-se observar que o algoritmo não chega a um mínimo global como é o objetivo.

Figura 17 – Gradiente Descendente x Gradiente Descendente Estocástico.



Fonte: (JUANKBOARDS, 2019).

### 2.4.3 Gradiente Descendente Estocástico com Momentum

Sabe-se que a atualização do gradiente descendente estocástico segue o que é descrito na equação (2.19). No entanto, observa-se que a atualização dos pesos é dependente apenas da derivada e da taxa de aprendizagem, assim, pode-se ocorrer que o otimizador encontre um ponto de mínimo ou de sela como mostrado na Figura 15. Assim, para evitar tais problemas, adiciona-se um termo denominado *Momentum* que é multiplicado por um fator  $\rho$ . Dessa forma, evita-se mínimos locais porque ao decorrer do processo de treinamento o otimizador acumula *momentum* que faz com ele transponha esses obstáculos. O fator  $\rho$  serve apenas para diminuir um pouco o crescimento do *momentum*. A atualização dos pesos é definida através das equações (2.20) e (2.21).

$$g_{t+1} = \rho g_t - \frac{\partial error}{\partial w_t} \eta \quad (2.20)$$

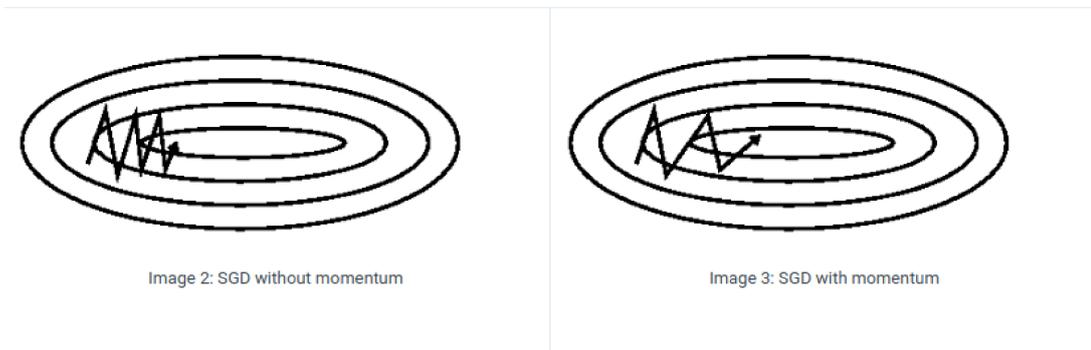
$$w_{t+1} = w_t - g_{t+1} \quad (2.21)$$

Em que:

- $g_t$  *Momentum* na iteração  $t$ ;
- $\rho$  Fator de frenagem.

Na Figura 18 mostra-se como o termo *momentum* interfere diretamente na velocidade de convergência e na suavidade do processo de treinamento. Esses aspectos influenciam diretamente na eficiência computacional que é um objetivo a ser alcançado.

Figura 18 – Sem *Momentum* x Com *Momentum*.



Fonte: (RUDER, 2016).

### 2.4.4 AdaGrad

Até agora, a taxa de aprendizagem era a mesma para todas as atualizações dos pesos sinápticos. No entanto, observa-se que essa não é uma boa decisão do ponto de vista

do processo de aprendizagem (ROMAGUERA, 2017). Assim, tem-se o otimizador que é apresentado nas equações (2.22) e (2.23)

$$v_t^i = v_{t-1}^i + \left( \frac{\partial error}{\partial w_t^i} \right)^2 \quad (2.22)$$

$$w_{t+1}^i = w_t^i - \frac{\eta}{\sqrt{v_t^i + \varepsilon}} \frac{\partial error}{\partial w_t^i} \quad (2.23)$$

Em que:

- $v_t^i$  Média móvel do gradiente ao quadrado na iteração t do neurônio i;
- $w_t^i$  Peso na iteração t do neurônio i;
- $\varepsilon$  Constante para evitar denominador igual a zero.

Observa-se na equação (2.22) um acumulador de gradientes. Dessa forma, se um recurso é muito frequente, ao verificar conjuntamente as equações (2.22) e (2.23), tem-se taxas de aprendizado baixas. Por outro lado, se os recursos ocorrem em pequenas frequências, tem-se altas taxas de aprendizagem. Além disso, observa-se que com esse otimizador foge-se de mínimos locais porque quando tem-se um baixo gradiente observa-se que a taxa de aprendizagem torna-se grande o que provoca a saída do processo de aprendizagem daquele mínimo local auxiliando no processo de aprendizagem. No entanto, observa-se que o algoritmo diminui agressivamente a taxa de aprendizagem para um denominador grande, assim, após algumas épocas os parâmetros que mais aparecem terão incrementos bem pequenos dificultando o processo de aprendizagem.

#### 2.4.5 RMSProp

Visando corrigir o problema do otimizador *AdaGrad*, procura-se reduzir o incremento de  $v_t^i$  de forma a diminuir a consequência da baixa taxa de aprendizagem para parâmetros frequentes. Para isso, adiciona-se um fator de frenagem  $\beta$  que é apresentado nas equações (2.24) e (2.25) a atualização do método.

$$v_t^i = \beta v_{t-1}^i + (1 - \beta) \left( \frac{\partial error}{\partial w_t^i} \right)^2 \quad (2.24)$$

$$w_{t+1}^i = w_t^i - \frac{\eta}{\sqrt{v_t^i + \varepsilon}} \frac{\partial error}{\partial w_t^i} \quad (2.25)$$

Em que:

- $\beta$  Fator de frenagem.

### 2.4.6 Adam

*Adam* é um acrônimo de *adaptive moment estimation* e surgiu como uma junção dos métodos apresentados anteriormente. De forma semelhante ao gradiente descendente estocástico com *momentum* o *Adam* não depende do gradiente somente no momento atual. Assim, tem-se uma espécie de memória que auxilia o otimizador a fugir dos mínimos locais. Primeiramente proposto por (KINGMA; BA, 2014), de forma semelhante ao *RMSProp* tem-se uma média cumulativa dos gradientes ao quadrado. Além disso, armazena-se também uma média semelhante dos gradientes. Por fim, para evitar o problema com os recursos mais frequentes adiciona-se um fator de frenagem nas equações, evitando que parâmetros que mais ocorrem tenham taxa de aprendizado muito baixo nas épocas finais. A atualização do método é apresentada nas equações (2.26) - (2.30).

$$m_t^i = \beta_1 m_{t-1}^i + (1 - \beta_1) \left( \frac{\partial error}{\partial w_t^i} \right) \quad (2.26)$$

$$v_t^i = \beta_2 v_{t-1}^i + (1 - \beta_2) \left( \frac{\partial error}{\partial w_t^i} \right)^2 \quad (2.27)$$

$$\hat{m}_t^i = \frac{m_t^i}{1 - \beta_1^t} \quad (2.28)$$

$$\hat{v}_t^i = \frac{v_t^i}{1 - \beta_2^t} \quad (2.29)$$

$$w_{t+1}^i = w_t^i - \frac{\eta}{\sqrt{\hat{v}_t^i + \epsilon}} \hat{m}_t^i \quad (2.30)$$

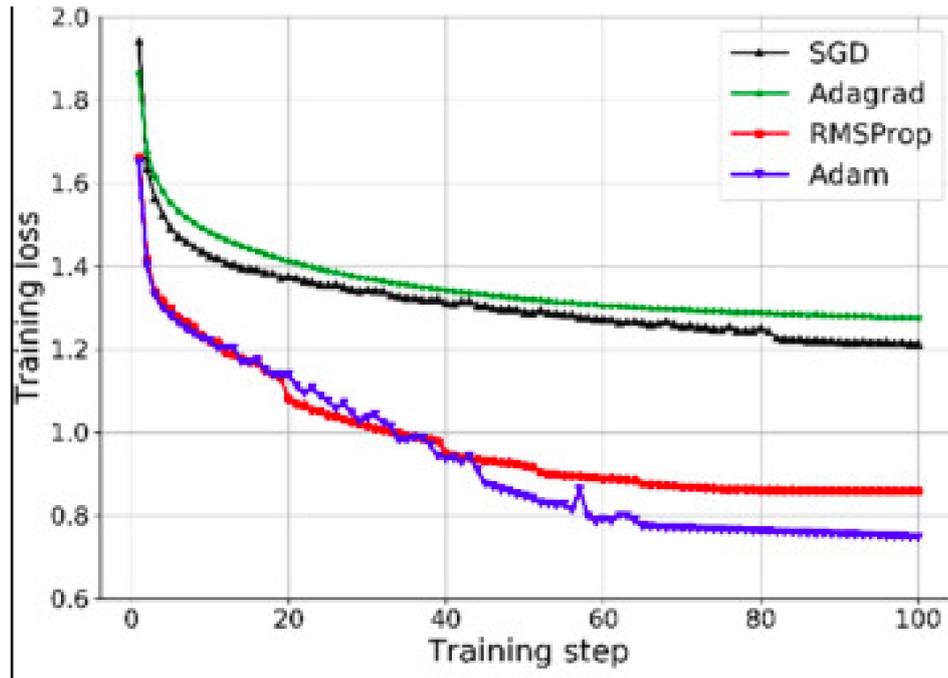
Em que:

- $\beta_1^t$  Primeiro fator de frenagem elevado à iteração t;
- $\beta_2^t$  Segundo fator de frenagem elevado à iteração t;
- $m_t^i$  Média móvel do gradiente na iteração t do neurônio i;
- $\hat{m}_t^i$  Média móvel do gradiente corrigida na iteração t do neurônio i
- $\hat{v}_t^i$  Média móvel do gradiente ao quadrado corrigida na iteração t do neurônio i.

Observa-se que as equações (2.28) e (2.29) apresentam uma correção de viés. Essa correção é necessária porque,  $m_t^i$  e  $v_t^i$  são iniciados como vetores de zero e, dessa forma, nota-se que no início do processo ocorre uma tendência desses valores continuarem iguais a zero, o que não é viável já que eles que permitem a convergência do método. Por fim, tem-se na Figura 19 a comparação entre alguns métodos de otimização apresentados até aqui. Nota-se que geralmente o otimizador *Adam* é a melhor escolha na maioria das aplicações. No entanto, há diversas pesquisas que estão sendo feitas na fronteira do conhecimento que mostram que esse algoritmo de otimização tem um desempenho pior que o gradiente

descendente estocástico com *momentum*, como por exemplo na classificação de imagens. Em (KESKAR; SOCHER, 2017), os autores conseguiram melhorar a performance do otimizador através da estratégia de começar o processo de aprendizagem com o otimizador *Adam* e após um critério especificado ser atingido mudar para o gradiente descendente. Observou-se um desempenho semelhante ao obtido com o gradiente descendente estocástico com *momentum*.

Figura 19 – Comparação entre otimizadores.



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

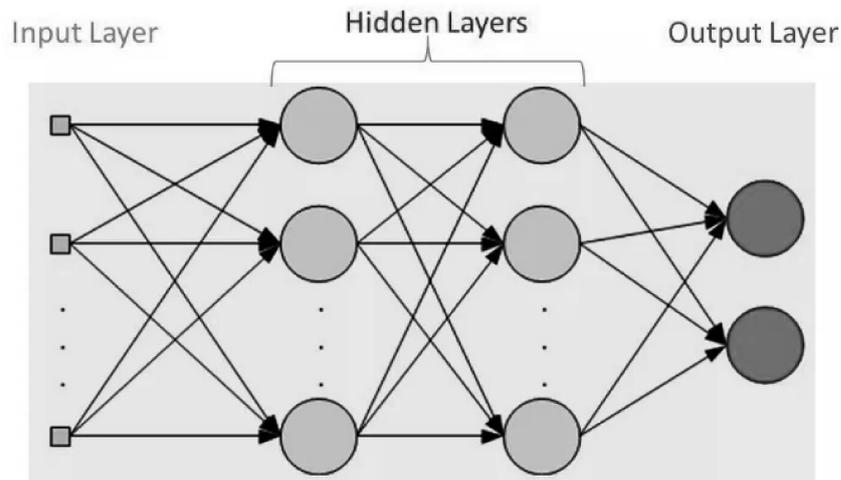
## 2.5 ARQUITETURAS DE REDES NEURAIAS

Existem diversas arquiteturas de RNA atualmente e todas foram criadas para atender à um conjunto de aplicações em específico. Basicamente, existem fatores que são comuns a maioria das arquiteturas que existem na atualidade. A primeira estrutura de todas as RNA é a camada de entrada que é onde a estrutura recebe os *inputs* do mundo exterior. Pode-se fazer uma analogia com os sensores biológicos presentes nos seres humanos, como por exemplo, a visão. Logo após, tem-se a camada oculta que é onde ocorre todo o processo de generalização da RNA. Salienta-se que se houver mais de uma camada oculta, essa RNA é denominada uma rede de aprendizagem profunda, assunto que tem revolucionado o mundo com sua alta aplicabilidade e enorme eficiência. Por fim, tem-se a camada de saída que é a resposta da RNA à entrada que foi estimulada. Em um classificador, tem-se como saída a que classe pertence aquele conjunto de entradas que a RNA foi exposta. Como já dito, à depender da aplicabilidade deve-se escolher

uma arquitetura que melhor se encaixe ao problema, assim tem-se alguns exemplos de topologias nessa seção.

**Redes Multilayer Perceptron** Um Perceptron é uma RNA simples com apenas uma camada que é destinada a classificação binária. Na época que foi criado foi uma revolução para a história das redes neurais artificiais, no entanto, com o tempo caiu em desuso provocando a época conhecida como inverno da inteligência artificial. Observa-se que apesar de ter revolucionado na época, um dos maiores problemas do Perceptron é que não consegue-se modelar a maioria dos problemas no mundo real, que são não lineares, um dos fatos que também proporcionaram sua decadência na época. No entanto, percebeu-se que a união de vários Perceptron possui capacidade de generalização para aplicações não lineares, o que retornou o interesse nesse modelo. Um *Multilayer Perceptron* é uma topologia que é formada por uma camada de entrada, camadas ocultas e uma camada de saída como mostrado na Figura 20. Não há recorrência e a entrada de uma camada oculta corresponde a saída de outra num modelo denominado *Feed-Forward*. No seu processo de treinamento usa-se o *backpropagation* em conjunto com um dos otimizadores apresentados na seção 2.4 e avalia-se o erro através de uma função de custo dentre as exibidas na seção 2.3.

Figura 20 – Rede Multilayer Perceptron.

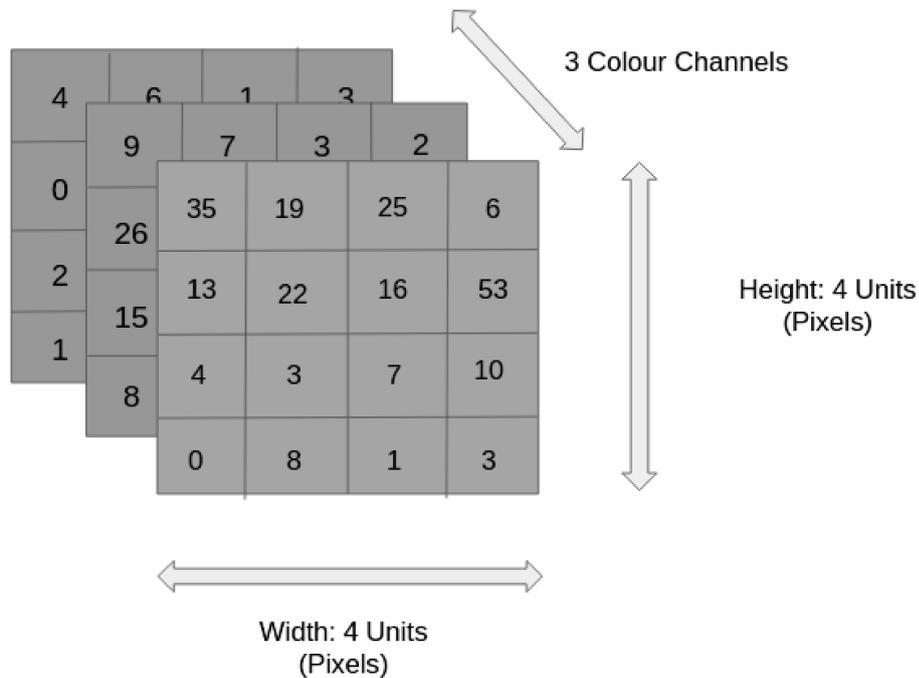


Fonte: (ACADEMY, 2019).

**Redes Neurais Convolucionais** Esse tipo de arquitetura de rede neural artificial revolucionou a aplicação em processamento de padrões e imagens. Observa-se que esse tipo de RNA pode ser aplicada a diversos problemas do mundo atual como por exemplo a aplicação em reconhecimento de rostos e identificação de suspeitos como o que ocorreu no carnaval de Salvador no Brasil (SANTOS, 2018). Além disso, uma das aplicações mais famosas dessa arquitetura é o consagrado reconhecimento e marcação de facial que ocorre no *Facebook* (DEMARTINI, 2014). Como essa

arquitetura é especialista em reconhecimento de imagens, observa-se que a entrada dessa topologia deve-se adequar para receber imagens. Assim, uma imagem numa RNA convolucional é entendida como um cubo que tem como altura e largura de acordo com o tamanho da imagem e a profundidade é referente à escala de cores da figura como mostrado na Figura 21.

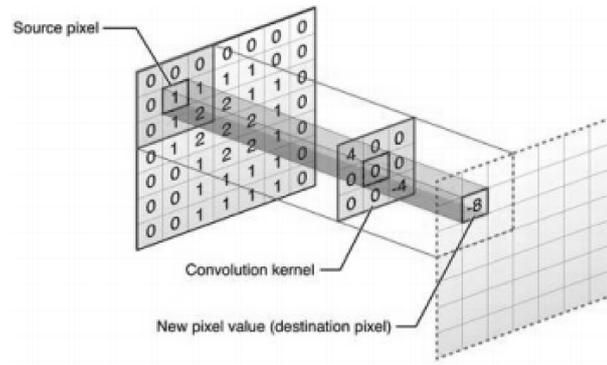
Figura 21 – Entrada de uma Rede Convolucional.



Fonte: (ALVES, 2018).

A base da arquitetura são as convoluções que são operações matemáticas baseadas em álgebra linear que ocorrem após a entrada da RNA como mostrado na Figura 22. Após passar pela entrada e convolução tem-se uma camada denominada *pooling* que tem como principal objetivo reduzir o tamanho das matrizes e assim, diminuir o esforço computacional. Por fim, tem-se uma rede neural clássica que tem como função melhorar a previsão das classes. Observa-se que nessa parte da RNA ocorre o cálculo do erro e o ajuste dos pesos ótimos através do algoritmo de *backpropagation* e algum otimizador baseado no gradiente descendente. Vale salientar que após a saída do processo de *pooling* os dados de treinamento devem passar por um processo denominado *flattening* que transforma a matriz de características em um vetor resultante que serve como entrada para a RNA clássica no fim do processo.

Figura 22 – Convolução.



Fonte: (HOCHULI, 2016).

**Redes Neurais Recorrentes** As RNA recorrentes são um conjunto de topologias responsáveis pelo processamento de áudio e linguagem natural. Sua principal característica que a diferencia das RNA *Feed-Forward* é que na sua topologia a rede neural artificial apresenta uma ou várias estruturas e realimentação. Esses *loops* auxiliam no treinamento de dados sequenciais porque, por exemplo, em linguagem natural se a RNA é apresentada a uma palavra letra por letra, a primeira letra auxilia através do *loops* na previsão da última letra apresentada. Observa-se que o processo de aprendizagem e teste de uma topologia recorrente é dinâmica, ou seja, a RNA possui memória que se modifica a cada passo do treinamento. Dessa forma, a RNA utiliza os dados de entrada em conjunto com essa memória para produzir uma nova classificação e uma nova recordação que será utilizada nos próximos dados de entrada.

Existem diversos outros tipos de topologia, como por exemplo, Redes de Hopfield, Deep Belief Network e Deep Neural Network Capsules. No entanto, aprofundar em topologias de RNA não faz parte do escopo desse trabalho.

## 2.6 MÉTRICAS DE AVALIAÇÃO

Observa-se que após o processo de treinamento e validação da rede neural artificial estudada deve-se apresentá-la a dados de testes que são diferentes dos que ela foi treinada. No entanto, para avaliar a qualidade do treinamento deve-se fundamentar de forma concisa qual é o objetivo da aplicação que se está estudando e assim definir qual é a métrica que melhor se ajusta para avaliação do teste.

### 2.6.1 Matriz Confusão

A base para qualquer métrica de avaliação da aplicação em questão é uma figura de mérito denominada matriz confusão. Observa-se que a matriz confusão é uma tabela que mostra de forma intuitiva a frequência de acerto para cada classe do modelo se a aplicação

for um classificador. Além disso, observa-se que a matriz é dividida em valores preditos e reais e, dessa forma, observa-se a quantidade de acertos e de que forma a RNA esta acertando as classes. Observa-se que com essas informações pode-se inferir interpretações importantes do modelo. Por exemplo, em um classificador que se tenha como objetivo classificar se um paciente esta doente ou não, é importante verificar a matriz de confusão porque pode-se ter algumas métricas de avaliação satisfatórias, no entanto, ao verificar-se a matriz de confusão observa-se que o modelo esta acertando mais casos em que o paciente não esta doente e errando casos que a pessoa está enferma. Assim, é importante um conhecimento prévio das métricas de avaliação e a que melhor se adequa ao modelo para não se ter inferências enganosas. Um exemplo de matriz confusão é mostrado na Tabela 2.

Tabela 2 – Exemplo de matriz confusão

		PREDITO	
		Negativo	Positivo
REAL	Negativo	VN	FP
	Positivo	FN	VP

Fonte: Elaborada pelo autor (2020).

Em que:

- $VN$  Verdadeiro Negativo;
- $VP$  Verdadeiro Positivo;
- $FP$  Falso Positivo;
- $FN$  Falso Negativo.

### 2.6.2 Acurácia

Uma das métricas mais utilizadas nos modelos de RNA é a acurácia. Basicamente, a interpretação qualitativa dessa métrica de avaliação é de todas as amostras de teste que o RNA foi exposto, quantas a rede neural artificial classificou corretamente.

$$Acuracia = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.31)$$

Observa-se que é importante atentar-se para conjuntos desbalanceados no cálculo da acurácia. Por exemplo em casos em que deseja-se classificar uma transação como fraudulenta ou não. Observa-se que o conjunto é desbalanceado porque é sabido que casos de fraudes são incomuns se comparados com todos os casos possíveis. Assim, se hipoteticamente existem 280000 casos legais e 2000 fraudulentos, nota-se que a acurácia seria de 99.3% caso o modelo classifique todos os casos como legais (BORBA, 2019). Assim, observa-se que apesar da acurácia mostrar um bom desempenho para o modelo, observa-se que a RNA falha em detectar fraudes. Na matriz confusão do exemplo de classificação de

fraudes mostrada na Tabela 3 observa-se que uma situação considerada positiva é aquela que ocorreu a fraude, por outro lado, negativo é uma situação legal, ou seja, não ocorre a fraude.

Tabela 3 – Matriz confusão da classificação de fraudes

		PREDITO	
		Negativo	Positivo
REAL	Negativo	280000	0
	Positivo	2000	0

Fonte: Elaborada pelo autor (2020).

Seguindo, tem-se duas métricas de avaliação que mostram qual é o desempenho do classificador para cada classe. Primeiramente, tem-se a sensibilidade mostrada na equação (2.32). Resumidamente, uma interpretação qualitativa dessa métrica é que ela mostra dos exemplos positivos quantos foram classificados corretamente.

$$Sensibilidade = \frac{VP}{VP + FN} \quad (2.32)$$

De forma análoga, tem-se a Especificidade que exibe um número que representa a porcentagem das amostras negativas que foram classificadas corretamente. Essa métrica é mostrada na expressão (2.33).

$$Especificidade = \frac{VN}{VN + FP} \quad (2.33)$$

Assim, para contornar o problema de conjuntos desbalanceados, pode-se definir uma nova métrica denominada Acurácia balanceada que é baseada na sensibilidade e na especificidade e é exibida na expressão (2.34).

$$Acurácia\ balanceada = \frac{1}{2}(Especificidade + Sensibilidade) \quad (2.34)$$

Assim, no exemplo da matriz de confusão mostrada na Tabela 3, a acurácia balanceada calculada através de (2.34) é igual a 25% o que é bem mais compatível com o mostrado na matriz de confusão do exemplo.

### 2.6.3 Precisão

A precisão é uma outra métrica de avaliação da RNA que é comumente utilizada quando se tem um alto custo para os falsos positivos. Em um exemplo hipotético, em situações de análise de exames médicos os classificadores devem, além de tudo, uma alta precisão. Se por acaso um paciente seja classificado com uma doença que não tem,

pode-se iniciar um tratamento não necessário trazendo prejuízos onerosos e para a saúde da pessoa. Por isso, nessas situações os classificadores são extremamente precisos e redundância são adicionadas. No caso da detecção de defeitos em sistemas de distribuição, caso o classificador tenha uma baixa precisão, observa-se que a distribuidora terá prejuízos em mandar um equipe para solucionar um curto-circuito que não existiu. A expressão para a precisão é mostrada na equação (2.35).

$$P = \frac{VP}{VP + FP} \quad (2.35)$$

Em que:

$P$  Precisão.

De forma semelhante ao o que ocorre na acurácia, deve-se atentar para a interpretação do resultado da precisão para conjuntos desequilibrados. Além disso, para problemas com diversas classes, deve-se procurar métricas para apresentar qual o desempenho global da RNA. Assim, pode-se definir a *Micro-average* da precisão através da equação (2.36).

$$Micro - average = \frac{VP_1 + VP_2 + \dots + VP_m}{VP_1 + VP_2 + \dots + VP_m + FP_1 + FP_2 + \dots + FP_m} \quad (2.36)$$

Em que:

$VP_1$  Verdadeiro Positivo da Classe 1;  
 $VP_2$  Verdadeiro Positivo da Classe 2;  
 $VP_m$  Verdadeiro Positivo da Classe m;  
 $FP_1$  Falso Positivo da Classe 1;  
 $FP_2$  Falso Positivo da Classe 2;  
 $FP_m$  Falso Positivo da Classe m;

Por outro lado, a *Macro-average* da precisão tem um caráter mais global e leva em conta a precisão calculada individualmente para cada classe, como mostrado na expressão (2.37).

$$Macro - average = \frac{P_1 + P_2 + \dots + P_m}{m} \quad (2.37)$$

Em que:

$m$  Número de classes;  
 $P_1$  Precisão da Classe 1;  
 $P_2$  Precisão da Classe 2;  
 $P_m$  Precisão da Classe m.

Portanto, considerando que tenha-se um classificador desequilibrado com quatro classes que os resultados são (PYTHIEST, 2017):

**Classe A**  $VP_1 = 1$  e  $FP_1 = 2$

**Classe B**  $VP_2 = 10$  e  $FP_2 = 90$

**Classe C**  $VP_3 = 1$  e  $FP_3 = 1$

**Classe D**  $VP_4 = 1$  e  $FP_4 = 1$

Em que:

$VP_3$  Verdadeiro Positivo da Classe 3;

$VP_4$  Verdadeiro Positivo da Classe 4;

$FP_3$  Falso Positivo da Classe 3;

$FP_4$  Falso Positivo da Classe 4.

Usando as expressões (2.36) e (2.37) pode-se calcular a macro e micro média para essa situação, sendo respectivamente 0.4 e 0.123. Observa-se que as amostras da Classe B são a maioria no conjunto de teste, no entanto, utilizando a expressão (2.35) nota-se que sua precisão é de apenas 0.1. Por outro lado, as outras classes tem uma precisão igual a 0.5. Assim, verifica-se que a *Macro-average* apresenta um resultado enganoso porque as classes que tem precisão igual a 0.5 aumentam a precisão global, no entanto, os dados mais representativos estão na Classe B que tem uma precisão baixa. Por outro lado, nota-se que *Micro-average* é sensível a essa baixa precisão do conjunto de dados que tem o maior número de amostras, dessa forma, na maioria das aplicações com classes desbalanceadas utiliza-se a micro média (PYTHIEST, 2017).

#### 2.6.4 Recall

De forma semelhante a precisão, tem-se o *Recall*. Essa métrica deve ser selecionada quando se tem um alto custo dos falsos negativos, como foi o exemplo das transações fraudulentas anteriormente abordado. Observa-se que uma transação fraudulenta real for predita como não fraudulenta, as consequências para a instituição financeira podem ser muito sérias. Outro exemplo seria no caso em que se usa dados geológicos para prever o rompimento de uma barragem através de uma rede neural artificial. Se hipoteticamente a rede classificar uma situação de emergência que necessita de evacuação como uma situação normal, os danos para a população serão catastróficos. A métrica *Recall* é apresentada na equação (2.38). Qualitativamente o *recall* informa a quantidade de acertos o modelo teve daquelas amostras que realmente pertenciam a uma classe em específico.

$$R = \frac{VP}{VP + FN} \quad (2.38)$$

Em que:

$R$  Recall.

Além disso, uma discussão semelhante ao o que ocorreu na precisão para encontrar uma métrica global para um modelo com diversas classes pode ser realizada para o *Recall*. As equações da *Micro-average* e *Macro-average* são apresentadas nas expressões (2.39) e (2.40) respectivamente.

$$\text{Micro - average} = \frac{VP_1 + VP_2 + \dots + VP_m}{VP_1 + VP_2 + \dots + VP_m + FN_1 + FN_2 + \dots + FN_m} \quad (2.39)$$

Em que:

$FN_1$  Falso Negativo da Classe 1;  
 $FN_2$  Falso Negativo da Classe 2;  
 $FN_m$  Falso Negativo da Classe m.

$$\text{Macro - average} = \frac{R_1 + R_2 + \dots + R_m}{m} \quad (2.40)$$

Em que:

$R_1$  Recall da Classe 1;  
 $R_2$  Recall da Classe 2;  
 $R_m$  Recall da Classe m;

### 2.6.5 F1

Por fim, tem-se uma métrica que apresenta uma junção entre precisão e *recall*. O F1 é importante e substitui a acurácia quando se tem dados do conjunto de teste desequilibrados. Além disso, para todas as aplicações essa métrica de avaliação fornece uma forma de avaliar conjuntamente a precisão e o *recall* através de um único número, o que é vantajoso para problemas com diversas classes. Vale salientar que pela equação (2.41) observa-se que o F1 é uma métrica que é mais afetada pelos baixos valores, assim, valores pequenos de precisão ou *recall* irão fazer com que o F1 diminua.

$$F1 = 2 \frac{P \times R}{P + R} \quad (2.41)$$

### 3 VEÍCULOS ELÉTRICOS

Neste capítulo é feita uma retomada histórica sobre veículos elétricos. Além disso, pontua-se as principais características dos tipos de recarga mais importantes da atualidade. Por fim, pontua-se os impactos conhecidos dos VE no sistema de distribuição.

#### 3.1 HISTÓRIA DOS VEÍCULOS ELÉTRICOS

A história dos veículos elétricos apresenta uma dependência profunda com o desenvolvimento das tecnologias de armazenamento de energia elétrica, afinal, esse é um dos componentes mais importantes do VE. Observa-se que as primeiras baterias utilizadas em veículos elétricos tinham como componentes químicos chumbo e ácido e foram desenvolvidas em 1859 por Gaston Planté (BARAN; LEGEY, 2011). Nota-se que as tecnologias e fábricas de veículos elétricos eram comuns na época, no entanto, a dificuldade para recarga da bateria do veículo elétrico e sua baixa autonomia fizeram arrefecer um pouco o ímpeto pelo desenvolvimento da tecnologia. Além disso, em 1885 testou-se e teve sucesso no grande rival do VE que é o motor de combustão interna. Apesar da grande concorrência e os entraves proporcionados pela baixa duração ou custo elevado das tecnologias de armazenamento, entre os anos de 1890 e 1900 duas tecnologias aumentaram de forma considerável o desempenho geral dos veículos elétricos, a frenagem regenerativa e o sistema híbrido. A primeira refere-se a capacidade do veículo elétrico de transformar energia cinética em energia elétrica através dos freios. Dessa forma, pode-se recarregar as baterias mesmo durante o uso do VE. A outra, observou-se que os veículos movidos a motores à gasolina tinha uma autonomia e um preço acessível em relação ao VE. Além disso, a baixa autonomia das baterias em junção da falta de infraestrutura da rede de distribuição da época provocou o desenvolvimento de um sistema que compartilhava as vantagens do VE e do motor movido a gasolina. Apesar das desvantagens, pode-se citar que em 1899 construiu-se um veículo elétrico capaz de atingir a velocidade de  $100\text{Km/h}$ , o que para época era uma velocidade sem precedentes. Além disso, no Brasil a tecnologia também foi utilizada em uma frota de ônibus no Rio de Janeiro, onde a mídia da época salientou o baixo ruído e o conforto da tecnologia movida a eletricidade. No entanto, os VE não foram capazes de superar os motores movidos a gasolina. Observa-se que em Nova York no ano de 1912 a frota de VE era de 30 mil unidades, no entanto, a frota de veículos movidos a gasolina era 30 vezes maior (STRUBEN; STERMAN, 2008). Diversos fatores provocaram o crescimento dos veículos movidos a gasolina na época, no entanto, pode-se citar, i) capacidade de produção em grande quantidade e com baixo preço; ii) crescimento das rodovias de grande porte e, dessa forma, necessidade de maior autonomia; iii) descoberta do petróleo no Texas reduziu o preço da gasolina (BARAN; LEGEY, 2011).

O interesse pelos VE só teve início novamente na década de 1960 quando questões

ambientais começaram a preocupar a população mundial. Nessa época ainda se tinha como componente da gasolina o chumbo e não existia catalisadores ou filtros para diminuir os impactos ambientais causados pela combustão interna dos motores movidos a gasolina. Além disso, nessa mesma época ocorreram crises no setor de petróleo o que provocou o aumento dos combustíveis aumentando mais ainda o interesse por VE. No Brasil, esse novo interesse foi reafirmada pela produção do primeiro veículo elétrico nacional produzido por uma empresa que já fechou as portas, GURGEL S.A. Furnas Centrais Elétricas S.A. O VE era denominado Gurgel e tinha uma potência equivalente de  $3.2kW$  e alimentado por 10 baterias.

Figura 23 – Gurgel.



Fonte: (CARROBRASIL, 2019).

Apesar do declínio dos combustíveis fósseis nessa época, o VE não foi capaz de firmar sua posição porque ainda não possuía uma tecnologia de armazenamento de energia elétrica eficiente, além disso, a infraestrutura do sistema de distribuição da época não fornecia recursos necessários para uma recarga eficiente.

No entanto, a partir da década de 90 cresceu a preocupação com o meio ambiente e com os impactos dos combustíveis fósseis nas alterações do clima e na saúde dos seres humanos com a poluição causada pela queima completa ou incompleta dos derivados do petróleo. Um estudo feito pelo congresso dos EUA fez uma estimativa que os danos causados à qualidade do ar pelos derivados do petróleo usados no transporte público chegariam a uma ordem de 256 bilhões de dólares (PERES; HORTA; LAMBERT-TORRES, 2002).

Também em 1992 ocorreu a Conferência das Nações Unidas sobre o Meio Ambiente e o Desenvolvimento no Rio de Janeiro que um dos temas discutidos foi a introdução dos veículos híbridos para a redução das emissões de dióxido de carbono global. O desenvolvimento dos veículos elétricos a partir daí só cresceu e nessa história de crescimento pode-se citar duas ações tomadas pelo governo dos EUA que alavancaram ainda mais o interesse pelo assunto. Pensando em diminuir a dependência do país pelo petróleo produzido em sua maioria no Oriente Médio o governo americano instituiu o *Energy Independence and Security Act* que destina 95 milhões de dólares anuais a pesquisa no desenvolvimento de tecnologias para os veículos elétricos e na capacitação de pessoas para atuar no setor (BARAN; LEGEY, 2011). Outra medida importante que foi um marco para o desenvolvimento dos veículos elétricos ocorreu em 2009 com a promulgação da Lei *American Clean Energy and Security Act*. O documento versava que todas as distribuidoras do país deveriam apresentar planos para o desenvolvimento de redes inteligentes com a inclusão de VE até 2012 (BARAN; LEGEY, 2011).

Em 2019 o estado da arte dos veículos elétricos é a picape elétrica lançada pela Tesla mostrada na Figura 24. Com uma capacidade de  $250kW$ , cerca de 80 vezes mais capacidade que o nosso Gurgel, o VE pode alcançar a autonomia de  $800km$  e tem previsão de lançamento em 2021 (NAKAGAWA, 2019).

Figura 24 – Tesla Cybertruck.



Fonte: (NAKAGAWA, 2019).

## 3.2 ESTRATÉGIAS DE RECARGA DE VEÍCULOS ELÉTRICOS

Observa-se diversas vantagens dos veículos elétricos em relação aos equipamentos movidos a combustão tradicional. Além do fato da preocupação com o meio ambiente devido a alta taxa de emissão de poluentes na atmosfera dos veículos tradicionais, nota-se que os VE apresentam um menor nível de complexidade na manutenção. No entanto, salienta-se que para isso deve-se investir na mão de obra especializada para a manutenção de VE. Além disso, observa-se também uma maior eficiência, que geralmente ultrapassa a marca de 90% nos VE. Por fim, sabe-se também que o nível de ruído e vibração é baixo em relação aos veículos movidos a combustíveis tradicionais. Esse fato trás um maior conforto e bem estar para o usuário que é traduzido em uma maior qualidade de vida. Apesar de todas essas vantagens deve-se investir em infraestrutura da rede elétrica de distribuição para um aumento confiável e seguro da inserção de VE. Nota-se que o aumento da frota pode causar impactos significativos nos índices de qualidade e confiabilidade da rede elétrica. Além disso, a recarga dos VE causam um impacto significativo nas estratégias de proteção que devem ser reformuladas. Estes fatos ocorrem devido às características do tipo de recarga escolhido do VE. Basicamente, existem duas grandes classes que são (BREMERMANN, 2014): carregamento controlado e carregamento sem controle.

### 3.2.1 Carregamento sem controle

Observa-se que o carregamento de VE sem controle ocorre quando há conexão do veículo elétrico na rede de distribuição a qualquer hora, não importando os parâmetros de segurança e confiabilidade da rede elétrica. Esse tipo de recarga, o carregamento ocorre desde o momento que acontece a conexão até quando o usuário deseja. Não há uma garantia de recarga completa da bateria, porque quem decide o momento de parada é o usuário e sua necessidade. Nota-se que a tarifa de energia elétrica não é considerada, assim, não há nenhum tipo de ajuste à curva de carga, podendo ocorrer o carregamento do veículo elétrico no horário que a rede elétrica está com um maior consumo de energia, ou seja, no horário de ponta. Além disso, não há restrições de segurança para os equipamentos que participam do carregamento, o que pode causar danos severos a rede elétrica. Observa-se que se há uma recarga sem controle nenhum de vários usuários, os índices de confiabilidade e segurança serão afetados drasticamente. Por fim, observa-se que usando estratégias de recarga descontroladas, há um impacto direto sobre a variação de carga. Com isso, nota-se o envelhecimento prematuro de componentes da rede elétrica, além do aumento das perdas técnicas que são àquelas associadas ao efeito Joule.

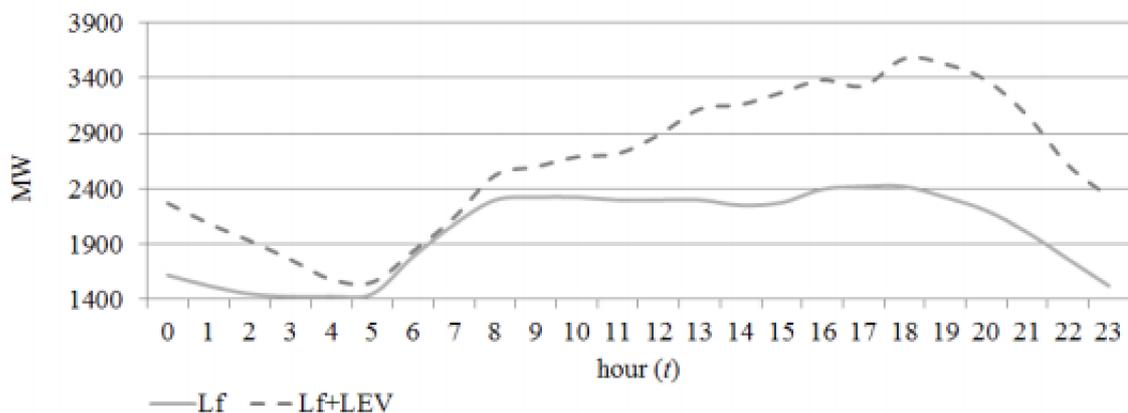
#### 3.2.1.1 Recarga direta

A estratégia de recarga direta é a mais simples. Observa-se que não há nenhum tipo de controle, dessa forma, nota-se que se um grande número de VE carregar no horário

de ponta, limites de fluxo de potência ativa e reativa serão extrapolados, saturação de transformadores e atuação de equipamentos de proteção poderão ocorrer. Além disso, é importante salientar que não há nenhuma estratégia de controle por parte da distribuidora, assim, o usuário tem total controle sobre a recarga e não dispõe de meios para decidir o melhor momento para a rede de distribuição. Dessa forma, situações como o usuário sair com o seu veículo elétrico sem o completo carregamento da bateria podem ocorrer. Assim, é importante observar que se num local de atuação de uma distribuidora for constatado que o tipo de recarga de bateria que prevalece é a direta, medidas de conscientização dos usuários devem ser tomadas e até descontos podem ser dados àqueles donos de veículos elétricos que recarreguem seus VE em horário fora de ponta, ou seja, de menor demanda.

Na Figura 25 observa-se a recarga direta. Na figura, o traço  $Lf$  representa a carga normal do sistema elétrico estudado, já  $Lf + LEV$  representa a união da carga do sistema com a recarga do veículo elétrico. É importante observar, como já dito, que a recarga impacta diretamente a carga global do sistema elétrico estudado, em especial, no horário de maior demanda. Em uma situação hipotética para esse SEP, se esse sistema elétrico apresentar uma capacidade em torno de  $3400MW$ , nota-se que problemas com, por exemplo, estabilidade de tensão irão ocorrer principalmente no período de ponta. Assim, estratégias de proteção do SEP, como por exemplo, desligamento seletivo, deverão ser tomadas para garantir a segurança e a confiabilidade global do sistema elétrico.

Figura 25 – Recarga direta.



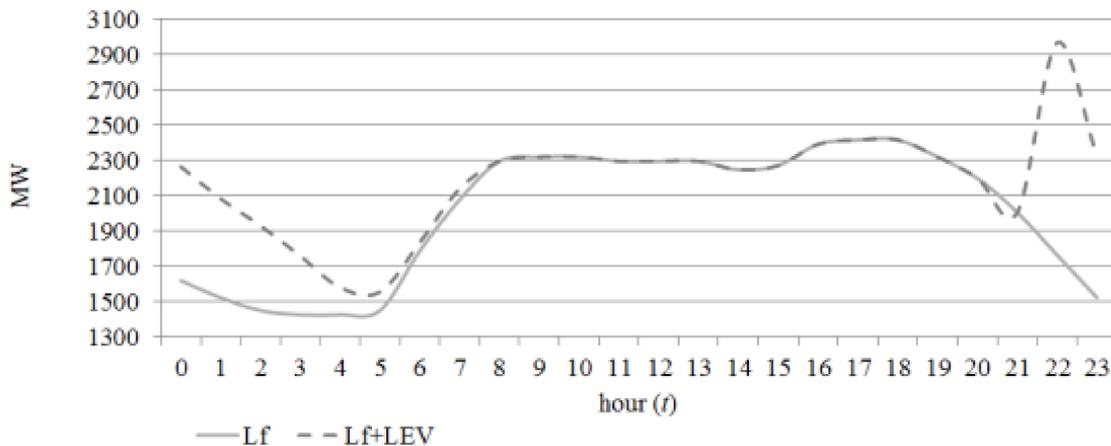
Fonte: (BREMERMANN, 2014).

### 3.2.1.2 Recarga no Vale

Afim de solucionar em parte o problema da recarga de vários veículos elétricos no horário de maior demanda, tem-se a estratégia de recarga no vale. Essa estratégia consiste em, através da curva de carga, descobrir o momento de menor demanda do sistema e diminuir a tarifa da energia elétrica nesse momento. Dessa forma, incentiva-se o usuário a

carregar seu VE nesse instante da curva de carga. No entanto, vale observar que ainda é uma estratégia de recarga sem controle, pois, quem decide o momento de recarga é o próprio usuário sem nenhuma informação sobre o sistema. Há inclusive estudos de planejamento da operação de sistemas elétricos que propõem uma metodologia de recarga de VE no momento de baixa demanda. No entanto, o estudo tem o objetivo através de dados históricos e mensuração de sinais projetar o vale da curva de carga do dia seguinte para cada usuário que realiza recarga de veículos elétricos no sistema (ZHANG *et al.*, 2014). Como há um abordagem individualizada, pode-se através da curva de carga individual atribuir maiores taxas e descontos no decorrer do dia. Esses estudos são importantes porque a depender do tamanho do sistema elétrico estudado e na quantidade de veículos elétricos que podem ser recarregados, a migração da maioria deles para o horário de vale pode transferir o horário de ponta para o vale, assim, os mesmos problemas da recarga direta poderão ocorrer. Na Figura 26, nota-se a estratégia de recarga no vale. Observa-se um pico na curva  $Lf + LEV$  após as 21:00 horas. Esse momento coincide com o fim do período de maior demanda do sistema.

Figura 26 – Recarga no vale.



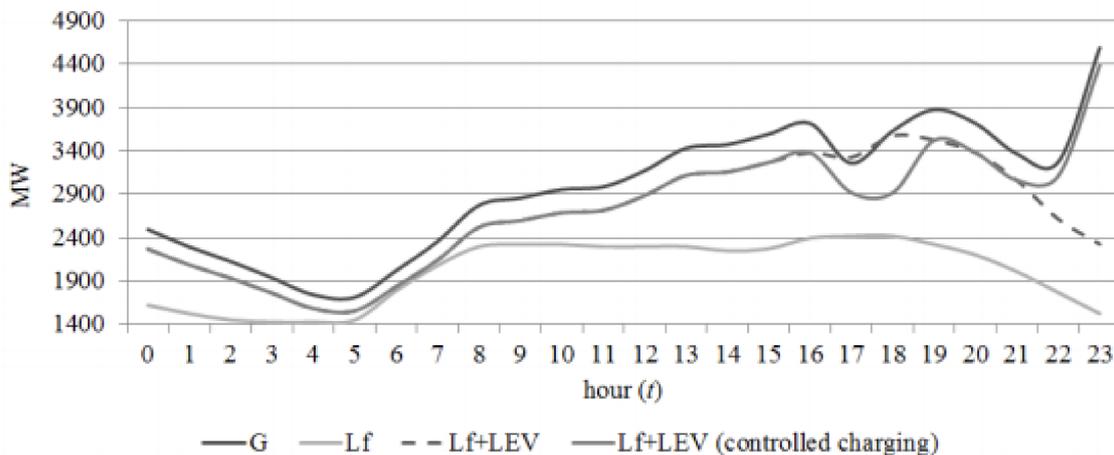
Fonte: (BREMERMANN, 2014).

### 3.2.2 Carregamento com controle

Para melhorar ou mitigar os problemas mostrados nas estratégias de recarga de veículos elétricos sem controle, observa-se as técnicas de recarga de veículos elétricos com controle. Observa-se que essa metodologia persegue um objetivo, como por exemplo, diminuir o número de veículos recarregando no horário de maior demanda. Além disso, pode-se dividir esse tipo de estratégia de recarga em duas categorias: i) centralizada; ii) descentralizada. Na primeira, há uma entidade regulamentadora da recarga dos veículos elétricos que monitora o nível de penetração de VE, a curva de carga e os parâmetros do sistema. Assim, atua-se diretamente no carregador do veículo elétrico para otimizar a

recarga proporcionando segurança ao sistema (BREMERMANN, 2014). Por outro lado, tem-se a recarga inteligente descentralizada em que cada usuário tem todas as ferramentas disponíveis para decidir o melhor momento para a recarga do veículo elétrico (SALDAÑA *et al.*, 2019). Do ponto de vista da recarga inteligente, um parâmetro importante a se ter é a escalabilidade. Esse termo mede a capacidade de se adicionar mais VE no sistema elétrico. Desse ponto de vista, a estratégia descentralizada leva vantagem em relação à centralizada. De forma semelhante, tem-se a controlabilidade do usuário final que é maior na tecnologia descentralizada por razão óbvias. Por fim, tem-se a facilidade de implementação que é melhor na tecnologia descentralizada, porque a tecnologia centralizada há maior necessidade de instalação de uma maior infraestrutura. Na Figura 27 nota-se uma estratégia de recarga inteligente. Nessa Figura,  $G$  representa a capacidade de geração do sistema e  $Lf + LEV(\textit{controlledcharging})$  mostra a curva do sistema com a presença da recarga inteligente. Observa-se que, diferente da linha pontilhada, a partir das 17h quando é o horário de maior demanda do sistema, ocorre uma diminuição da curva  $Lf + LEV(\textit{controlledcharging})$  que representa a recarga inteligente atuando. Além disso, é observável também que a recarga inteligente faz com o que os veículos elétrico recarregue suas baterias após as 23:00 horas.

Figura 27 – Recarga controlada.



Fonte: (BREMERMANN, 2014).

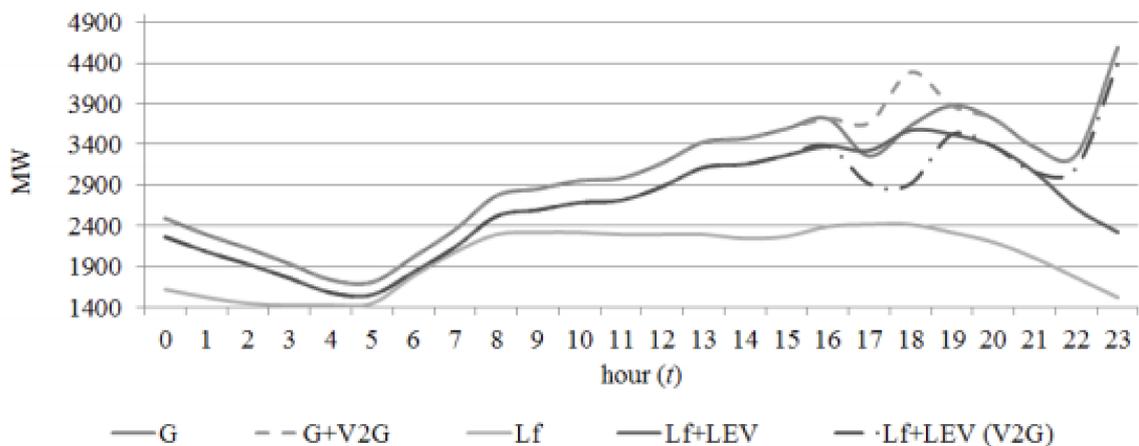
### 3.2.2.1 Recarga V2G

Por fim, tem-se a recarga V2G que, diferentemente das recargas de veículos elétricos apresentadas anteriormente, é considerada bidirecional. Esse tipo de recarga tem ganhado importância na atualidade devido à grande repercussão da geração distribuída mundialmente. Nesse tipo de recarga, que é considerada controlada também, baseado nos índices de confiabilidade e segurança do sistema que são monitorados constantemente escolhe-se o melhor momento para recarregar os veículos elétricos. Além dos índices

observa-se também a curva de carga e o horário de maior demanda da sistema. No entanto, de forma contrária ao o que ocorre na Figura 27, no momento que o sistema elétrico de distribuição tem sua capacidade de geração no máximo, ou seja, maior demanda, a recarga inteligente V2G oferece suporte, por isso é denominado bidirecional. Assim, observa-se vantagens óbvias do uso desse tipo de recarga. Além de diminuir drasticamente o risco do não suprimento dos usuários da rede de distribuição, pode-se citar outras vantagens que estão ligadas a capacidade de regulação. Como a recarga através da estratégia V2G fornece um equilíbrio entre carga e geração, tem-se um benefício imediato que é a regulação da frequência que é importante para a segurança e confiabilidade do sistema. Como o aumento da carga acompanhado de uma baixa capacidade de geração está intimamente ligado a problemas de estabilidade de tensão, a recarga V2G atua diminuindo o risco da ocorrência de afundamento de tensão seguido da atuação de equipamentos de proteção responsáveis por monitorar esses fenômenos.

Na Figura 28 observa-se a metodologia de recarga V2G. Nota-se que na situação normal onde se tem  $G$  e  $Lf + LEV$  como capacidade de geração e carga total do sistema respectivamente, é visível que a partir das 17:00 horas ocorre a perda de capacidade de geração do sistema. Esse fenômeno provoca afundamento de tensão e corte seletivo de carga. Por outro lado, quando há a recarga por V2G, tem-se a capacidade de geração e carga total do sistema representados pelos traços  $G + V2G$  e  $Lf + LEV(V2G)$ . Observa-se que nesse caso, às 17:00 horas o sistema não perde capacidade de geração e a carga elétrica é perfeitamente atendida devido ao suporte fornecido pela recarga V2G. Além disso, a partir das 23:00 horas ocorre a recarga dos veículos elétricos, ou seja, fora do horário de ponta.

Figura 28 – Recarga V2G.



Fonte: (BREMERMANN, 2014).

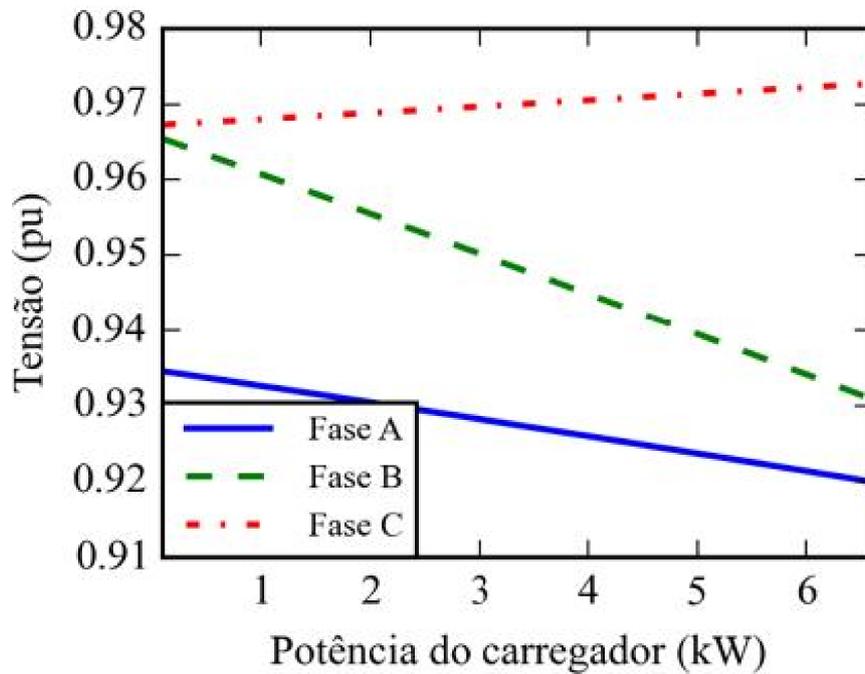
### 3.3 VEÍCULOS ELÉTRICOS NOS SISTEMAS DE DISTRIBUIÇÃO

Com o crescente aumento da inserção de veículos elétricos na frota convencional, aumenta-se a preocupação com a infraestrutura da rede de distribuição existente para recarga dos VE. Além disso, é evidente que melhorias e ajustes devem ser feitos. Por exemplo, na estratégia de recarga V2G é sabido que ocorre o fluxo bidirecional de corrente, no entanto, os equipamentos de proteção convencionais instalados nos sistemas de distribuição em sua maioria são para correntes unidirecionais. Dessa forma, perde-se a radialidade do sistema o que dificulta extremamente o planejamento e a operação do sistema (DAVOUDI; CECCHI; AGÜERO, 2016). Apesar de ser evidente que a inserção de VE do tipo V2G aumenta a confiabilidade do SEP. Assim, é importante investigar como se comporta as variáveis do sistema de distribuição com a recarga dos veículos elétricos.

#### 3.3.1 Perfil de tensão

Em sistemas de transmissão é informação importante na literatura especializada o desacoplamento entre potência ativa e tensão. No entanto, devido a características elétricas dos sistemas de distribuição, o desacoplamento se torna bem menor. Assim, caso seja necessário recarregar um veículo elétrico em determinada barra, deve-se diminuir a magnitude de tensão na barra que o VE está presente para possibilitar o fluxo de potência ativa (ARIOLI, 2016). Na Figura 29, observa-se como se comporta o perfil de tensão quando se aumenta gradualmente a potência ativa requisitada pelo veículo elétrico durante a recarga. Vale salientar que para essa simulação utilizou-se um carregador bifásico conectado nas fases 'A' e 'B'. Nota-se que enquanto incrementa-se a potência ativa as fases 'A' e 'B' apresentam um decréscimo nas magnitudes das tensões. No entanto, a magnitude da tensão na fase 'C' aumenta devido a corrente induzida pelas outras fases no condutor da fase 'C' (ARIOLI, 2016).

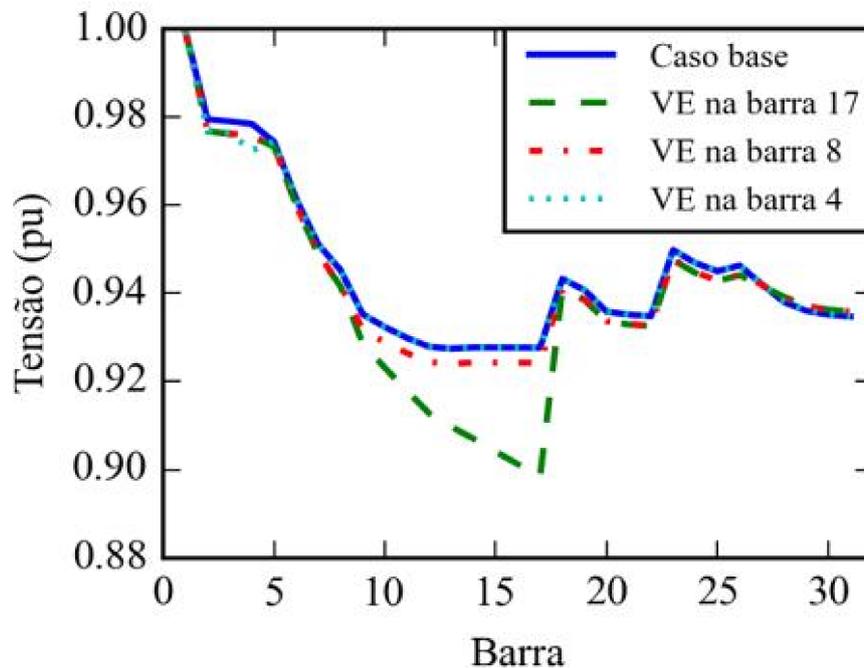
Figura 29 – Comportamento do perfil de tensão com o incremento da potência.



Fonte: (ARIOLI, 2016).

Além disso, vale observar que para barras próximas a subestação, tem-se uma menor impedância equivalente do trecho entre os dois pontos, subestação e barra que o VE está recarregando. Assim, observa-se que a queda da tensão nas fases envolvidas no recarregamento é menor em relação a um ponto afastado da subestação (ARIOLI, 2016). Observa-se na Figura 30 que a queda no perfil de tensão da barra 17, que é mais afastada em relação a subestação, é a mais acentuada se comparado com os outros locais de recarga de VE que são mais próximos da subestação. Além da distância em relação ao medidor, relata-se que outros fatores impactam o perfil da tensão durante o carregamento, como por exemplo, nível de carregamento do sistema e quantidade de veículos elétricos instalados na rede de distribuição.

Figura 30 – Comportamento do perfil de tensão com o aumento da distância.



Fonte: (ARIOLI, 2016).

### 3.3.2 Desequilíbrio de tensão

Outro impacto observado em (ARIOLI, 2016) é o desequilíbrio de tensão. Basicamente, esse fenômeno tem como definição uma diferença nos valores dos módulos ou ângulos de um sistema trifásico que costumeiramente tem fases de mesmo módulo e defasadas de  $120^\circ$ . Geralmente, esse problema ocorre nos sistemas de distribuição e tem como principal causa o mal planejamento da divisão das cargas entre as fases disponíveis. Além disso, a falta de um projeto de boa qualidade dentro das residências dos usuários pode agravar o problema. Para definir através de uma equação deve-se primeiramente definir as tensões e corrente em componente simétricas. Através do teorema de Fortescue pode-se transformar um sistema desequilibrado em A-B-C para três sistemas equilibrados expressos em 0-1-2. Os sistemas equilibrados são:

**Sequência positiva** Três fasores de mesmo módulo, defasados de  $120^\circ$ , na mesma sequência que o sistema original;

**Sequência negativa** três fasores de mesmo módulo, defasados de  $120^\circ$ , na sequência oposta que o sistema original;

**Sequência zero** três fasores de mesmo módulo, defasados de  $0^\circ$ .

É importante frisar que a sequência positiva fornece uma representação da parte equilibrada do sistema estudado. Por outro lado, a sequência negativa mede o desbalanço do parâmetro, seja ele tensão ou corrente. Por fim, tem a sequência zero que está intimamente relacionada com o envolvimento do terra. Para transformar de uma sequência A-B-C para componentes simétricas 0-1-2 tem-se a relação que é mostrada em (3.1). Salienta-se que uma expressão semelhante pode ser definida para as tensões.

$$\begin{pmatrix} \dot{I}_0 \\ \dot{I}_1 \\ \dot{I}_2 \end{pmatrix} = \begin{pmatrix} 1 & 1 & 1 \\ 1 & a & a^2 \\ 1 & a^2 & a \end{pmatrix} \begin{pmatrix} \dot{I}_a \\ \dot{I}_b \\ \dot{I}_c \end{pmatrix} \quad (3.1)$$

Em que:

- $\dot{I}_{abc}$  Correntes em sequência de fase ABC;
- $\dot{I}_{012}$  correntes em sequência de fase 012;
- $a$  operador que tem como valor  $1\angle 120^\circ$ ;
- $a^2$  equivale a  $1\angle -120^\circ$ ;

Existem diversas definições para o desequilíbrio de tensão na literatura especializada, no entanto, a mais simples e mais utilizada é mostrada na equação (3.2) (PAULILO, 2013).

$$FD\% = \frac{|\dot{V}_2|}{|\dot{V}_1|} \quad (3.2)$$

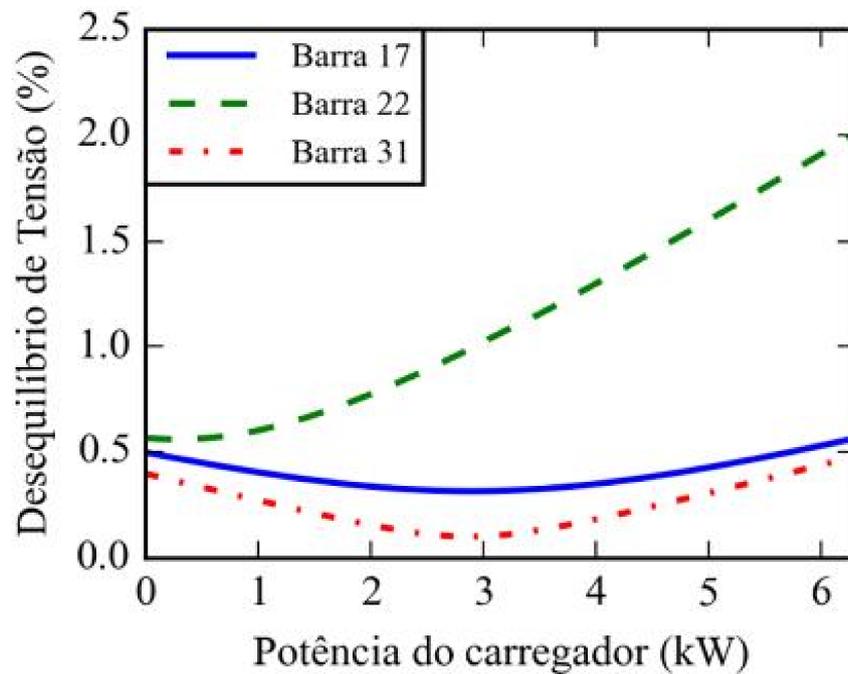
Em que:

- $FD\%$  Fator de desequilíbrio da tensão em porcentagem;
- $|\dot{V}_2|$  Módulo da tensão de sequência negativa;
- $|\dot{V}_1|$  Módulo da tensão de sequência positiva.

Observa-se que o alto desequilíbrio de tensão está associado a diversos problemas, dentre eles, o aumento das perdas técnicas e o aquecimento desproporcional de equipamentos provocando o desgaste excessivo e a necessidade de manutenção fora do período planejado. Assim, diversos órgãos apresentam limites para esse fenômeno com o intuito de evitar danos ao sistema de distribuição. Dentre esses limites o mais restritivo é o do Operador Nacional do Sistema que define que o desequilíbrio não pode ultrapassar 2% (PAULILO, 2013). Com intuito de demonstrar como os veículos elétricos impactam diretamente no desequilíbrio de tensão, em (ARIOLI, 2016) instalou-se um posto de recarga de VE em uma barra do sistema de distribuição e, a partir daí, aumentou-se gradualmente a potência demandada pelo VE e o desequilíbrio de tensão foi calculado para cada incremento. Observa-se na Figura 31 essa simulação e nota-se que a barra 22

que é onde se encontra o posto de recarga do VE é a que apresenta o maior crescimento do desequilíbrio de tensão, diferente das outras barras onde não há recarga de VE. Observa-se que se o posto de conexão do VE for instalado numa fase que esteja aliviada em relação as outras, pode-se reduzir o desequilíbrio de tensão. Assim, se caso seja feito um correto planejamento para a instalação do ponto de conexão do VE no sistema de distribuição, pode-se reduzir o desequilíbrio de tensão já presente no sistema.

Figura 31 – Comportamento do desequilíbrio da tensão com o aumento da potência ativa requisitada pelo VE.



Fonte: (ARIOLI, 2016).

## 4 METODOLOGIA PROPOSTA

Este capítulo apresenta a metodologia proposta na presente dissertação para aplicação de redes neurais artificiais aos problemas de detecção e localização de defeitos de alta impedância em sistema de distribuição de energia elétrica, considerando, inclusive, a presença de veículos elétricos. Portanto, a aplicabilidade de RNA a problemas complexos envolvendo SDEE, como o mencionado anteriormente, é explorada tendo em vista sua capacidade de generalização e reconhecimento de padrões. No entanto, a eficácia desta capacidade de generalização depende de um conjunto suficiente de amostras de dados relevantes para a aplicação proposta. Deste modo, questões associadas a esta amostragem são introduzidas neste capítulo, bem como são apresentados os módulos propostos de detecção e localização de defeitos. Estes módulos, juntamente com a estratégia de obtenção de dados amostrais, constituem a metodologia proposta neste trabalho.

### 4.1 OBTENÇÃO E TRATAMENTO DE DADOS

Haja vista a importância de uma boa amostragem de dados relevantes para a aplicação proposta, e como não se dispunha de dados práticos ou reais para tal, optou-se pela geração de dados através de simulações com modelo computacional que representa o comportamento do sistema em estudo, utilizando o software OpenDSS, que é um programa recomendado pela ANEEL para a realização de estudos em rede de distribuição (ANEEL, 2014). O software é um programa que permite um vasto número de possibilidades para simulações de sistemas de energia elétrica, incluindo potencial para simulação de redes de distribuição com presença de recursos distribuídos. Como característica de destaque, o OpenDSS comporta a simulação de sistemas elétricos configurados em malha, sendo, portanto, adequado para análises de redes elétricas com presença de GD e veículos elétricos com característica de recarga V2G.

Uma característica importante do OpenDSS é a de ser uma plataforma de código aberto que pode ser expandida de acordo com as necessidades do usuário. Além disto, apresenta uma característica denominada *Component Object Model* (COM), que se destaca em análises de redes elétricas que requerem nível elevado de automatização na simulação. Assim, o programa pode ser acionado através de outras plataformas como, por exemplo, Python e Matlab. Aproveitando esta potencialidade, utilizou-se, nesta dissertação, linguagem e ambiente de programação Python para implementação das RNAs, utilizando bibliotecas específicas, bem como para automatizar as simulações e, desta forma, dar eficiência ao processo de simulação da metodologia proposta.

Conforme esta metodologia de aplicação, foram realizadas simulações, utilizando ambiente Python em associação ao OpenDSS, que se organizam em dois grupos:

**Grupo-1** análises em condições operativas normais;

**Grupo-2** análises de curto-circuito monofásico do tipo em derivação, do inglês *shunt*.

Para tanto, alguns parâmetros dos sistemas foram variados durante as simulações com a finalidade de se construir um banco de dados representativo das características da rede elétrica, incluindo seu comportamento diante de carregamento de VE. Estes parâmetros foram:

**Carregamento do sistema** Nos dois grupos de análise anteriormente citados, a carga da rede elétrica foi variada, de maneira uniforme entre as barras, de 60% a 140% dos respectivos valores nominais, com passo de 10%. Este procedimento cobre a maioria das situações que ocorrem em redes reais de distribuição, onde, dependendo das características da curva de carga, se excursiona por diversos percentuais durante o dia.

**Localização do defeito** Selecionou-se um conjunto representativo de barras de média tensão da rede elétrica. Destas barras, derivam transformadores de distribuição que alimentam ramais de baixa tensão que, por sua vez, fornecem energia elétrica para unidades consumidoras residências e comerciais. Todas as barras de baixa tensão supridas por estes ramais foram submetidas a condição de curto-circuito, a fim de gerar o banco de dados.

**Presença de veículos elétricos** Como um objetivo da dissertação é investigar qual é o impacto da recarga de VE nos problemas de detecção e localização de defeitos de alta impedância, simulações com e sem a presença de VE em recarga foram realizadas. Destaca-se que os postos de recarga de VE foram considerados conectados a instalações de unidades residenciais alimentadas em baixa tensão.

**Tipo de recarga** Além da presença de VE, variou-se também o tipo de recarga utilizado. Assim, pode-se retirar conclusões de como se comporta a rede elétrica quando se varia o instante na curva de carga em que o VE é recarregado.

Conforme descrito em capítulo anterior, considera-se no presente trabalho estrutura contextualizada no conceito de medidores inteligentes. Com o objetivo de investigar o impacto de diferentes estratégias de localização de medidores inteligentes na rede de distribuição, considera-se quatro estratégias envolvendo: medição no enrolamento secundário do transformador da subestação; medição no enrolamento primário de um transformador típico de distribuição em ponto intermediário do alimentador; medição no primário de um transformador de distribuição localizado no final do alimentador. Desta forma, as quatro estratégias citadas são:

**Estratégia-1** Medição somente na subestação;

**Estratégia-2** Medição na subestação e em ponto intermediário do alimentador de distribuição;

**Estratégia-3** Medição na subestação e no final do alimentador de distribuição;

**Estratégia-4** Medição na subestação, em ponto intermediário e no final do alimentador.

Destaca-se que cada MI apresenta uma aquisição de dados independente dos demais, em todas as estratégias anteriores. As estratégias e, portanto, o número ótimo de MI, são avaliadas mediante os módulos de detecção e localização de defeitos de alta impedância, e comparadas através das métricas apresentadas na seção 2.6. Para determinar a estratégia ótima com relação aos medidores, a metodologia proposta considera a medição em todos os pontos (subestação, ponto intermediário e final do alimentador).

As mesmas estratégias anteriores serviram para gerar os cenários de recarga de VE na rede, ou seja, considerando VE conectado à baixa tensão correspondente a pontos de média no início, meio e final de alimentador.

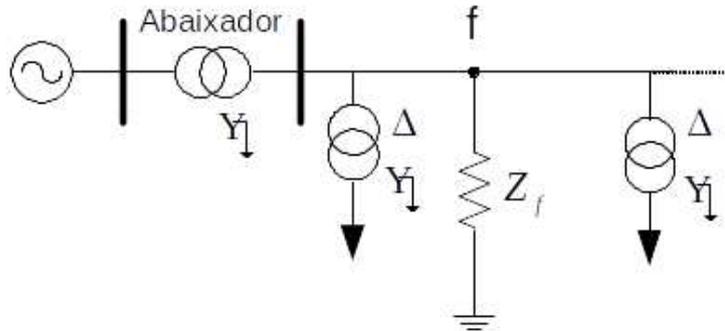
Combinando-se os parâmetros anteriores, carregamento do sistema, localização do defeito, presença de VE e tipo de recarga, com auxílio de um algoritmo desenvolvido em Python, para a estratégia com medição em todos os pontos, simula-se a rede elétrica no OpenDSS para cada combinação. Daí, para cada combinação, obtém-se os fasores de tensão e corrente em componentes de sequência dos três MI, subestação, ponto intermediário e final de alimentador, tanto para condições operativas normais, quanto para condições de curto-circuito.

Importante aspecto é que os fasores de tensão e corrente são transformados de componentes de fase para componentes de sequência, a fim de facilitar o reconhecimento de padrões pelas RNAs de detecção e localização de defeitos de alta impedância. Isto se justifica pelo fato de que fasores de tensão e corrente, em componentes de fase, podem apresentar alterações pouco expressivas durante um defeito de alta impedância, enquanto que em componentes simétricas, estes fasores podem evidenciar variações e facilitar a tomada de decisão.

A análise de defeitos monofásicos em derivação, no Grupo-2 de simulações, justifica-se por este tipo de defeito com envolvimento de terra ser o mais comum em redes aéreas de distribuição, com uma participação de 70% entre todos os tipos de curto-circuito (MATOS, 2009). Na Figura 32, observa-se um alimentador contendo um transformador de subestação (abaixador) e dois outros transformadores abaixadores de distribuição ao longo do alimentador. Considera-se um defeito em derivação no ponto 'f', entre os transformadores de distribuição, com impedância de falta  $Z_f$ . Como o presente trabalho

objetiva investigar o comportamento da rede de distribuição mediante defeitos de alta impedância, considera-se, para todas as simulações,  $Z_f$  igual a  $30\Omega$ .

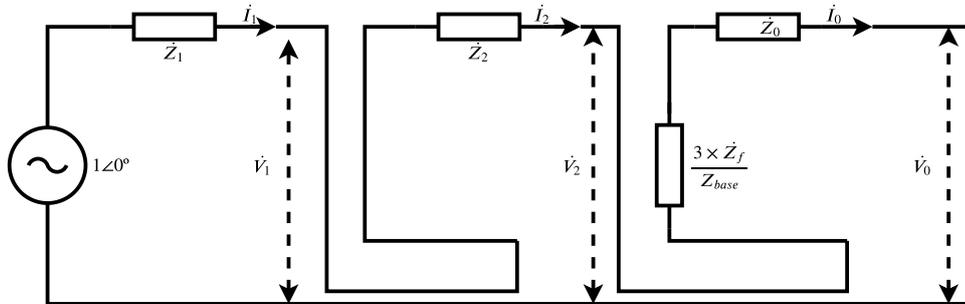
Figura 32 – Defeito do tipo em derivação.



Fonte: (OLIVEIRA *et al.*, 2016).

A composição dos circuitos de sequência para o cálculo dos parâmetros deste tipo de curto-circuito é mostrada na Figura 33. Onde  $\dot{Z}_f$  na figura representa a impedância de defeito. Além disto, os parâmetros  $\dot{Z}_0$ ,  $\dot{Z}_1$  e  $\dot{Z}_2$  representam as impedâncias complexas em componentes simétricas. Já  $\dot{V}_0$ ,  $\dot{V}_1$ ,  $\dot{V}_2$ ,  $\dot{I}_0$ ,  $\dot{I}_1$  e  $\dot{I}_2$  são os fasores de tensão e corrente em componentes de sequência. Por fim,  $Z_{base}$  é a base de impedância do sistema.

Figura 33 – Modelo para cálculo da corrente de curto-circuito.



Fonte: Elaborada pelo autor (2020).

Através da equação (4.1) (KINGMA; BA, 2014), pode-se calcular a corrente de curto-circuito de um defeito monofásico em derivação. Observa-se que quanto maior a impedância do local em que há o curto-circuito, menor é a corrente e, portanto, maior a probabilidade desta corrente não sensibilizar os equipamentos de proteção.

$$I_{cc} = \frac{3}{\left| 2\dot{Z}_1 + \dot{Z}_0 + \frac{3\dot{Z}_f}{Z_{base}} \right|} I_{base} \quad (4.1)$$

Em que:

$I_{cc}$  Corrente de curto-circuito;  
 $I_{base}$  Corrente base.

Para a comprovação que  $Z_f$  igual a  $30\Omega$  define um defeito de alta impedância, utilizando o mesmo sistema estudado no trabalho, foram aplicados defeitos monofásicos *shunt* com impedâncias de defeitos iguais a:  $0\Omega$ ,  $30\Omega$  e  $8000\Omega$ . Na tabela 4 é apresentado as variações percentuais dos resultados para os defeitos com  $Z_f$  igual a  $0\Omega$  e  $Z_f$  igual a  $30\Omega$  para um período da curva de carga. Além disso, apresenta-se também a mesma análise para  $Z_f$  igual a  $30\Omega$  e  $Z_f$  igual a  $8000\Omega$ . Observa-se através dos resultados que variando  $Z_f$  de  $0\Omega$  para  $30\Omega$  há uma grande variação percentual dos resultados. Por outro lado, mudando a impedância de defeito de  $30\Omega$  para  $8000\Omega$ , a variação percentual não passa de 2%. Assim, comprova-se que  $Z_f$  igual a  $30\Omega$  define um defeito de alta impedância.

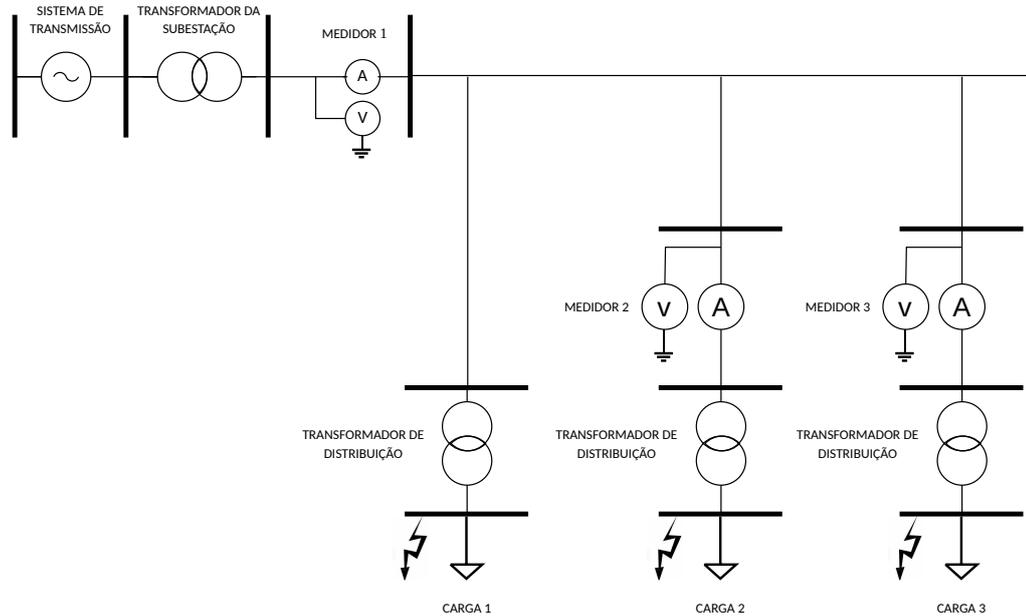
Tabela 4 – Variação percentual para diferentes impedâncias de defeito

	$ \dot{V}_0 $	$ \dot{V}_1 $	$ \dot{V}_2 $	$ \dot{I}_0 $	$ \dot{I}_1 $	$ \dot{I}_2 $
0Ω - 30Ω	0.00016	590.00000	807.40470	0.00027	1214.80000	1149.33850
30Ω - 8000Ω	0	0	1.366200	0	2.000000	1.944800

Fonte: Elaborada pelo autor (2020).

A Figura 34 apresenta um esquema simples, envolvendo três barras de média tensão, para as simulações visando à obtenção dos dados de amostras de curto-circuito. Este esquema envolve o sistema de transmissão seguido pela subestação representada por um transformador abaixador e por um MI instalado no enrolamento de baixa tensão deste transformador. No alimentador derivado da subestação, tem-se três transformadores típicos de distribuição que alimentam cargas conectadas na baixa tensão, além de dois MI nos primários dos dois transformadores de distribuição mais ao final deste alimentador. Destaca-se que os curtos monofásicos em derivação são aplicados nas barras de baixa tensão do sistema e que pontos de recarga de VE, quando considerados, conectam-se a estas barras de baixa.

Figura 34 – Esquema da simulação.



Fonte: Elaborada pelo autor (2020).

Por fim, após a obtenção das amostras de dados, faz-se uma análise exploratória, para garantir que não haja valores não numéricos, pois estes dados comprometem o desempenho de uma RNA.

Os módulos de detecção e localização de defeitos no âmbito da metodologia proposta são descritos na sequência. Neste contexto, vale ressaltar, conforme descrito anteriormente, que ambos os módulos consideram MI em três zonas do alimentador de distribuição, início (subestação), ponto intermediário e final, a fim de dar suporte à decisão pela melhor Estratégia, entre as definidas anteriormente.

## 4.2 MÓDULO DE DETECÇÃO DE DEFEITOS

Basicamente, o módulo de detecção de defeitos tem como função determinar o estado de operação do sistema de distribuição, a saber: condição operativa normal ou curto-circuito. É válido mencionar que para defeitos com baixo valor de impedância, a detecção é uma tarefa mais simples, pois os fasores de tensão e corrente de curto-circuito são mais bem diferenciados em relação aos de condição normal. No entanto, isto não se observa para defeitos de alta impedância.

As condições de obtenção de dados, envolvendo curtos na baixa, grupos de análise, medição e parâmetros como carga, foram descritas no subcapítulo anterior. Observa-se que uma rede real de distribuição é naturalmente sujeita a um número de condições operativas normais muito maior do que de condições de curto-circuito, pois as probabilidades de defeitos são relativamente baixas, em comparação com a probabilidade de operação

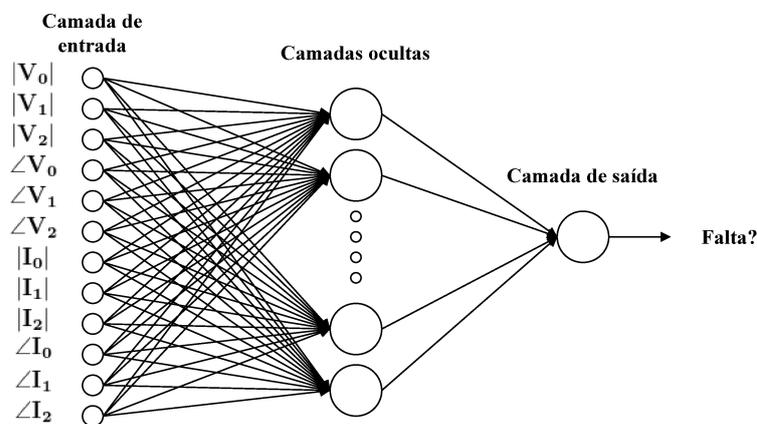
normal. Portanto, considerar os dados sem um pré tratamento no sentido de reduzir a desproporcionalidade entre condição normal e de defeito pode afetar a capacidade de generalização das RNAs, devido à carência de dados de defeito mediante um universo muito maior de amostras de condição normal.

Desta forma, de acordo com a metodologia proposta, faz-se uma seleção prévia dos dados obtidos de simulação, de modo que o conjunto amostral de dados de condição normal corresponda, em quantidade de amostras, ao dobro do conjunto amostral de defeito. Este procedimento também é utilizado em (SILVA *et al.*, 2007) e evita a perda de generalização das RNAs, ao mesmo tempo em que mantém a predominância dos dados de condição normal em relação a defeito.

Estes dados, agrupando as combinações de condições e parâmetros de forma adequada ao problema, como descrito, são divididos em três subconjuntos: treinamento (50%), validação (25%) e teste (25%). Após esta organização, faz-se o treinamento da RNA dedicada à detecção utilizando o subconjunto de treinamento.

Para o módulo de detecção de defeitos, escolheu-se uma RNA com uma arquitetura do tipo de múltiplas camadas *Multilayer Perceptron*, que é alimentada com os módulos e fases das tensões e correntes, em componentes de sequência, conforme ilustrado na Figura 35. Esta RNA é denominada RNA-deteção.

Figura 35 – Arquitetura da RNA-deteção.



Fonte: Elaborada pelo autor (2020).

As entradas e saída da RNA-deteção são tratadas da seguinte forma:

**Entradas** Para facilitar o processamento de dados pela RNA e, portanto, aumentar sua capacidade de reconhecimento de padrão, os dados de entrada, ou seja, tensões e correntes em módulo e fase, são normalizados em uma distribuição normal padrão com média zero (0) e desvio padrão igual a '1'. Este procedimento é especialmente

importante devido à diferença entre níveis de tensão e corrente de diferentes zonas de um alimentador.

**Saída** A saída foi modelada com um par de valores binários, em que  $[0, 1]$  define condição operativa normal e  $[1, 0]$  define condição de defeito.

Destaca-se que cada padrão de entrada tem um padrão de saída correspondente, e que um padrão corresponde a uma condição específica da rede elétrica, ou seja, a uma amostra única envolvendo uma dada condição pontual de: i) carregamento; ii) normalidade ou defeito; iii) localização de defeito se a amostra for de defeito; iv) presença ou não de VE; v) tipo de recarga em caso de presença de VE; vi) localização de VE em caso de sua presença. Como o processo de aprendizagem é supervisionado, além das entradas, também se define a saída esperada da RNA, dada pelo par de valores binários.

De acordo com a metodologia proposta, para cada MI no alimentador sob análise, define-se uma RNA. Logo, tem-se que:

$$N_{entrada} = 12 \quad (4.2)$$

$$N_{saida} = 2 \quad (4.3)$$

Em que:

$N_{entrada}$  Número de neurônios na camada de entrada;  
 $N_{saida}$  Número de neurônios na camada de saída.

O número de neurônios na camada de entrada é igual a '12', pois para cada padrão de entrada, há, conforme Figura 35, três valores para: i) módulo de tensão; ii) ângulo de fase de tensão; iii) módulo de corrente; iv) ângulo de fase de corrente. Já a saída tem dois neurônios devido ao par de valores binários escolhido para esta camada.

Como se trata de uma classificação binária, utilizou-se o otimizador *Adam* em união com uma função de perda do tipo entropia binária cruzada, ambos disponíveis em biblioteca do ambiente de programação Python. Além das camadas de entrada e de saída, deve-se definir o número de camadas ocultas, onde se processam as informações provenientes da camada de entrada. A correta definição do número de camadas ocultas para cada aplicação desperta interesse em pesquisas atuais, porém, não há uma regra que defina de maneira exata como proceder em cada situação. Todavia, de acordo com alguns trabalhos, é possível aproximar qualquer função com apenas duas camadas ocultas (OLIVEIRA *et al.*, 2016).

Como outro aspecto limitador do número de camadas ocultas, tem-se que o erro calculado na saída da RNA é retro-propagado pelas camadas ocultas para a atualização dos

pesos sinápticos. Portanto, quanto maior o número de camadas ocultas, maior a propagação de erros (SILVA; OLIVEIRA, 2001). Logo, o presente trabalho optou por utilizar o número de duas camadas ocultas definido para um aproximador universal (OLIVEIRA *et al.*, 2016).

Definido o número de camadas, deve-se ainda definir o número de neurônios em cada camada oculta. Geralmente, este processo é conduzido de forma empírica, porém, alguns trabalhos sugerem estratégias para esta definição. As equações (4.4) e (4.5) formulam duas maneiras de se definir o número de neurônios em cada camada oculta (RUFINO, 2017). Na presente dissertação, optou-se pela equação (4.5), que resulta, para a RNA da Figura 35, em  $N_{oculta} = 9$ . Ou seja, as duas camadas ocultas têm nove neurônios, em que cada neurônio apresenta função de ativação *relu*.

$$N_{oculta} = \sqrt{N_{entrada}N_{saida}} \quad (4.4)$$

$$N_{oculta} = \frac{2}{3}(N_{entrada} + N_{saida}) \quad (4.5)$$

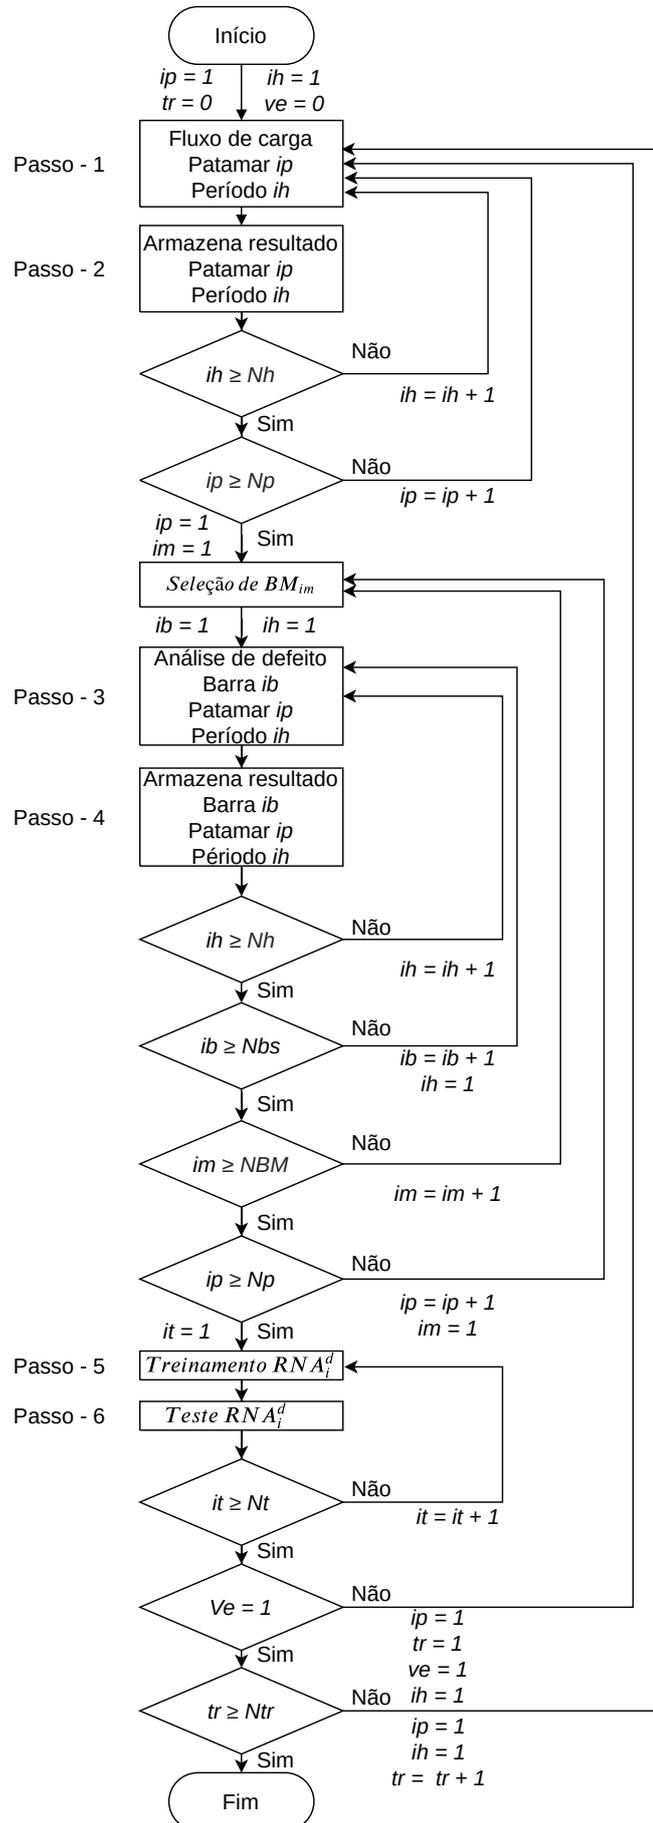
Em que:

$N_{oculta}$  Número de neurônios na camada oculta.

Ademais, de acordo com (RAUL, 2018), para um classificador binário em que se objetiva classificar eventos mutuamente exclusivos, como condição normal e de defeito, deve-se utilizar a função de ativação *softmax* na camada de saída, para melhor adequação da probabilidade de um padrão pertencer a determinada classe de evento. Desta forma, como se tem dois neurônios na camada de saída, o de maior valor de probabilidade determina a classe do padrão de entrada. Este é o motivo de se ter utilizado dois neurônios na camada de saída, ao invés de apenas um valor binário. Por fim, a rede foi treinada por 30 épocas.

Um esquemático do módulo de detecção em conjunto com a etapa de aquisição de dados é apresentado na Figura 36. Este fluxograma é válido para um determinado medidor  $MI_i$ , ou seja, o respectivo algoritmo é executado para cada medidor inteligente  $MI_i$  pertencente a  $NMI$ , em que  $NMI$  é o conjunto de MI considerados.

Figura 36 – Fluxograma do módulo de detecção para  $MI_i$ .



Em que:

$Np$  Número de patamares ou níveis de carga do sistema;

$Nh$  Número de períodos;

$Ntr$  Número de tipos de recarga;

$Nbs$  Número de barras da rede secundária de baixa tensão derivadas do barramento primário  $BM_{im}$ , incluindo entre  $NBM$ ;

$NBM$  Número de barras de média tensão sob análise.

Conforme fluxograma da Figura 36, o barramento  $BM_{im}$  é variado a fim de se avaliar o impacto de defeitos em diferentes zonas de um alimentador. Além disto, varia-se a condição operativa entre ausência de VE,  $ve = 0$ , e presença de VE na rede,  $ve = 1$ , bem como entre os tipos de recarga de VE,  $tr$ , quando VE é presente. Estes tipos  $tr$  variam entre:

- Recarga V2G;
- Recarga Direta;
- Recarga no Vale.

Os passos do algoritmo da Figura 36 são descritos na sequência.

**Passo-1** Consiste na execução de fluxo de potência, utilizando o OpenDSS, considerando o sistema em condições normais de operação para cada patamar de carga  $ip$  e para cada período  $ih$ .

**Passo-2** Armazena os resultados dos fluxos de potência do Passo-1, ou seja, tensões e correntes em módulo e fase, verificados no ponto de medição de  $MI_i$ , para o patamar  $ip$  e período  $ih$ .

**Passo-3** Análise de curto-circuito na barra secundária de baixa tensão  $ib$  sob análise que está diretamente ligada à barra de média tensão  $BM_{im}$  selecionada. Esta análise é feita considerando o patamar de carga  $ip$  e período  $ih$ .

**Passo-4** Armazena os resultados da análise de defeitos do Passo-3, ou seja, tensões e correntes em módulo e fase, verificados no ponto de medição de  $MI_i$ , para o curto-circuito na barra  $ib$ , patamar  $ip$  e período  $ih$ .

**Passo-5** Este passo realiza o processo de treinamento da RNA-deteccção para o medidor  $MI_i$ , denominada  $RNA_i^d$ , utilizando os dados das análises de condição normal e de defeito armazenados nos Passos-2 e 4, respectivamente, em conjunto com os padrões de saída relacionados (condição normal ou defeito).

**Passo-6** Teste de  $RNA_i^d$ , utilizando os padrões armazenados no conjunto de teste previamente descrito.

A cada execução *it* do algoritmo da Figura 36, os Passos-5 a 6 são repetidos até que um número total de execuções  $Nt$  seja alcançado, sendo que no presente trabalho,  $Nt = 50$ . Este procedimento é realizado porque no processo de inicialização de uma RNA, os pesos sinápticos são pseudo-aleatórios. Portanto, para considerar esta aleatoriedade, o processo passo a passo da Figura 36 é repetido visando a uma análise através de uma ferramenta da estatística descritiva denominada mediana. Assim, evita-se a interferência de pontos discrepantes na análise, já que, a mediana é pouco sensível a *outliers*.

Importante aspecto é que, como um objetivo desta dissertação é verificar o impacto de VE na deteção e localização de defeitos de alta impedância, o fluxograma da Figura 36 considera tanto a condição sem VE,  $ve = 0$ , quanto a condição com VE,  $ve = 1$ , além dos diferentes tipos de recarga *tr*. Isto permite avaliar, através das métricas utilizadas no Passo-6, os impactos de interesse.

Cabe destacar que os quatro primeiros passos são realizados através da interface COM do OpenDSS/Python. Desta forma, para aumentar a eficiência computacional e viabilizar um nível de automatização dos comandos do OpenDSS, utiliza-se código em Python para captura dos dados de fluxo de potência e análise de curto-circuito. A seguir, já com os dados capturados, utiliza-se o ambiente *Google Colaboratory* nos Passos-5 e 6 para treinamento, validação e teste da RNA-deteccção. Este ambiente é parte da plataforma de desenvolvimento *Jupyter Notebook* do Python, executado em nuvem e disponibilizado pelo Google.

Algumas características determinaram a escolha da ferramenta anteriormente citada, entre elas:

- bibliotecas pré-instaladas;
- interação com o Google Drive;
- utilização de plataforma gráfica *Graphics Processing Unit* de forma fácil e sem custo;
- ambiente *Google Colaboratory* permite lidar de forma eficiente com a dimensão elevada do conjunto de dados e de análises de fluxo de carga e curto-circuito.

Caso o módulo de deteção indique defeito para alguma amostra, esta amostra é submetida ao módulo de localização, descrito na sequência. Após a localização, métricas

apropriadas de avaliação são aplicadas para aferir a qualidade dos resultados da composição destes dois módulos.

Como as análises envolvem MI no início (subestação), ponto intermediário e final de alimentador, a fim de identificar a melhor Estratégia entre as quatro descritas no subcapítulo anterior, uma das seguintes situações podem ocorrer:

**Condição-1** Nenhuma  $RNA_i^d$  detecta falta: neste caso, o padrão é identificado como condição operativa normal e o módulo de localização não é executado para a respectiva amostra;

**Condição-2** Pelo menos uma  $RNA_i^d$  detecta falta: neste caso, o padrão é identificado como de defeito, ou seja, curto-circuito monofásico em derivação, e o módulo de localização de defeitos, descrito a seguir, é executado para a respectiva amostra.

#### 4.3 MÓDULO DE LOCALIZAÇÃO DE DEFEITOS

Após a detecção de um defeito de alta impedância, Condição-2 anteriormente definida, a metodologia proposta inclui a aplicação do módulo de localização desenvolvido neste trabalho. Primeiramente, destaca-se que para curto-circuito com impedância reduzida, os fasores de tensão e de corrente diferem-se de forma mais sensível em relação aos respectivos valores de condição operativa normal e, com isto, um medidor na proximidade deste defeito é mais facilmente sensibilizado, acusando sua localização. No entanto, para um curto-circuito de alta impedância, esta sensibilização é mais difícil devido à maior complexidade para separação entre padrões de condição normal e de defeito, o que, portanto, pode confundir um sistema de localização.

As mesmas condições de obtenção de dados do módulo de detecção, envolvendo curto-circuitos no lado de baixa tensão, grupos de análise, medição e parâmetros, são utilizadas no módulo de localização. Destaca-se que qualquer variação positiva na carga, mesmo que pequena, pode confundir a RNA especialista em localizar defeitos. Desta forma, é importante que o conjunto de treinamento tenha uma gama representativa de cenários a fim de permitir a generalização do aprendizado e a identificação do padrão de defeito, de modo a cobrir a maioria de condições possível.

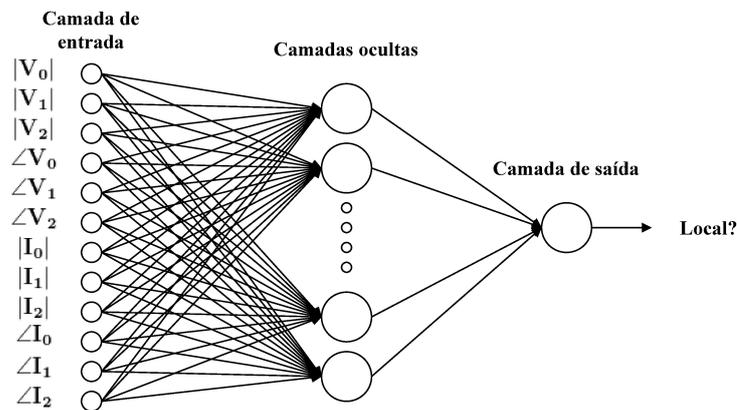
A estrutura da RNA de localização, RNA-localização, é similar à da RNA-detecção previamente introduzida, com diferença básica na estrutura da saída esperada e no conjunto amostral, que no caso da localização, envolve apenas amostras de condição de defeito, enquanto que na detecção, envolve também as condições operativas normais. Deste modo, as entradas e saída da RNA-localização associada a cada MI são definidas da seguinte forma:

**Entradas** Fasores de tensão e corrente, ou seja, módulos e fases das correntes nas três fases, totalizando 12 entradas, no ponto de medição. Assim como na RNA-deteção, estes dados são normalizados em uma distribuição com média zero (0) e desvio padrão igual a '1' para aumentar a capacidade de generalização da RNA.

**Saída** A saída desta RNA indica a distância entre o barramento de média tensão associado ao defeito, ou seja, o barramento que alimenta a barra da rede secundária sob defeito, e a subestação. Visando a um aprendizado mais eficiente, esta saída foi codificada através de representação binária de seis dígitos.

A estrutura de RNA utilizada, assim como no módulo de deteção, é a do tipo *Multilayer Perceptron*. Com base na estrutura descrita da RNA-localização, a Figura 37 ilustra sua arquitetura.

Figura 37 – Arquitetura da RNA-localização.



Fonte: Elaborada pelo autor (2020).

Assim como na RNA-deteção, utiliza-se o otimizador tipo *Adam* na RNA-localização, em conjunto com a função de custo entropia categórica cruzada, duas camadas ocultas com função de ativação *relu* e a função de ativação *softmax* na camada de saída (RAUL, 2018). No caso da RNA-localização, tem-se que:

$$N_{entrada} = 12 \quad (4.6)$$

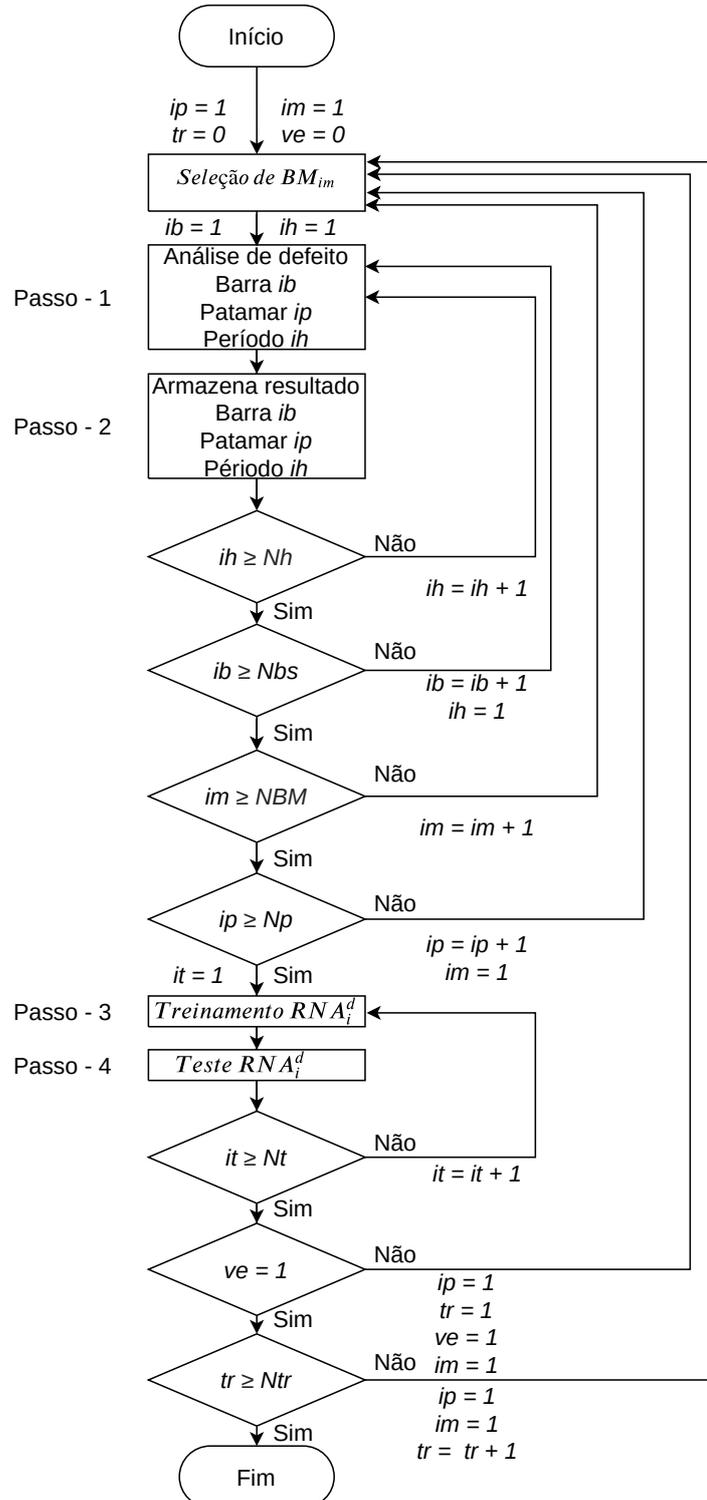
$$N_{saida} = 6 \quad (4.7)$$

Seguindo uma sugestão de (OLIVEIRA *et al.*, 2016), utiliza-se na RNA-localização um número de neurônios nas camadas ocultas igual a três vezes o número de neurônios da camada de entrada, ou seja:

$$N_{oculta} = 3 * (N_{entrada}) = 36 \quad (4.8)$$

Outro parâmetro importante é o número de 1000 épocas de treinamento da RNA-localização, determinado de forma empírica. Os conjuntos amostrais também foram divididos em: treinamento (50%), validação (25%) e teste (25%). Um fluxograma para o módulo de localização é mostrado na Figura 38.

Figura 38 – Fluxograma do módulo de localização.



Fonte: Elaborada pelo autor (2020).

Os passos do fluxograma da Figura 38 são descritos a seguir.

**Passo-1** Consiste na análise de curto-circuito na barra secundária de baixa tensão  $ib$ , conectada ao ramal alimentado pelo transformador acoplado à barra de média tensão  $BM_{im}$ , considerando o patamar de carga  $ip$  e período  $ih$ .

**Passo-2** Armazena os resultados da análise de defeitos do Passo-1, ou seja, tensões e correntes em módulo e fase, verificados no ponto de medição de  $MI_i$ , para o curto-circuito na barra  $ib$ , patamar  $ip$  e período  $ih$ .

**Passo-3** Este passo realiza o processo de treinamento da RNA-localização para o medidor  $MI_i$ , denominada  $RNA_i^L$ , utilizando os dados da análise de defeitos armazenados no Passo-2, em conjunto com os padrões de saída relacionados (distâncias ao defeito).

**Passo-4** Teste de  $RNA_i^L$ , utilizando os padrões armazenados no conjunto de teste.

No módulo de localização, o número de execuções dos Passos-3 e 4 é dado por  $Nt = 5$ . Assim como na detecção, utiliza-se a interface COM do OpenDSS/Python nos Passos-1 e 2, e o ambiente do *Google Colaboratory* nos Passos-3 e 4.

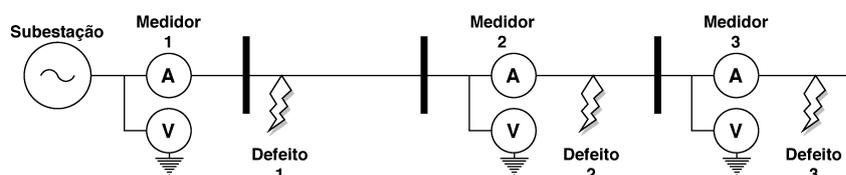
Conforme descrito para o módulo de detecção, na Condição-2, caso pelo menos um medidor detecte falta no padrão de determinada amostra, o módulo de localização é executado de acordo com as seguintes sub-condições, baseadas em (TRINDADE; FREITAS; VIEIRA, 2013) e (SENGER *et al.*, 2000):

**Sub-condição-2.1** Um único MI identifica determinada amostra como defeito. Neste caso, este MI é selecionado para localizar a barra de média tensão  $BM_k$  associada ao curto-circuito.

**Sub-condição-2.2** Mais de um MI identifica determinada amostra como defeito. Neste caso, o MI mais a jusante entre os que identificaram o defeito é selecionado para localizar a barra de média tensão  $BM_{im}$  associada ao curto-circuito.

Para elucidar as sub-condições anteriores, considera-se a situação da Figura 39 que é uma versão simplificada do estudo feito nesta dissertação.

Figura 39 – Alimentador de distribuição simplificado.



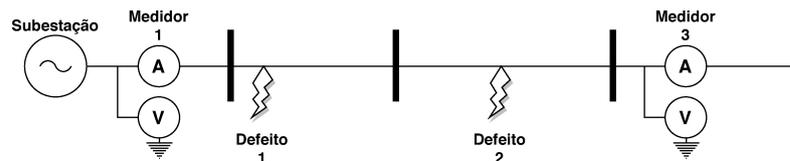
Fonte: Elaborada pelo autor (2020).

A Figura 39 trata da do alimentador real estudado sob o regime de curto-circuito monofásico *shunt*. Observa-se três defeitos aplicados no início, meio e fim da rede de distribuição, aplicados de forma mutuamente exclusiva. Seguindo, a impedância de defeito utilizada foi a mesma utilizada no estudo de caso, ou seja, trata-se um curto-circuito de alta impedância. Por fim, observa-se três medidores instalados no início, meio e fim do sistema da distribuição estudado.

Analisando a Figura 39 sob o ponto de vista da corrente, espera-se que apenas os medidores a montante do defeito sejam sensibilizados. Assim, por exemplo, espera-se que o "Defeito 1" provoque variações na corrente apenas no primeiro medidor, devido ao fato de que o alimentador de distribuição em questão é radial e não há fluxo de corrente em sentido reverso. Por outro lado, como o defeito aplicado é assimétrico, pontos à sua jusante apresentam um desequilíbrio de tensão e, assim, espera-se que o "Medidor 3" detecte variações em  $V_1$  e  $V_2$  durante o "Defeito 1" e "Defeito 2".

Para melhor explicar os aspectos anteriores, observa-se a situação apresentada na Figura 40, envolvendo os defeitos no início e meio do alimentador de distribuição, analisados individualmente, ou seja, não simultâneos, além dos medidores no início e no fim deste alimentador. Para esta situação, a Tabela 5 apresenta a variação nos fasores de tensão e corrente medidos nos medidores quando se altera o ponto do curto-circuito, ou seja, a variação nos fasores entre os "Defeitos 1 e 2". Esta variação foi obtida para um período específico da curva de carga do alimentador.

Figura 40 – Alimentador de distribuição com "Defeitos 1 e 2".



Fonte: Elaborada pelo autor (2020).

Tabela 5 – Variação percentual entre defeitos

	$\dot{V}_0$	$\dot{V}_1$	$\dot{V}_2$	$\dot{I}_0$	$\dot{I}_1$	$\dot{I}_2$
<b>Medidor 1</b>	0	0	0.0663	0	0.1	0.0943
<b>Medidor 3</b>	0.07	2	3.2	0	0	0.01

Fonte: Elaborada pelo autor (2020).

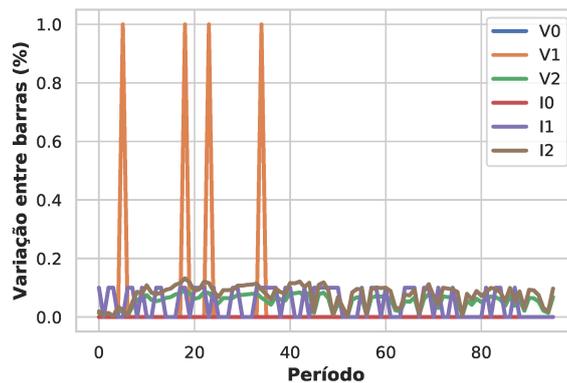
Observa-se na Tabela 5 que, para o "Medidor 1", a maior variação percentual ocorre para o fasor  $|\dot{I}_1|$  que, no entanto, é significativamente inferior à maior variação verificada no "Medidor 3", para  $|\dot{V}_2|$ . Este comportamento é explicado pelo fato do defeito ser de

alta impedância, o que atenua as correntes de defeito. Portanto, embora seja justificável a maior variação no "Medidor 1" ocorrer para a corrente  $|\dot{I}_1|$ , uma vez que este medidor está à montante dos defeitos, esta variação não é mais significativa do que a variação de tensão no "Medidor 3".

Por outro lado, no "Medidor 3", observa-se variações maiores neste caso, pois sendo um medidor à jusante dos defeitos, consegue detectar o desequilíbrio de tensão provocado pelos mesmos, através de uma variação significativa em  $|\dot{V}_1|$  e  $|\dot{V}_2|$ , neste caso. Isto favorece, portanto, a localização, uma vez que o "Medidor 3" consegue diferenciar com eficácia os "Defeitos 1 e 2".

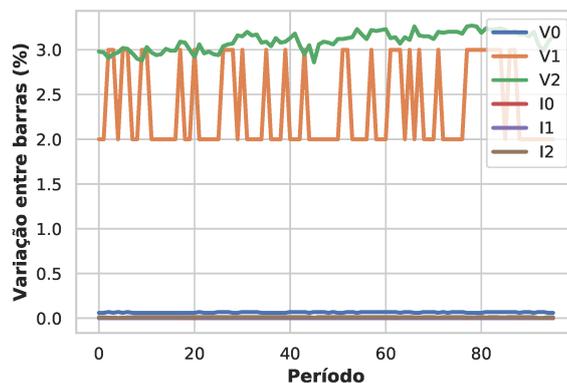
As Figuras 41 e 42 apresenta as variações nos fasores abordados anteriormente para todos os pontos da curva de carga, em que se pode observar variações significativas em tensão, devido ao desequilíbrio provocado pelos defeitos em derivação considerados. Isto justifica a utilização dos fasores de tensão como entradas da RNA-localização.

Figura 41 – Variação entre defeitos - Medidor 1.



Fonte: Elaborada pelo autor (2020).

Figura 42 – Variação entre defeitos - Medidor 3.

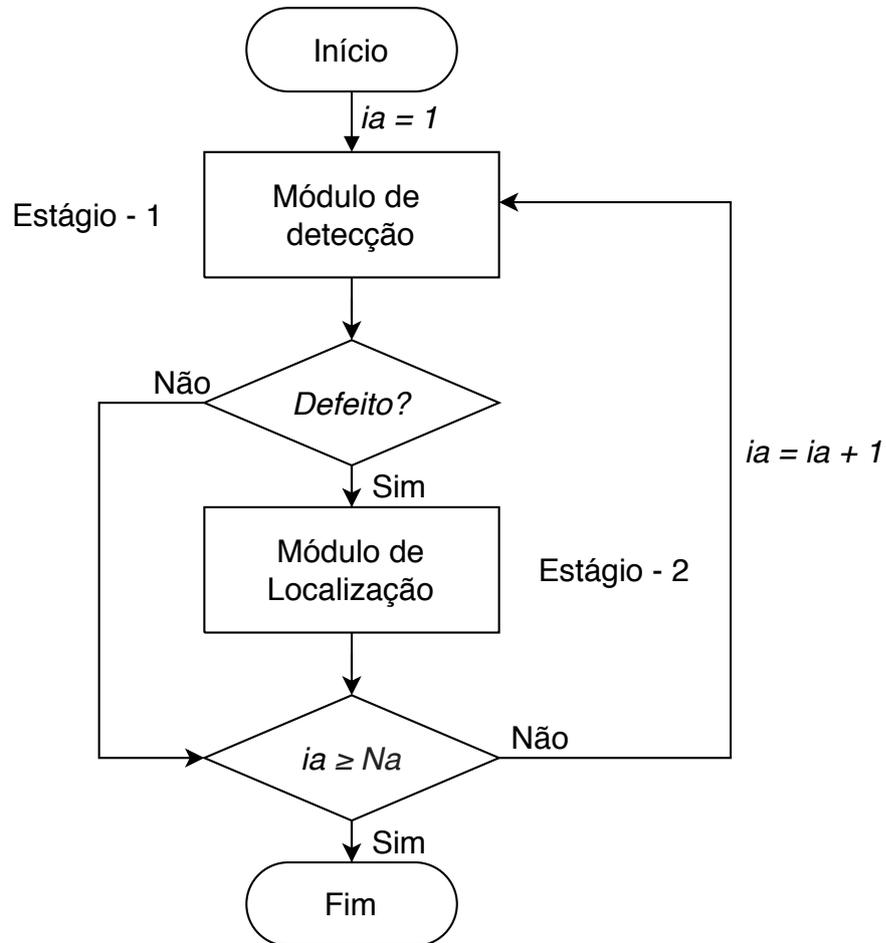


Fonte: Elaborada pelo autor (2020).

#### 4.4 ALGORITMO PROPOSTO

O fluxograma que faz a junção entre os módulos de detecção e localização é mostrado na Figura 43.

Figura 43 – Algoritmo proposto.



Fonte: Elaborada pelo autor (2020).

Em que:

$N_a$  Número de amostras.

Os estágios do algoritmo proposto da Figura 43 são os seguintes:

**Estágio-1** No primeiro estágio, analisa-se a amostra  $ia$  e verifica-se se a condição é de defeito ou não.

**Estágio-2** Caso, no primeiro estágio, uma amostra seja detectada como defeito, esta amostra é submetida ao módulo de localização do segundo estágio, para a localização do defeito.

Salienta-se que o fluxograma presente na Figura 43 é válido para amostras sem e com a presença de VE. Além disto, para a situação com VE, varia-se também o tipo de recarga utilizado. Com todas as amostras avaliadas, pode-se aferir o impacto da inserção de veículos e de diferentes tipos de recarga.



Na Figura, os círculos pretos e vermelhos representam as barras de baixa e média tensão com transformador de distribuição, respectivamente. Já os ícones verdes representam as barras de média tensão escolhidas. Observa-se que para este estudo,  $NBM = 6$  barras  $BM_{im}$  de média tensão do alimentador de distribuição sob estudo da rede de Búzios. O critério de escolha foi por barras distribuídas ao longo do alimentador, de modo a se ter uma amostra representativa de dados. Isto foi feito de modo que cada medidor inteligente tenha à sua jusante duas barras  $BM_{im}$ . Nas barras de média tensão escolhidas, existem um total de 80 barras de baixa tensão conectadas através de transformadores típicos de distribuição com potências nominais exibidas na Tabela 6. Conforme descrito no capítulo anterior, considera-se MI no alimentador, sendo um no início, ou seja, na subestação, outro em ponto intermediário e um terceiro no fim do alimentador. A Tabela 6 apresenta os dados das barras de média tensão escolhidas. Por fim, os ícones roxos da Figura 44 representam os três medidores inteligentes instalados, localizados na subestação e nos barramentos de média "BUZ05\_209" e "BUZ05\_472".

Tabela 6 – Detalhes sobre às barras de média tensão.

Nome	Barras de baixa tensão	Potência do transformador (kVA)
BUZ05_110	19	112.5
BUZ05_189	7	75
BUZ05_430	7	150
BUZ05_439	16	45
BUZ05_593	23	112.5
BUZ05_614	8	112.5

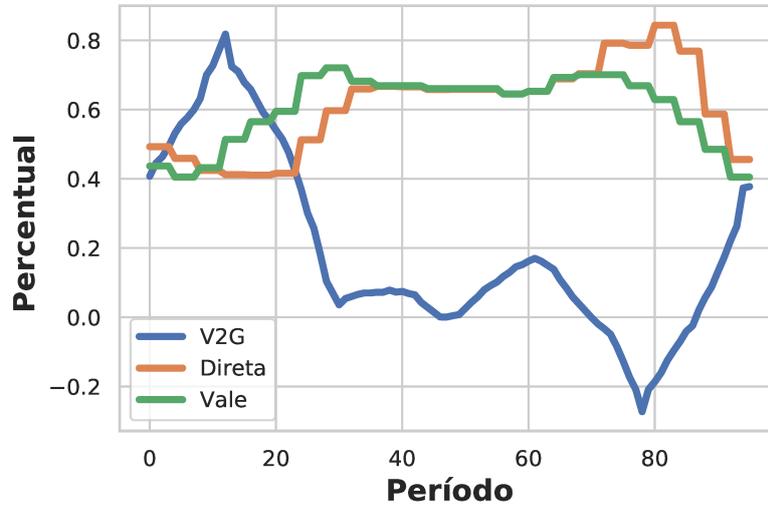
Fonte: Elaborada pelo autor (2020).

Observa-se que as barras escolhidas apresentam grandes variações no número de barras de baixa tensão conectadas. Este fato provoca um desequilíbrio no resultado, que é tratado através das métricas *Micro-average* e acurácia balanceada a fim de proporcionar uma análise assertiva.

## 5.2 DESCRIÇÃO DAS CONDIÇÕES DE SIMULAÇÃO

Para investigar o impacto da instalação de veículos elétricos e do tipo de recarga no problema de detecção e localização de defeitos de alta impedância, escolheu-se três barras, dentre as 80 de baixa tensão conectadas nas barras de média tensão escolhidas, bem distribuídas no ramal de baixa, para receber um posto de recarga bifásico com potência comercial de 7.4 kW. Para avaliar o impacto da recarga de VE, o tipo de recarga,  $tr$ , foi variado dentre opções cujas curvas são ilustradas na Figura 45.

Figura 45 – Curvas de recarga de VE.



Fonte: (JIN *et al.*, 2012; CAMPOZANA *et al.*, 2017).

A impedância de curto-circuito considerada no presente trabalho é de  $30\Omega$ , caracterizada como defeito de alta impedância. Conforme descrito anteriormente, a metodologia proposta envolve, neste estudo de caso, um total de seis RNAs, a saber:

$RNA_i^d$  RNA de detecção para o MI no início do alimentador;

$RNA_m^d$  RNA de detecção para o MI no meio do alimentador;

$RNA_f^d$  RNA de detecção para o MI no final do alimentador;

$RNA_i^L$  RNA de localização para o MI no início do alimentador;

$RNA_m^L$  RNA de localização para o MI no meio do alimentador;

$RNA_f^L$  RNA de localização para o MI no final do alimentador.

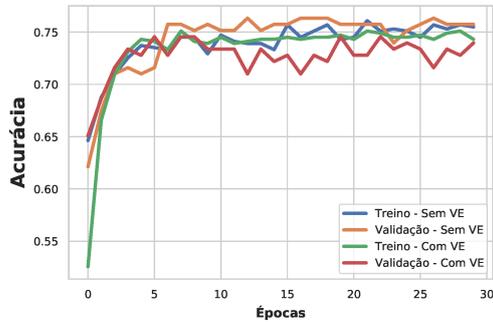
## 5.3 RESULTADOS

### 5.3.1 Recarga V2G

Primeiramente, tem-se o módulo de detecção para a recarga V2G. O passo inicial para avaliar as RNAs propostas é verificar a qualidade do treinamento para se observar questões como erro e acurácia, considerando aspectos de *overfitting* e *underfitting*. Mais precisamente, o erro está associado à qualidade do treinamento, enquanto que acurácia, que representa a taxa de acerto global, não implica, necessariamente, qualidade. Por exemplo, em caso de sobreajuste, a RNA perde a capacidade de generalização, com alta acurácia para o conjunto de treinamento e baixa acurácia para o conjunto de teste.

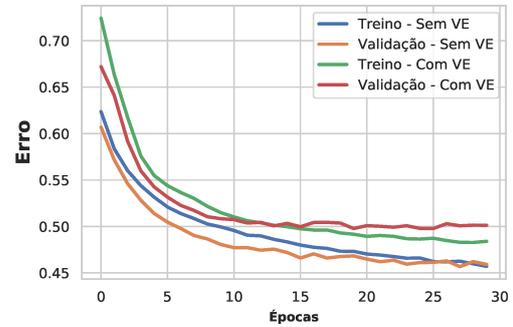
As curvas de treinamento e validação para as três RNA-deteccção,  $RNA_i^d$ ,  $RNA_m^d$  e  $RNA_f^d$ , são apresentadas nas Figuras 46-51.

Figura 46 – Acurácia -  $RNA_i^d$ ,  
Recarga V2G.



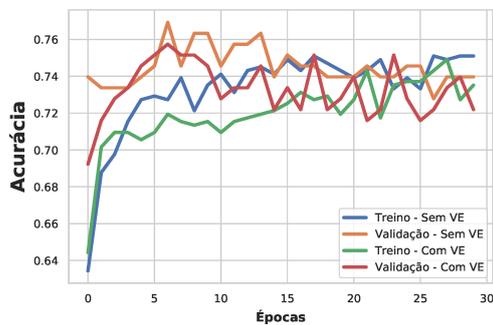
Fonte: Elaborada pelo autor (2020).

Figura 47 – Erro -  $RNA_i^d$ ,  
Recarga V2G.



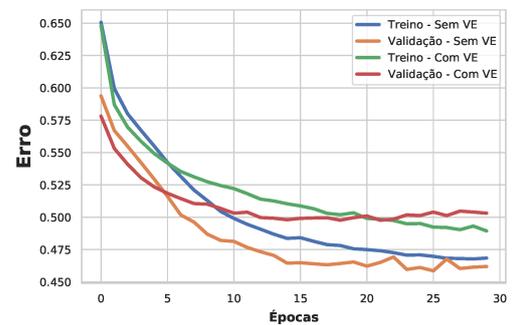
Fonte: Elaborada pelo autor (2020).

Figura 48 – Acurácia -  $RNA_m^d$ ,  
Recarga V2G.



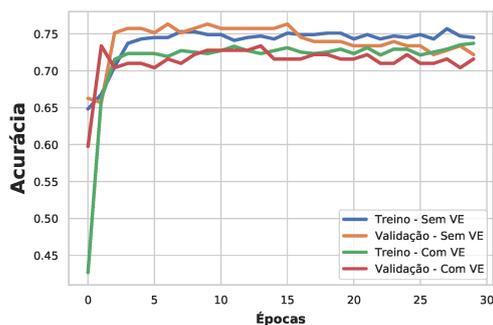
Fonte: Elaborada pelo autor (2020).

Figura 49 – Erro -  $RNA_m^d$ ,  
Recarga V2G.



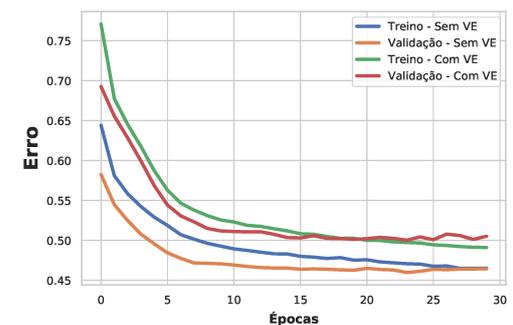
Fonte: Elaborada pelo autor (2020).

Figura 50 – Acurácia -  $RNA_f^d$ ,  
Recarga V2G.



Fonte: Elaborada pelo autor (2020).

Figura 51 – Erro -  $RNA_f^d$ ,  
Recarga V2G.



Fonte: Elaborada pelo autor (2020).

Observa-se nas Figuras 46-51 que, em todas as RNAs, quando se considera veículo elétrico no SDEE, percebe-se um aumento no erro acompanhado de um decréscimo na acurácia, evidenciado uma piora na qualidade do treinamento. Reforça-se que isto ocorre tanto para o conjunto de treinamento quanto o de validação, no entanto, maiores conclusões só podem ser retiradas através das métricas de avaliação aplicadas no conjunto de teste, observadas nas Figuras 52-55, considerando as quatro estratégias definidas no capítulo anterior, ou seja:

**Estratégia-1** Considerando apenas a  $RNA_i^d$ ;

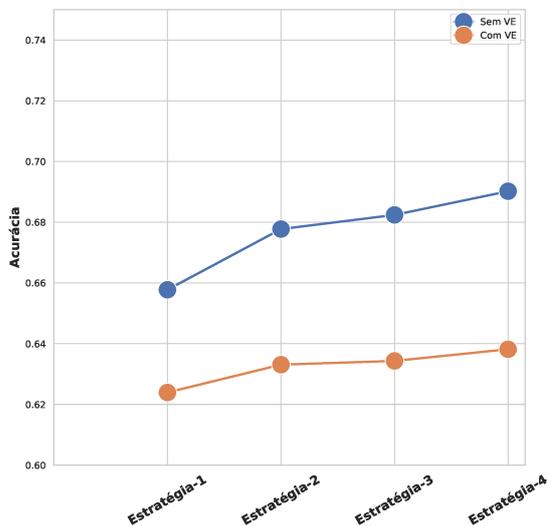
**Estratégia-2** Considerando  $RNA_i^d$  e  $RNA_m^d$ ;

**Estratégia-3** Considerando  $RNA_i^d$  e  $RNA_f^d$ ;

**Estratégia-4** Considerando  $RNA_i^d$ ,  $RNA_m^d$  e  $RNA_f^d$ .

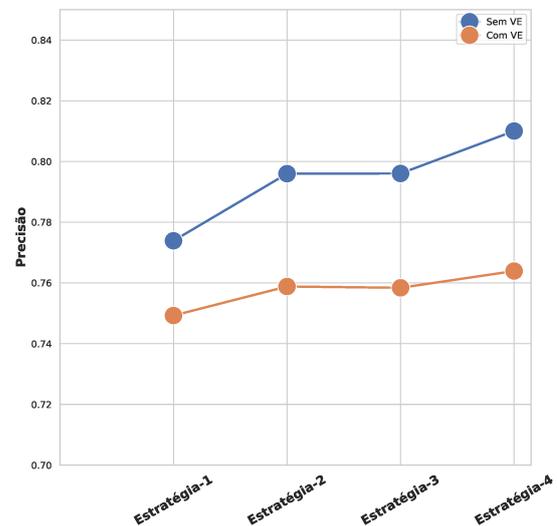
Destaca-se que os pontos marcados nas figuras representam as medianas dos resultados de todas as execuções.

Figura 52 – Acurácia - Detecção, Recarga V2G.



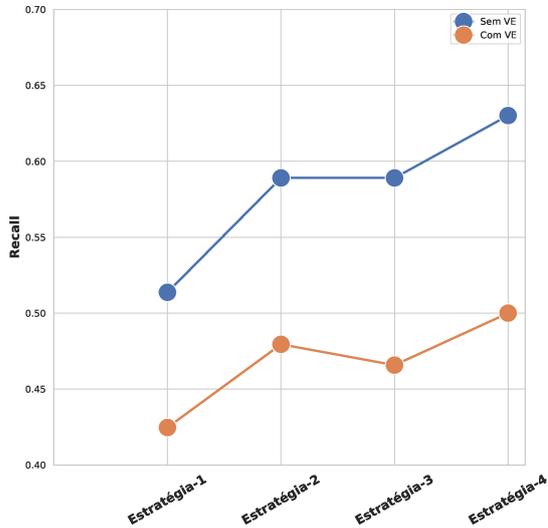
Fonte: Elaborada pelo autor (2020).

Figura 53 – Precisão - Detecção, Recarga V2G.



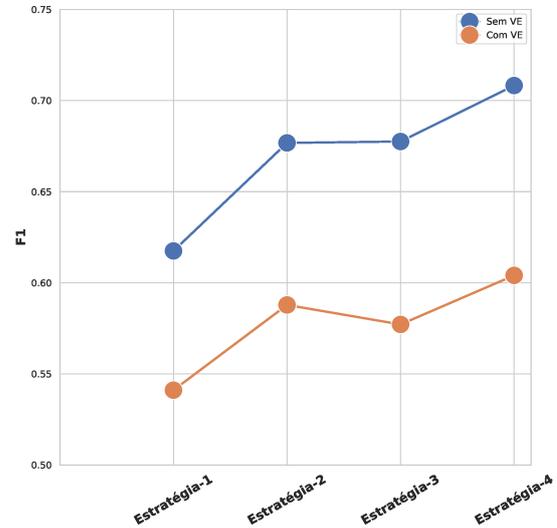
Fonte: Elaborada pelo autor (2020).

Figura 54 – Recall - Detecção, Recarga V2G.



Fonte: Elaborada pelo autor (2020).

Figura 55 – F1 - Detecção, Recarga V2G.



Fonte: Elaborada pelo autor (2020).

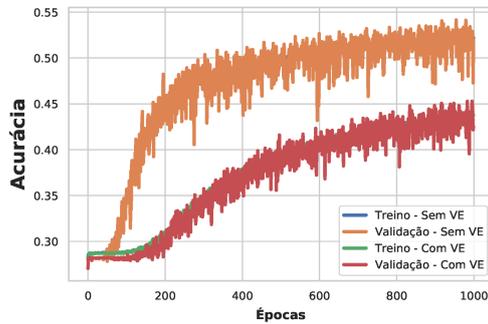
Observa-se num primeiro momento que em todas as métricas apresentadas nas Figuras 52-55 a situação sem veículo elétrico apresentou um resultado melhor que a situação com veículo elétrico. Isto pode ser explicado porque na recarga V2G, no momento de pico de carga, o VE fornece potência para a rede, contribuindo para a corrente de defeito e atenuando a corrente vista pelos MIs, dificultando, portanto, o processo de detecção.

Outra conclusão importante e esperada é que a presença de maior número de MIs, Estratégia-4, aumenta o desempenho do sistema de detecção. Ainda nesta linha de comparação, caso a opção seja por apenas dois MIs, a Estratégia-2 é a mais adequada, por prover maior cobertura de pontos a jusante pelo segundo medidor, localizado no meio do alimentador.

Cabe destacar que na aplicação proposta, o mais importante é minimizar falsos negativos, ou seja, maximizar a métrica *recall*. Esta precedência em termos de importância deve-se ao fato de que um falso negativo significa que a RNA-deteção não acusa a ocorrência de um defeito em uma amostra associada a curto-circuito, o que pode resultar em acidentes com cabos caídos ao solo. Por outro lado, tem-se a precisão, que neste caso pode ser interpretada como uma taxa de acerto dos defeitos previstos, além da métrica F1, que é uma composição entre *recall* e precisão. Salienta-se que para a deteção focou-se apenas na classe defeito, assim, para esse caso, precisão é uma taxa de acerto dos defeitos previstos e *recall* a taxa de acerto dos defeitos existentes.

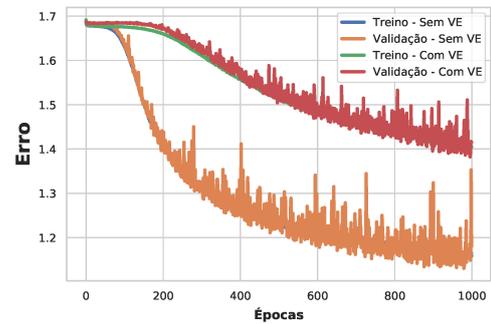
Sobre as RNAs-localização dos três MIs deste estudo,  $RNA_i^L$ ,  $RNA_m^L$  e  $RNA_f^L$ , tem-se as curvas mostradas nas Figuras 56-61 para treinamento e validação.

Figura 56 – Acurácia -  $RNA_i^L$ ,  
Recarga V2G.



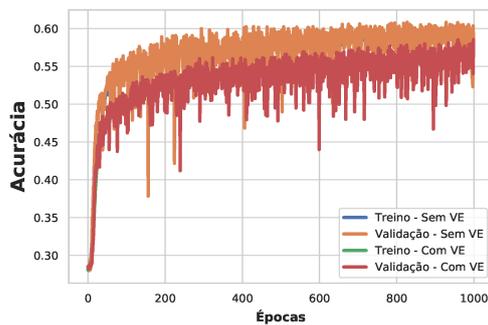
Fonte: Elaborada pelo autor (2020).

Figura 57 – Erro -  $RNA_i^L$ ,  
Recarga V2G.



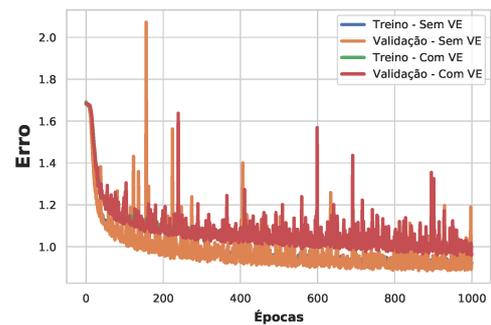
Fonte: Elaborada pelo autor (2020).

Figura 58 – Acurácia -  $RNA_m^L$ ,  
Recarga V2G.



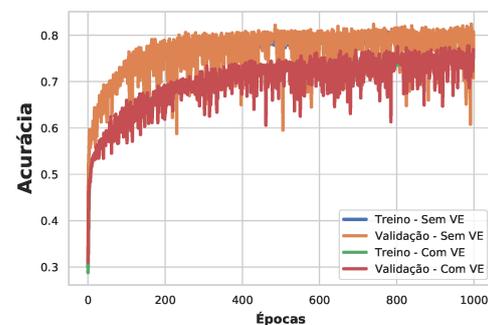
Fonte: Elaborada pelo autor (2020).

Figura 59 – Erro -  $RNA_m^L$ ,  
Recarga V2G.



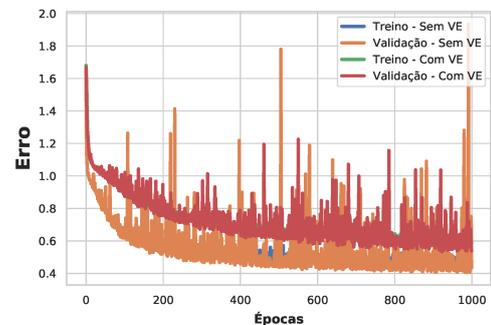
Fonte: Elaborada pelo autor (2020).

Figura 60 – Acurácia -  $RNA_f^L$ ,  
Recarga V2G.



Fonte: Elaborada pelo autor (2020).

Figura 61 – Erro -  $RNA_f^L$ ,  
Recarga V2G.



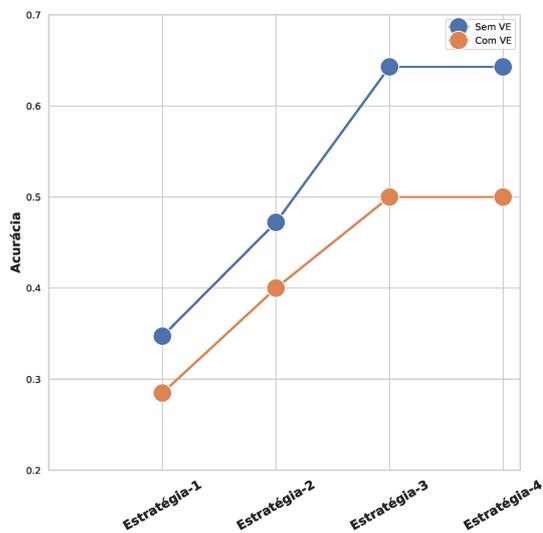
Fonte: Elaborada pelo autor (2020).

Observa-se que, como no módulo de detecção, a presença de VE impacta de forma negativa no desempenho do treinamento e da validação, devido à característica de recarga V2G explicada anteriormente. Além disto, especificamente nas RNAs-localização, observa-se uma variação durante estes processos, treinamento e validação que, nestas RNAs, não foi possível ser eliminada através do ajuste da taxa de aprendizado. Destaca-se a importância deste ajuste de forma empírica para combinar poucas oscilações no treinamento, através de uma taxa muito elevada, com perda de desempenho através de uma taxa muito reduzida. Apesar das variações durante o treinamento e a validação, não houve variação significativa no erro e na acurácia finais, após a convergência do processo de treinamento.

Importante conclusão é a de que o MI mais à jusante no alimentador é aquele cuja RNA tende ao melhor desempenho. Ou seja, em ordem decrescente de desempenho, tem-se  $RNA_f^L$  -  $RNA_m^L$  -  $RNA_i^L$ .

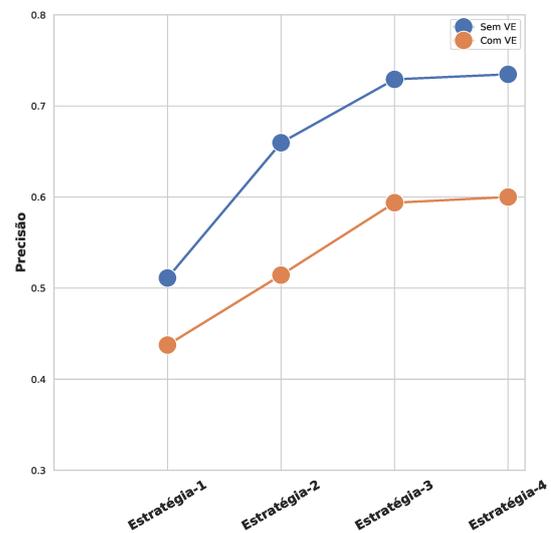
As métricas de avaliação aplicadas ao conjunto teste das RNAs-localização são ilustradas através das curvas apresentadas nas Figuras 62-65.

Figura 62 – Acurácia - Localização, Recarga V2G.



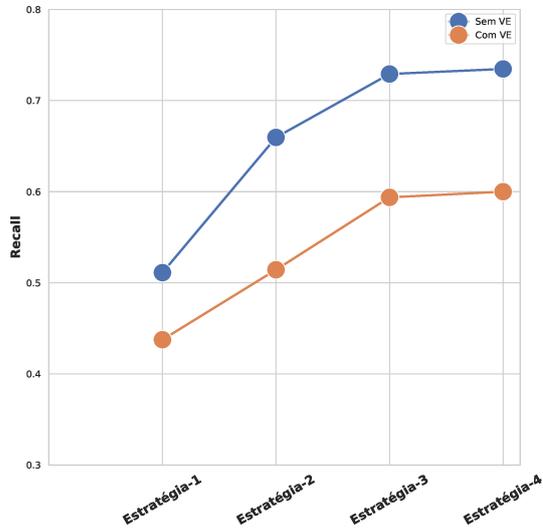
Fonte: Elaborada pelo autor (2020).

Figura 63 – Precisão - Localização, Recarga V2G.



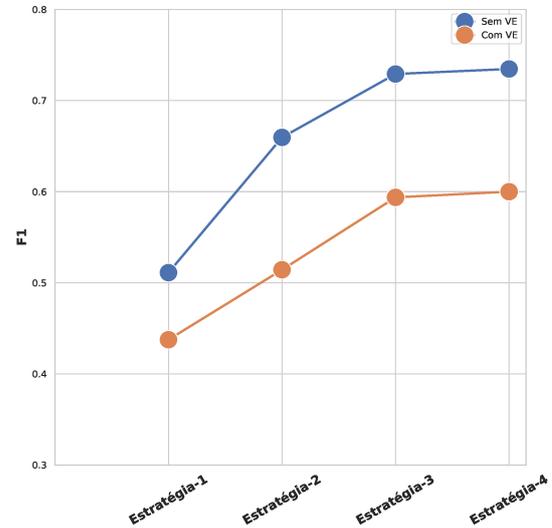
Fonte: Elaborada pelo autor (2020).

Figura 64 – Recall - Localização, Recarga V2G.



Fonte: Elaborada pelo autor (2020).

Figura 65 – F1 - Localização, Recarga V2G.



Fonte: Elaborada pelo autor (2020).

Verifica-se, a partir das métricas apresentadas, um desempenho melhor das RNAs-localização sem a presença de VE. Além disto, do ponto de vista da localização, o melhor arranjo de topologia para esse tipo de recarga é com o medidor na subestação em conjunto com o medidor instalado no fim da rede elétrica. Isso corrobora com o que foi dito sobre medidores a jusante do ponto de defeito terem melhor desempenho. Como o medidor no fim da rede elétrica é exposto a mais variações nas tensões, que são consequências dos defeitos de alta impedância aplicados, este tem um desempenho melhor do que qualquer outro medidor, elevando o desempenho da composição quando este está presente. Observando as imagens das métricas para a localização desse tipo de recarga, nota-se que as Figuras 63-65 são iguais. Para explicar esse comportamento, observa-se a Tabela 7 baseada em (SHMUELI, 2019).

Tabela 7 – Tabela verdade exemplo

		Real		
		Gato	Peixe	Galinha
Predito	Gato	4	6	3
	Peixe	1	2	0
	Galinha	1	2	6

Fonte: Elaborada pelo autor (2020).

Em que Gato refere-se a Classe-1, Peixe relaciona-se com Classe-2 e Galinha com a Classe-3

Para este problema, tem-se:

**Classe-1**  $VP_1 = 4$  e  $FP_1 = 6 + 3$  e  $FN_1 = 1 + 1$

**Classe-2**  $VP_2 = 2$  e  $FP_2 = 1 + 0$  e  $FN_2 = 6 + 2$

**Classe-3**  $VP_3 = 6$  e  $FP_3 = 1 + 2$  e  $FN_3 = 3 + 0$

Observa-se que os falsos positivos foram formados pelos erros nas linhas, já os falsos negativos são formados pelos erros nas colunas. Utilizando a expressão (2.36) para apenas três classes, chega-se na expressão (5.1) da *Micro-average* para a precisão.

$$Micro - average = \frac{4 + 2 + 6}{4 + 2 + 6 + 9 + 1 + 3} \quad (5.1)$$

Já para o *recall*, tem-se a expressão (5.2) para a *Micro-average*, baseada em (2.39).

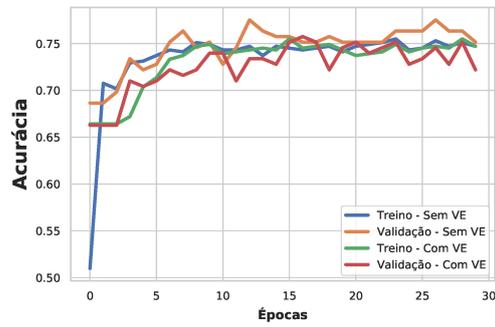
$$Micro - average = \frac{4 + 2 + 6}{4 + 2 + 6 + 2 + 8 + 3} \quad (5.2)$$

Observa-se que a soma do numerador e do denominador nas duas situações são iguais, portanto, a *Micro-average* para a precisão e para o *recall* são iguais. Isto ocorre porque se, por exemplo, a Classe-1 for classificada de forma errada como Classe-2, esta classificação é um falso positivo para Classe-2, mas também é um falso negativo para Classe-1. Assim, o total de falsos positivos e falsos negativos terá sempre o mesmo valor, explicando o porque dos gráficos de *recall* e de precisão serem iguais nas figuras 63 e 64, já que para lidar com o desbalanceamento entre as classes, utilizou-se a métrica *Micro-average*. Observa-se que, como a métrica F1 é uma média harmônica entre a precisão e a *recall*, se as duas forem iguais a F1, gerarão o mesmo valor.

### 5.3.2 Recarga direta

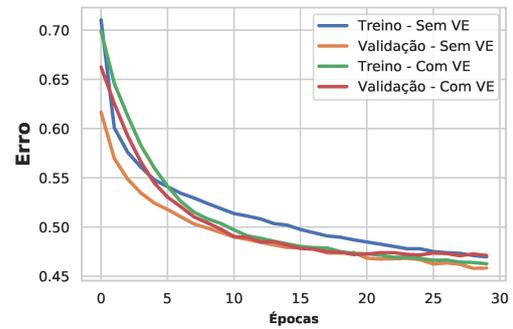
Conforme descrito no presente trabalho, a recarga direta é aquela cuja curva permite que o VE seja recarregado em qualquer momento decidido pelo usuário, sem interferência da concessionária. Para este tipo de recarga, tem-se as curvas de treinamento e validação para as três RNA-detecção,  $RNA_i^d$ ,  $RNA_m^d$  e  $RNA_f^d$ , apresentadas nas Figuras 66-71.

Figura 66 – Acurácia -  $RNA_i^d$ ,  
Recarga direta.



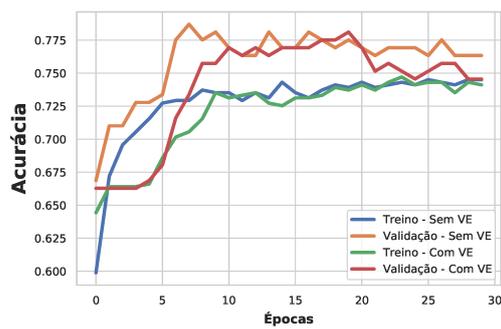
Fonte: Elaborada pelo autor (2020).

Figura 67 – Erro -  $RNA_i^d$ ,  
Recarga direta.



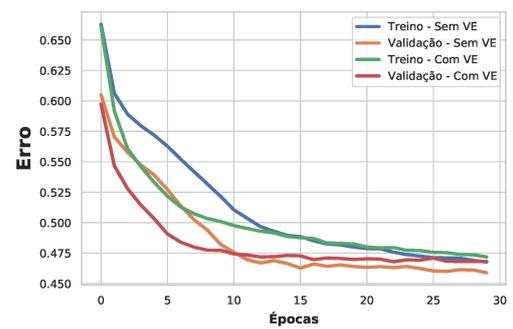
Fonte: Elaborada pelo autor (2020).

Figura 68 – Acurácia -  $RNA_m^d$ ,  
Recarga direta.



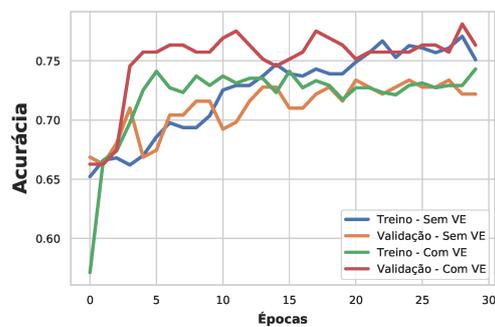
Fonte: Elaborada pelo autor (2020).

Figura 69 – Erro -  $RNA_m^d$ ,  
Recarga direta.



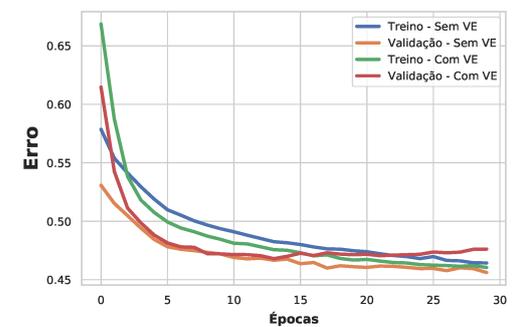
Fonte: Elaborada pelo autor (2020).

Figura 70 – Acurácia -  $RNA_f^d$ ,  
Recarga direta.



Fonte: Elaborada pelo autor (2020).

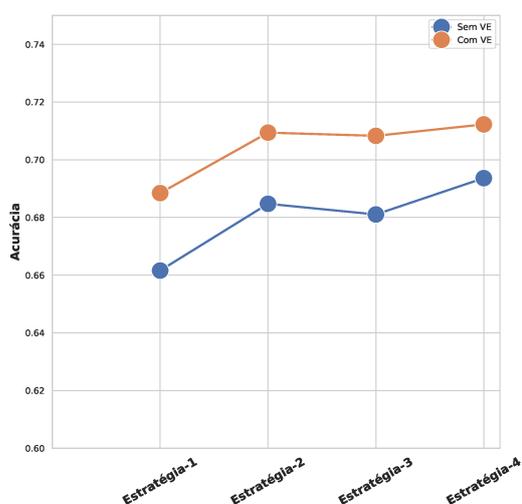
Figura 71 – Erro -  $RNA_f^d$ ,  
Recarga direta.



Fonte: Elaborada pelo autor (2020).

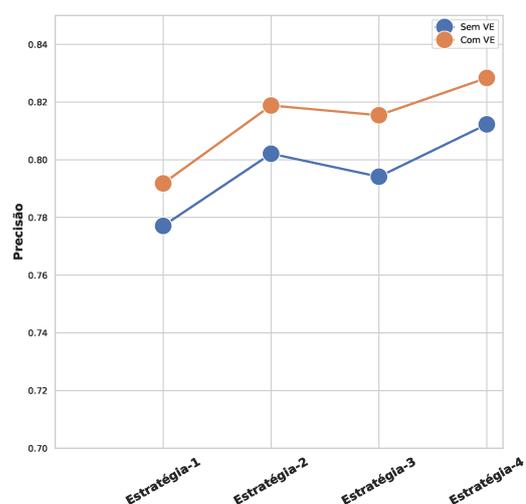
Observa-se nas Figuras 66-71 que o número de épocas escolhido foi satisfatório, uma vez que houve estabilização da curva de erro em um nível mínimo e da curva de acurácia em um nível máximo. Através destas curvas de treinamento e validação, não se pode concluir sobre o impacto da presença de VE para o tipo de recarga direta. As Figuras 72-75 apresentam as métricas obtidas para o conjunto de teste da detecção.

Figura 72 – Acurácia - Detecção,  
Recarga direta.



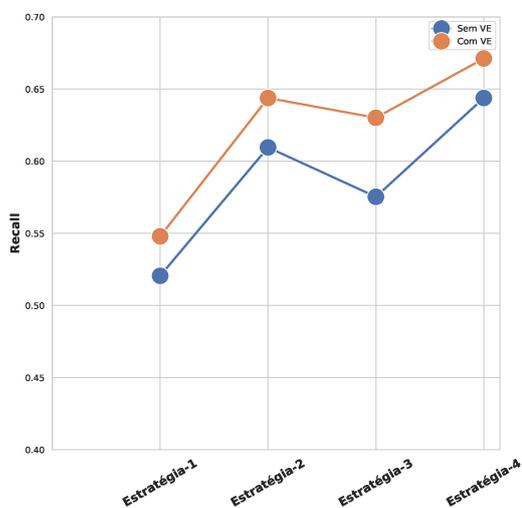
Fonte: Elaborada pelo autor (2020).

Figura 73 – Precisão - Detecção,  
Recarga direta.



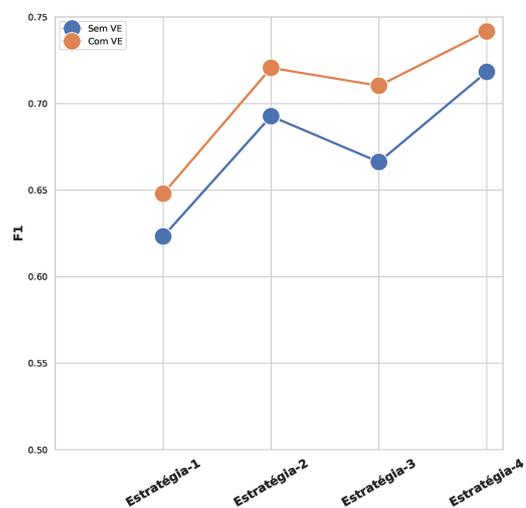
Fonte: Elaborada pelo autor (2020).

Figura 74 – Recall - Detecção,  
Recarga direta.



Fonte: Elaborada pelo autor (2020).

Figura 75 – F1 - Detecção,  
Recarga direta.



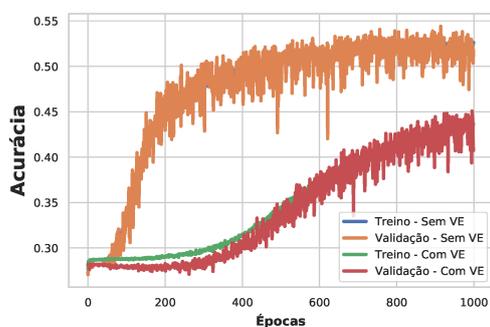
Fonte: Elaborada pelo autor (2020).

Observa-se que, com base nas métricas utilizadas, de forma semelhante ao que ocorreu no módulo de detecção da recarga V2G, a melhor opção para situações com dois medidores é a Estratégia-2. Observando todas as métricas apresentadas, em especial a métrica *recall* devido à importância dos falsos negativos, observa-se resultados satisfatórios, todos em torno ou acima de 60%. Salienta-se que, observando as figuras, a Estratégia-1, em que há medição apenas na subestação, é a menos eficaz, uma vez que os resultados ficam em torno de 50%.

Caso apenas uma métrica tivesse que ser escolhida para demonstrar a eficiência da RNA, a escolha correta seria a apresentada na Figura 75, que corresponde a uma média harmônica entre *recall* e precisão. Observa-se que o uso desta métrica é importante porque, para o módulo de detecção, há um desequilíbrio entre as classes a serem identificadas, pois amostras de condição operativa normal são em maior número do que amostras de defeito. Além disto, como mostrado na Tabela 6, há um desequilíbrio entre as barras de média escolhidas.

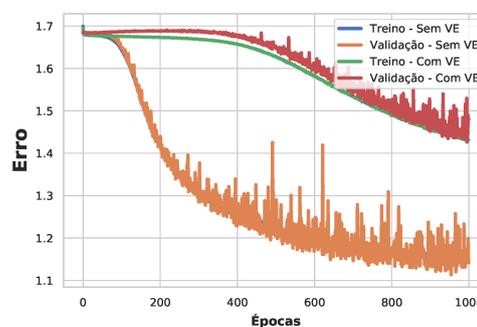
Seguindo, para o módulo de localização, tem-se as curvas das Figuras 76-81, que ilustram os processos de treinamento e validação das RNAs-localização dos três MIs,  $RNA_i^L$ ,  $RNA_m^L$  e  $RNA_f^L$ .

Figura 76 – Acurácia -  $RNA_i^L$ ,  
Recarga direta.



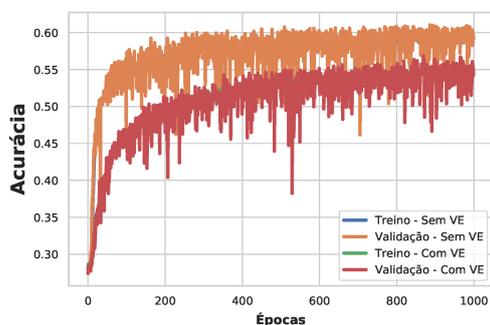
Fonte: Elaborada pelo autor (2020).

Figura 77 – Erro -  $RNA_i^L$ ,  
Recarga direta.



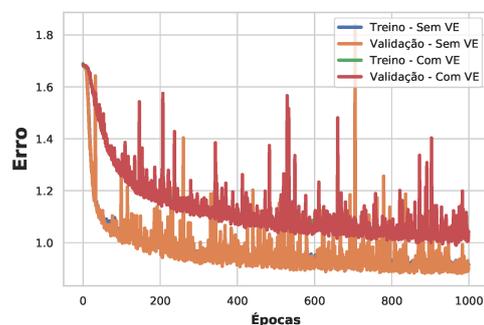
Fonte: Elaborada pelo autor (2020).

Figura 78 – Acurácia -  $RNA_m^L$ ,  
Recarga direta.



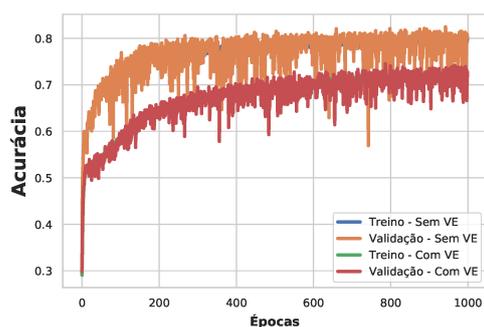
Fonte: Elaborada pelo autor (2020).

Figura 79 – Erro -  $RNA_m^L$ ,  
Recarga direta.



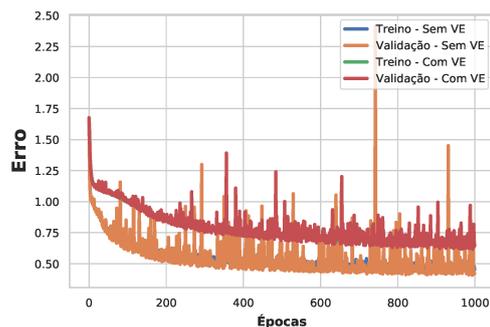
Fonte: Elaborada pelo autor (2020).

Figura 80 – Acurácia -  $RNA_f^L$ ,  
Recarga direta.



Fonte: Elaborada pelo autor (2020).

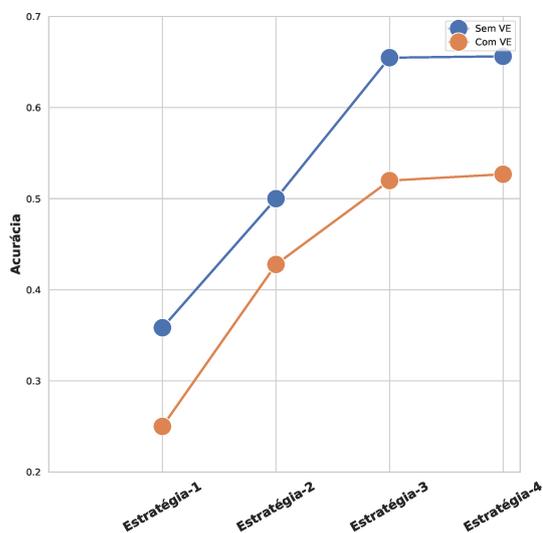
Figura 81 – Erro -  $RNA_f^L$ ,  
Recarga direta.



Fonte: Elaborada pelo autor (2020).

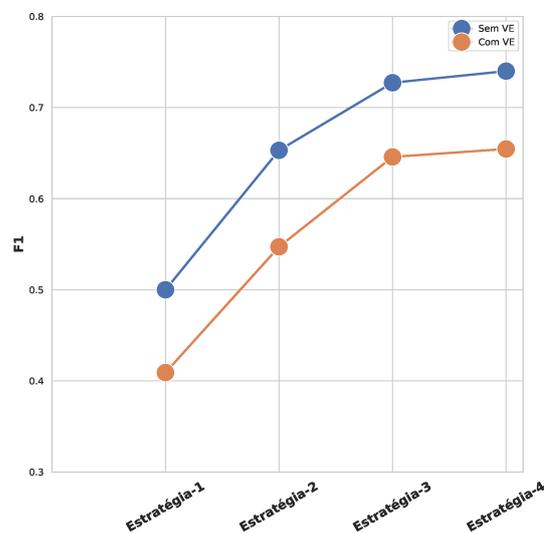
Também para o módulo de localização, pode-se observar que o número de épocas escolhido é suficiente para a estabilização dos processos das RNAs. Outro ponto a se observar é que, como ocorreu no módulo de localização da curva de recarga V2G, ocorrem variações durante o processo de treinamento. As Figuras 82-83 apresentam as métricas utilizadas para avaliar o conjunto de teste.

Figura 82 – Acurácia - Localização,  
Recarga direta.



Fonte: Elaborada pelo autor (2020).

Figura 83 – F1 - Localização,  
Recarga direta.



Fonte: Elaborada pelo autor (2020).

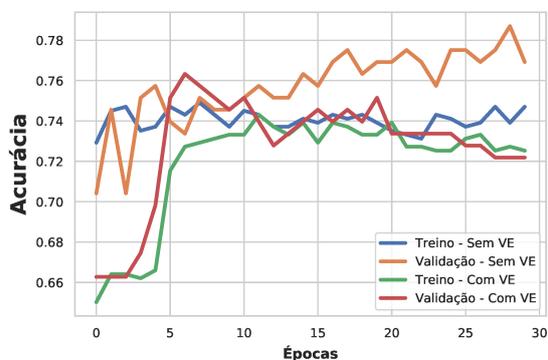
Observa-se nas Figuras 82-83 que a situação sem VE tem melhor desempenho do que com VE, de modo semelhante ao que ocorreu no módulo de localização da curva de recarga V2G. Além disso, de modo semelhante ao ocorrido para o tipo V2G, a melhor topologia com dois medidores é a que conta com o medidor na subestação e no fim da rede elétrica. Este comportamento se explica pela maior eficiência de medidores mais a jusante do ponto de defeito, devido ao desequilíbrio de tensão.

Por fim, somente as métricas acurácia e F1 são apresentadas para este tipo de recarga direta, pois o restante das métricas ocultadas conduz à mesma conclusão que F1.

### 5.3.3 Recarga no vale

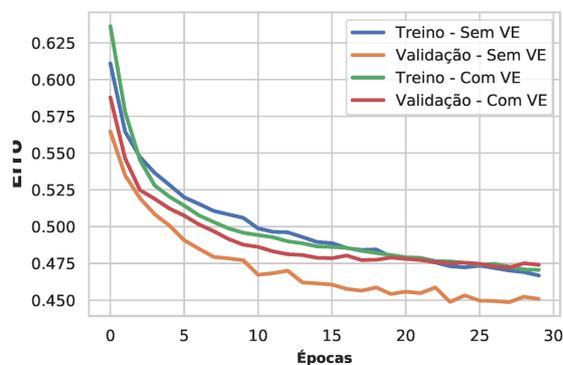
Neste tipo, em que incentivos são dados pela concessionária para que usuários optem pela recarga em momentos fora do pico da curva de carga, observa-se que, de forma semelhante ao tipo anterior, não há injeção de potência na rede elétrica pelo VE. As Figuras 84-89 apresentam as curvas de treinamento e validação para as RNAs-detecção.

Figura 84 – Acurácia -  $RNA_i^d$ ,  
Recarga no vale.



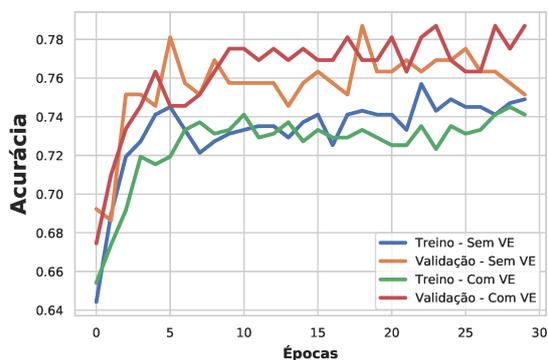
Fonte: Elaborada pelo autor (2020).

Figura 85 – Erro -  $RNA_i^d$ ,  
Recarga no vale.



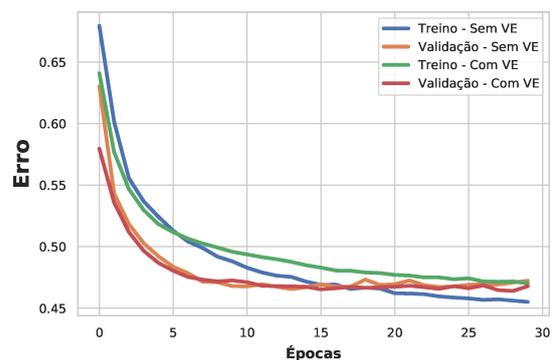
Fonte: Elaborada pelo autor (2020).

Figura 86 – Acurácia -  $RNA_m^d$ ,  
Recarga no vale.



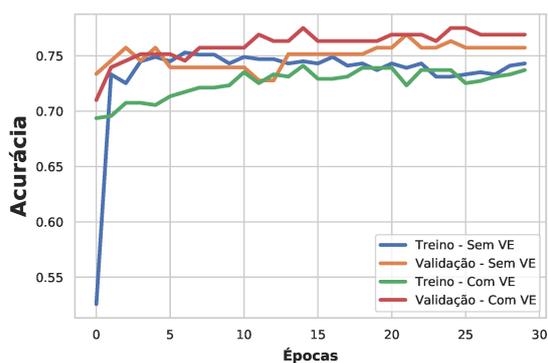
Fonte: Elaborada pelo autor (2020).

Figura 87 – Erro -  $RNA_m^d$ ,  
Recarga no vale.



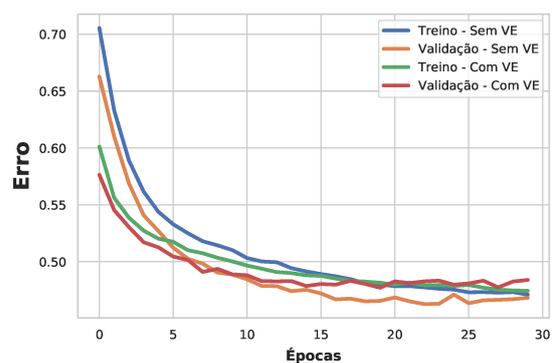
Fonte: Elaborada pelo autor (2020).

Figura 88 – Acurácia -  $RNA_f^d$ ,  
Recarga no vale.



Fonte: Elaborada pelo autor (2020).

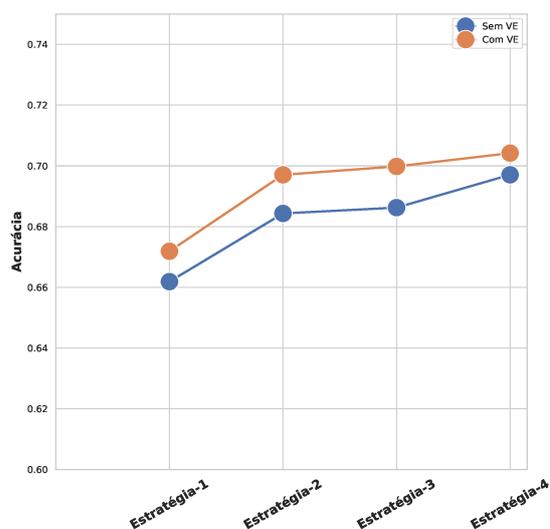
Figura 89 – Erro -  $RNA_f^d$ ,  
Recarga no vale.



Fonte: Elaborada pelo autor (2020).

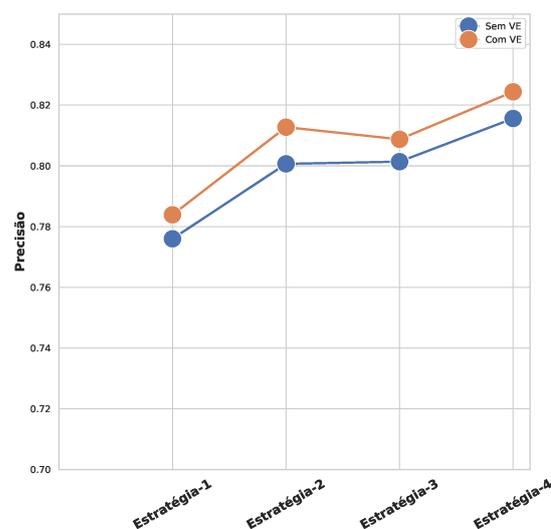
Observa-se nas Figuras 84-89 que não ocorre problemas como *overfitting* e *underfitting*, portanto, o número de épocas escolhido é suficiente para garantir a capacidade de generalização das RNAs. Nota-se que não há grandes diferenças entre as curvas de cada medidor, e que os erros e as acurácias apresentam as mesmas faixas de valores. As Figuras 90-93 apresentam os resultados para o conjunto teste através das métricas de avaliação.

Figura 90 – Acurácia - Detecção,  
Recarga no vale.



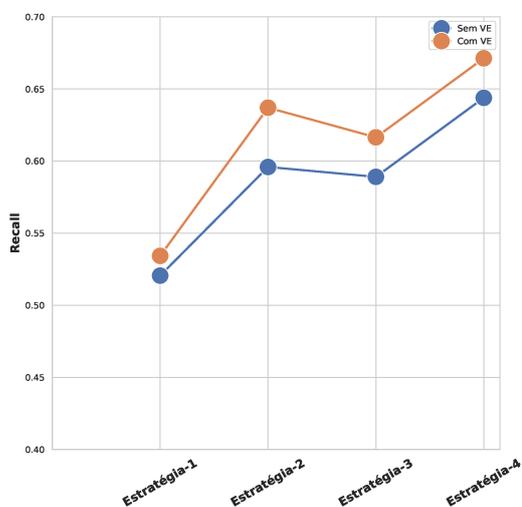
Fonte: Elaborada pelo autor (2020).

Figura 91 – Precisão - Detecção,  
Recarga no vale.



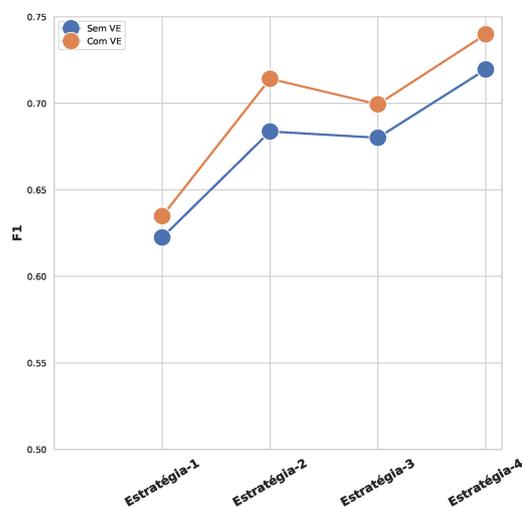
Fonte: Elaborada pelo autor (2020).

Figura 92 – Recall - Detecção,  
Recarga no vale.



Fonte: Elaborada pelo autor (2020).

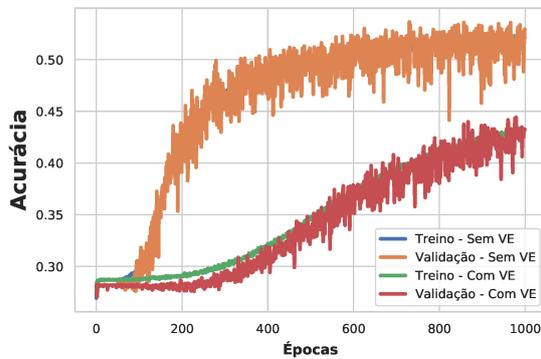
Figura 93 – F1 - Detecção,  
Recarga no vale.



Fonte: Elaborada pelo autor (2020).

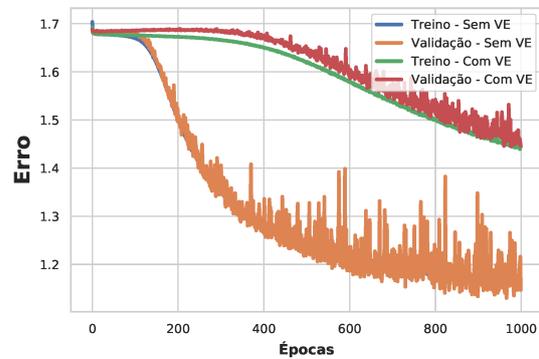
É importante observar que, de forma semelhante ao que ocorreu para todas as curvas de recarga, a Estratégia-2 teve melhor desempenho e esta deve ser escolhida do ponto de vista da detecção de defeitos, caso a concessionária adote apenas dois medidores. Este fato é embasado principalmente pela curva de *recall* que, conforme já discutido, lida com falsos negativos. Além disto, conforme esperado, a inserção de medidores inteligentes melhora a eficiência da detecção sob todas as métricas, ou seja, a Estratégia-1 teve pior desempenho e a Estratégia-4 obteve os melhores resultados. As Figuras 94-99 apresentam as curvas para o módulo de localização.

Figura 94 – Acurácia -  $RNA_i^L$ ,  
Recarga no vale.



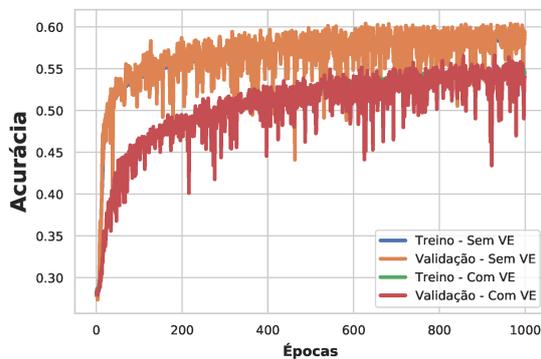
Fonte: Elaborada pelo autor (2020).

Figura 95 – Erro -  $RNA_i^L$ ,  
Recarga no vale.



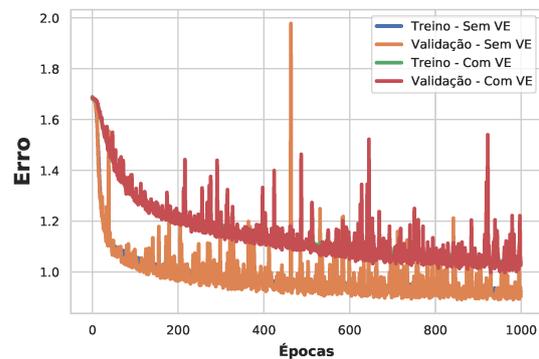
Fonte: Elaborada pelo autor (2020).

Figura 96 – Acurácia -  $RNA_m^L$ ,  
Recarga no vale.



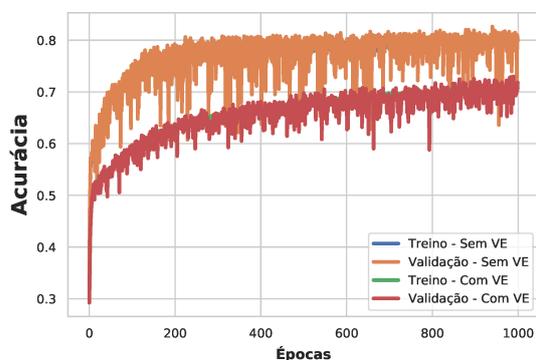
Fonte: Elaborada pelo autor (2020).

Figura 97 – Erro -  $RNA_m^L$ ,  
Recarga no vale.



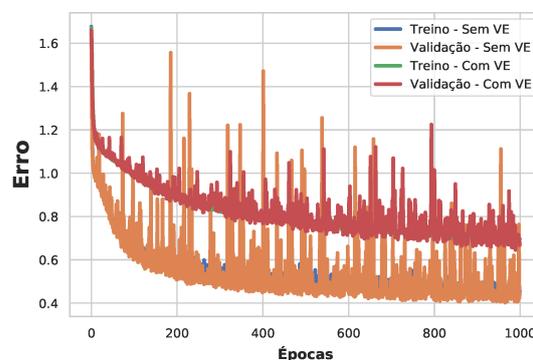
Fonte: Elaborada pelo autor (2020).

Figura 98 – Acurácia -  $RNA_f^L$ ,  
Recarga no vale.



Fonte: Elaborada pelo autor (2020).

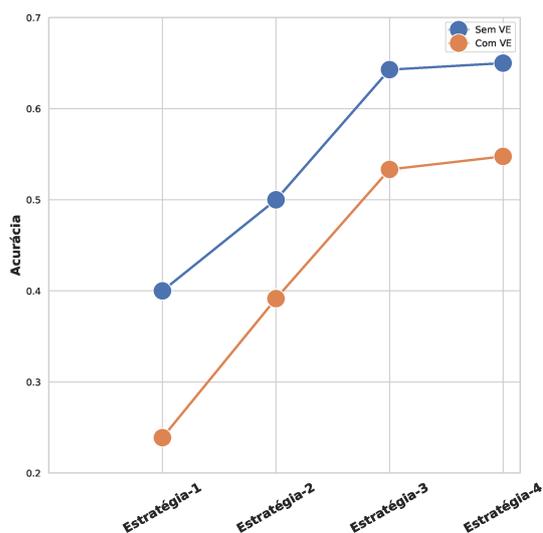
Figura 99 – Erro -  $RNA_f^L$ ,  
Recarga no vale.



Fonte: Elaborada pelo autor (2020).

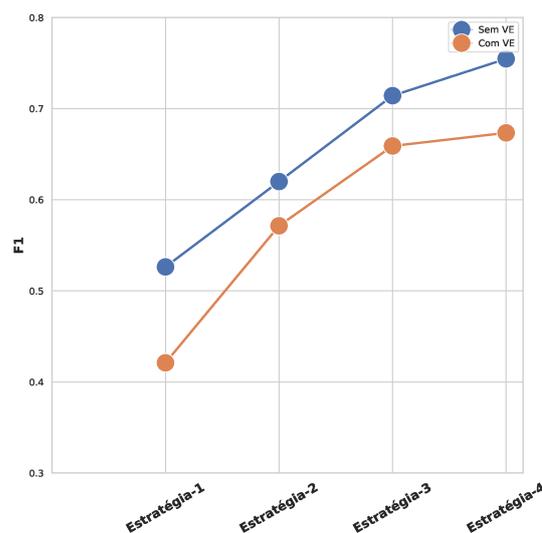
Observa-se nas Figuras 94-99 o mesmo comportamento do módulo de localização das outras curvas de recarga apresentadas. Assim, tem-se que o treinamento e a validação com VE tem pior desempenho do que a situação sem VE. Nota-se também que o número de épocas é satisfatório, ou seja, há uma estabilização das curvas no período apresentado. Por fim, as Figuras 100-101 apresentam as métricas de avaliação para o módulo de de localização.

Figura 100 – Acurácia - Localização,  
Recarga no vale.



Fonte: Elaborada pelo autor (2020).

Figura 101 – F1 - Localização,  
Recarga no vale.



Fonte: Elaborada pelo autor (2020).

O primeiro a se observar nas métricas apresentadas nas Figuras 100-101 é que conforme se adiciona medidores, melhora-se a qualidade da localização. Além disso, para

a situação com dois medidores, a melhor topologia é aquela formada pelo medidor na subestação e no fim da rede elétrica, portanto, Estratégia-3. Este fato corrobora para o argumento que medidores a jusante do defeito são mais sensibilizados para defeitos de alta impedância dos que os medidores a montante, devido aos desequilíbrios de tensão.

### 5.3.4 Discussão dos Resultados

A partir dos resultados anteriormente apresentados, verifica-se que para a recarga V2G, há impacto significativo da inserção de veículos elétricos em redes de distribuição no problema de detecção e localização de defeitos. Para o módulo de detecção, verifica-se que o impacto prejudica a detecção de defeitos de alta impedância, tornando-a menos assertiva, fato corroborado através das métricas de avaliação. Para essa curva de recarga, conclui-se que a corrente de defeito fica dividida entre o VE e a subestação, diminuindo assim a corrente que circula pela rede durante o curto-circuito e dificultando sua detecção. Já para a localização, verifica-se que a inserção de VE também prejudica, pois altera o desequilíbrio de tensão. Assim, como este desequilíbrio impacta nas tensões de sequência positiva e negativa, entradas das RNAs, reduz a assertividade do módulo de localização.

Para as curvas de recarga direta e no vale, focando no módulo de detecção, não se pode retirar conclusões sobre o impacto da adição de veículos elétricos. Verificando os gráficos que mostram as métricas para o conjunto teste das duas curvas de recarga, observa-se que as situações sem e com VE tiveram resultados bem próximos e não conclusivos. Uma possível explicação é que, para estas curvas de recarga, os VE operam como uma carga vista pela rede elétrica, não contribuindo para a corrente de defeito e, portanto, não comprometendo a qualidade da detecção. Já para a localização, de forma semelhante ao que ocorreu na curva de recarga V2G, a adição de VE altera o desequilíbrio de tensão e, por consequência, as tensões  $\dot{V}_1$  e  $\dot{V}_2$  são impactadas, dificultando a localização.

## 6 CONCLUSÃO

Dessa forma, conclui-se esta dissertação de mestrado que procurou mostrar o impacto da adição dos veículos elétricos em conjunto com seus postos de recarga num sistema de distribuição real para o problema de detecção e localização de defeitos de alta impedância. Além disso, variou-se também a curva de recarga utilizada e verificou-se quais as consequências para o problema proposto. Observou-se que as topologias e os parâmetros escolhidos das redes neurais artificiais propostas, tanto para o módulo de detecção quanto para o módulo de localização, culminaram num treinamento e numa validação de boa qualidade. Dessa forma, observou-se através dos gráficos que mostram o processo de treinamento, que não ocorreu problemas como sobreajuste ou subajuste.

Quanto aos resultados, observou-se primeiramente que para o módulo de detecção, utilizando a curva de recarga V2G para os veículos elétricos, a situação sem VE mostrou uma maior eficiência do que a situação com VE. Isso ocorreu porque como em certos períodos do dia o VE recarregado através dessa curva injeta potência no SDEE, a alimentação do curto-circuito fica dividida entre subestação e VE, fazendo com que os efeitos do defeito não sensibilizem de forma significativa os medidores instalados ao longo da rede elétrica. Dessa forma, a detecção é mais eficiente para a situação sem VE. Por outro lado, para as curvas de recarga direta e no vale não há momento que o VE injeta potência na rede, assim, a responsabilidade por alimentar o defeito e as cargas é exclusivamente da subestação. No entanto, observando as métricas de avaliação, notou-se que utilizando estas duas recargas não há diferenças significativas entre as situações sem VE e com VE, impossibilitando conclusões significativas.

Já para o módulo de localização, analisando os gráficos pertinentes, observou-se que para as três curvas de recarga de veículos elétricos utilizadas a situação sem VE foi mais eficiente do que a situação com VE. Como foi discutido, medidores mais a jusante do defeito localizam melhor o curto-circuito do que os outros medidores. Além disso, esta localização é feita utilizando às tensões em componentes simétricas, em especial, às tensões de sequência positiva e negativa. No entanto, a adição de veículos elétricos utilizando qualquer das curvas de recarga citadas altera o desequilíbrio de tensão e por consequência as tensões  $\dot{V}_1$  e  $\dot{V}_2$ , dessa forma, a situação sem VE apresenta métricas de avaliação melhores.

Por fim, através dos resultados percebeu-se que alterando-se o foco entre detecção e localização, altera-se de mesmo modo a topologia ótima formada com dois medidores. Através das métricas do módulo de detecção, avaliou-se que para este problema a configuração ótima é formada por um medidor instalado na subestação em conjunto com um medidor no meio da rede elétrica, ou seja, Estratégia-2. Reforça-se que a melhor das topologias pelas métricas apresentadas é aquela em que os três medidores estão presentes, no entanto,

uma avaliação econômica deve ser feita pela distribuidora para decidir o custo-benefício de se instalar dois ou três medidores na rede de distribuição estudada. Por outro lado o módulo de localização apresenta uma topologia ótima diferente da encontrada no módulo de detecção. De forma a reforçar a afirmação que medidores a jusante apresentam melhor desempenho para localização de defeitos de alta impedância, observou-se através das métricas de avaliação que todas as topologias que incluem o medidor no fim da rede elétrica, que é o mais a jusante do SDEE, apresentaram um melhor desempenho. Assim, para o caso de dois medidores, para o módulo de localização, a distribuidora deve escolher a Estratégia-3. Por fim, uma análise financeira deve ser feita também neste caso de modo a avaliar o custo-benefício de se instalar dois ou três medidores. Nota-se, a partir desta discussão que há configurações ótimas diferentes para o módulo de detecção e para o de localização. No entanto, sabendo que a detecção do defeito implica diretamente em evitar acidentes com perdas de vidas humanas, aconselha-se que a Estratégia-2 deve ser adotada. Isso é reforçado pelo fato que não se pode localizar o defeito se este não for detectado corretamente. Para futuros trabalhos, pode-se tentar otimizar o local do medidor inteligente para maximizar as métricas de avaliação para a detecção e localização.

A partir das análises feitas acima observa-se que os objetivos do trabalho foram alcançados, no entanto, ainda existem lacunas e assuntos a serem abordados que serão feitos em trabalhos futuros:

- Implementar o módulo de classificação de defeitos de alta a impedância;
- Substituir o Opendss pelo *Real Time Digital Simulator* para a aquisição dos dados, permitindo assim, um estudo mais realístico;
- Otimizar o local do medidor inteligente para maximizar as métricas de avaliação para a detecção e localização ao mesmo tempo;
- Adicionar o desequilíbrio de tensão como mais uma entrada da RNA e verificar as métricas de avaliação.

## REFERÊNCIAS

- ACADEMY, D. S. **Deep Learning Book**. 2019. Disponível em <http://www.deeplearningbook.com.br/>. Acessado em 10/04/2019.
- ALVES, G. **Entendendo Redes Convolucionais (CNNs)**. 2018. Disponível em <https://medium.com/neuronio-br/entendendo-redes-convolucionais-cnns-d10359f21184>. Acessado em 24/12/2019.
- ALVES, H. do N.; MACHADO, R. C.; BERGÊ, I. G. S. Design and development of a software for fault diagnosis in radial distribution networks. In: IEEE. **2010 9th IEEE/IAS International Conference on Industry Applications-INDUSCON 2010**. [S.l.], 2010. p. 1–6.
- ANEEL. **Nota Técnica nº 0057/2014-SRD/ANEEL**. [S.l.], 2014.
- ANEEL. **Serviço Público de Distribuição de Energia Elétrica**. 2019. Disponível em <https://www.aneel.gov.br/distribuicao2>. Acessado em 18/12/2019.
- ANGGRIAWAN, D. O.; PRASETYONO, E.; FAHRISI, F.; BUDIKARSO, A.; TJAHJONO, A.; ROGONONDO, H. R. P. Digital overcurrent relay implementation with non-standard inverse curve modelling using adaptive neuro fuzzy inference system. In: IEEE. **2019 International Conference of Artificial Intelligence and Information Technology (ICAIIIT)**. [S.l.], 2019. p. 327–330.
- ARIOLI, V. T. **Análise de impactos técnicos provocados pela penetração massiva de veículos elétricos em redes de distribuição de energia elétrica**. Dissertação (Mestrado) — Universidade Estadual de Campinas, 2016.
- AUCOIN, M.; RUSSELL, B. D. Detection of distribution high impedance faults using burst noise signals near 60 hz. **IEEE transactions on power delivery**, IEEE, v. 2, n. 2, p. 342–348, 1987.
- AUTO-ESPORTE. **Carros elétricos serão maioria até 2040**. 2019. Disponível em <https://revistaautoesporte.globo.com/Noticias/noticia/2019/05/carros-eletricos-serao-majoria-ate-2040.htmls>. Acessado em 18/12/2019.
- BARAN, R.; LEGEY, L. F. L. Veículos elétricos: história e perspectivas no brasil. **BNDES Setorial, Rio de Janeiro, n. 33, p. 207-224, mar. 2011.**, Banco Nacional de Desenvolvimento Econômico e Social, 2011.
- BHARDWAJ, A. **Funções de Ativação**. 2019. Disponível em <https://www.quora.com/What-makes-the-ReLU-function-more-appropriate-in-some-cases-over-a-Sigmoid-activation-function>. Acessado em 19/12/2019.
- BORBA, V. **Redes Neurais Convolucionais**. 2019. Disponível em <https://medium.com/@vitorborbarodrigues/>. Acessado em 24/12/2019.
- BREMERMANN, L. E. **Impact Evaluation of the Large Scale Integration of Electric Vehicles in the Security of Supply**. Tese (Doutorado) — Faculty of Engineering of University of Porto, 2014.

CAMPOZANA, K. S. *et al.* **Impacto energético e econômico de veículos elétricos em uma microrrede sob diferentes regimes de carregamento.** Dissertação (Mestrado), 2017. Monografia (Engenharia de Energia), Universidade Federal de Santa Catarina.

CARROBRASIL. **Gurgel Itaipu o primeiro carro elétrico fabricado na América do Sul.** 2019. Disponível em <https://www.carrobrasil.com.br/noticia/gurgel-itaipu-o-primeiro-carro-eletrico-fabricado-na-america-do-sul>. Acessado em 24/12/2019.

CHITNIS, M. S.; PANDIT, S. P.; SHAIKH, M. Electric vehicle li-ion battery state of charge estimation using artificial neural network. In: IEEE. **2018 International Conference on Inventive Research in Computing Applications (ICIRCA)**. [S.l.], 2018. p. 992–995.

CODE, R. **Entendendo a entropia cruzada.** 2019. Disponível em <https://rubikscodex.net/2019/06/10/understanding-cross-entropy/>. Acessado em 19/12/2019.

DARYANI, M. J.; KARKEVANDI, A. E.; USTA, O. A hybrid approach for microgrid protection system based on neural network and fuzzy logic. In: IEEE. **2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)**. [S.l.], 2019. p. 1–5.

DAVOUDI, M.; CECCHI, V.; AGÜERO, J. R. Network reconfiguration with relaxed radiality constraint for increased hosting capacity of distribution systems. In: IEEE. **2016 IEEE Power and Energy Society General Meeting (PESGM)**. [S.l.], 2016. p. 1–5.

DEMARTINI, F. **Sistema de reconhecimento facial do Facebook é melhor que o do FBI.** 2014. Disponível em <https://canaltech.com.br/redes-sociais/Sistema-de-reconhecimento-facial-do-Facebook-e-melhor-que-o-do-FBI/>. Acessado em 24/12/2019.

ELÉTRICA, A. B. de Distribuidores de E. **Xii semana nacional de segurança com energia elétrica.** [S.l.], 2018.

ELETRICIDADE, A. B. de Consientização para os Perigos da. **Anuário Estatístico de Acidentes de Origem Elétrica 2019 – Ano base 2018.** [S.l.], 2019.

EPE, E. D. P. E. Balanço energético nacional 2019: ano base 2018. **Ministério de Minas e Energia (MME), Rio de Janeiro, 2019.**

FACURE, M. **Funções de Ativação.** 2019. Disponível em <https://matheusfacure.github.io/2017/07/12/activ-func/>. Acessado em 19/12/2019.

FGV, E. Electric vehicles booklet. **FGV Energia, 2017.**

G1. **Ministério Público vai apurar responsabilidade da Energisa sobre queda de fios de alta tensão.** 2018. Disponível em <https://g1.globo.com/se/sergipe/noticia/ministerio-publico-vai-apurar-responsabilidade-da-energisa-sobre-queda-de-fios-de-alta-tensao.ghtml>. Acessado em 01/01/2019.

GAUTAM, S.; BRAHMA, S. M. Detection of high impedance fault in power distribution systems using mathematical morphology. **IEEE Transactions on Power Systems**, IEEE, v. 28, n. 2, p. 1226–1234, 2012.

GAUTO, M. **Dossiê carros elétricos: futuro eletrizante no setor de transporte**. 2019. Disponível em <https://epbr.com.br/dossie-carros-eletricos-futuro-eletrizante-no-setor-de-transportes-por-marcelo-gauto/>. Acessado em 18/12/2019.

GÖNEN, T. **Electric power distribution system engineering**. [S.l.]: CRC press Boca Raton, 2008. v. 2.

HE, J.; CHENG, Y.; HU, J.; YIP, H. An accelerated adaptive overcurrent protection for distribution networks with high dg penetration. **13th International Conference on Development in Power System Protection 2016 (DPSP)**, IET, 2016.

HE, X.; REN, H.; HAN, P.; CHEN, Y.; SHU, Z. Open circuit fault diagnosis of advanced cophase traction power supply system based on neural network. In: IEEE. **2018 International Conference on Intelligent Rail Transportation (ICIRT)**. [S.l.], 2018. p. 1–5.

HITECH. **CRESCIMENTO MUNDIAL DO MERCADO DE VEÍCULOS ELÉTRICOS**. 2019. Disponível em <https://hitech-e.com.br/blog/crescimento-mundial-do-mercado-de-veiculos-eletricos/>. Acessado em 18/12/2019.

HOCHULI, A. G. **Redes Neurais Convolucionais**. 2016. Disponível em <http://www.inf.ufpr.br/aghochuli/caffe/>. Acessado em 24/12/2019.

HUANG, P.; WEN, C.; FU, L.; PENG, Q.; TANG, Y. A deep learning approach for multi-attribute data: a study of train delay prediction in railway systems. **Information Sciences**, Elsevier, 2019.

JIN, R.; WANG, B.; ZHANG, P.; LUH, P. Decentralised online charging scheduling for large populations of electric vehicles: A cyber-physical system approach. **International Journal of Parallel, Emergent and Distributed Systems - IJPEDS**, v. 28, p. 1–17, 01 2012.

JUANKBOARDS. **Conceptos fundamentales en Machine Learning: función de pérdida y optimización**. 2019. Disponível em <https://planetachatbot.com/conceptos-fundamentales-en-machine-learning-funci>Acessado em 24/12/2019.

KASTURI, K.; NAYAK, C. K.; NAYAK, M. Electric vehicles management enabling g2v and v2g in smart distribution system for maximizing profits using momvo. **International Transactions on Electrical Energy Systems**, p. e12013, 04 2019.

KESKAR, N. S.; SOCHER, R. Improving generalization performance by switching from adam to sgd. **arXiv preprint arXiv:1712.07628**, 2017.

KEZUNOVIC, M. Intelligent systems in protection engineering. In: IEEE. **PowerCon 2000. 2000 International Conference on Power System Technology. Proceedings (Cat. No. 00EX409)**. [S.l.], 2000. v. 2, p. 801–806.

KEZUNOVIC, M. Automated fault analysis in a smart grid. In: IEEE. **2009 Transmission & Distribution Conference & Exposition: Asia and Pacific**. [S.l.], 2009. p. 1–3.

KEZUNOVIC, M. Smart fault location for smart grids. **IEEE transactions on smart grid**, IEEE, v. 2, n. 1, p. 11–22, 2011.

KEZUNOVIC, M.; VASILIC, S. Design and evaluation of context-dependent protective relaying approach. In: IEEE. **2001 IEEE Porto Power Tech Proceedings (Cat. No. 01EX502)**. [S.l.], 2001. v. 4, p. 6–pp.

KINDERMANN, G. **Curto circuito**. [S.l.]: Sagra-DC Luzzatto, 1992.

KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. **CoRR**, abs/1412.6980, 2014. Disponível em: <<http://dblp.uni-trier.de/db/journals/corr/corr1412.html#KingmaB14>>.

LEITE, M. P. **Identificação e Localização de Faltas de Alta Impedância Utilizando Medidores Inteligentes**. Dissertação (Mestrado) — Universidade Federal de Itajubá, 2017.

LUCAS, F.; COSTA, P.; BATALHA, R.; LEITE, D. High impedance fault detection in time-varying distributed generation systems using adaptive neural networks. In: IEEE. **2018 International Joint Conference on Neural Networks (IJCNN)**. [S.l.], 2018. p. 1–8.

MAHMUD, K.; HOSSAIN, M.; RAVISHANKAR, J. Peak-load management in commercial systems with electric vehicles. **IEEE Systems Journal**, IEEE, v. 13, n. 2, p. 1872–1882, 2018.

MATOS, d. R. **Um método para detecção e classificação de curtos-circuitos em redes de distribuição de energia elétrica baseado na transformada de Fourier e em redes neurais artificiais**. Dissertação (Mestrado) — Universidade Estadual Paulista, 2009.

MICHALIK, M.; REBIZANT, W.; LUKOWICZ, M.; LEE, S.-J.; KANG, S.-H. High-impedance fault detection in distribution networks with use of wavelet-based algorithm. **IEEE Transactions on Power Delivery**, IEEE, v. 21, n. 4, p. 1793–1802, 2006.

MOLOI, K.; JORDAAN, J.; HAMAM, Y. High impedance fault classification and localization method for power distribution network. In: IEEE. **2018 IEEE PES/IAS PowerAfrica**. [S.l.], 2018. p. 84–89.

MUSIEROWICZ, K.; LORENC, J.; MARCINKOWSKI, Z.; KWAPISZ, A. A fuzzy logic-based algorithm for discrimination of damaged line during intermittent earth faults. In: IEEE. **2005 IEEE Russia Power Tech**. [S.l.], 2005. p. 1–5.

NAGESHRAO, S. P.; JACOB, J.; WILKINS, S. Charging cost optimization for ev buses using neural network based energy predictor. **IFAC-PapersOnLine**, Elsevier, v. 50, n. 1, p. 5947–5952, 2017.

NAKAGAWA, L. **Elon Musk revela picape 'Tesla Cybertruck'**. 2019. Disponível em <https://olhardigital.com.br/carros-e-tecnologia/noticia/elon-musk-revela-picape-tesla-cybertruck/93315>. Acessado em 24/12/2019.

NIELSEN, M. A. **Neural networks and deep learning**. [S.l.]: Determination press San Francisco, CA, USA:, 2015. v. 25.

OLIVEIRA, A. R.; GARCIA, P. A. N.; OLIVEIRA, L. W.; OLIVEIRA, E. J.; SILVA, H. A. Fault classification in distribution systems based on fault current angles. **IEEE Latin America Transactions**, IEEE, v. 14, n. 1, p. 199–205, 2016.

PAULILO, G. Capítulo iii desequilíbrios de tensão. **Revista O Setor Elétrico**, São Paulo, n. 86, p. 42–48, 2013.

PERES, L. A. P.; HORTA, L. A.; LAMBERT-TORRES, G. Veículos elétricos: O limiar de uma era de transição onde o “hipercarro” é também fonte de energia. In: **VII Symposium of Specialists in Electric Operational and Expansion Planning, Brasilia, Brasil**. [S.l.: s.n.], 2002.

PONTI, M. A.; COSTA, G. B. P. da. Como funciona o deep learning. **arXiv preprint arXiv:1806.07908**, 2018.

PSR. **Machine-Learning**. 2019. Disponível em <https://anchor.fm/psr-energy-cast/episodes/005-PSR-Energycast—Machine-Learning-e5768o>. Acessado em 19/12/2019.

PUJANTARA, M.; HAFIDZ, I.; SETIAWAN, A.; PRIYADI, A.; PURNOMO, M. H.; ANGGRIAWAN, D. O.; TJAHHJONO, A. Optimization technique based adaptive overcurrent protection in radial system with dg using genetic algorithm. In: IEEE. **2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)**. [S.l.], 2016. p. 83–88.

PYTHIEST. **Micro Average vs Macro average Performance in a Multiclass classification setting**. 2017. Disponível em <https://datascience.stackexchange.com/questions/15989/micro-average-vs-macro-average-performance-in-a-multiclass-classification-settin>. Acessado em 24/12/2019.

RAMADAN, H.; ALI, A.; FARKAS, C. Assessment of plug-in electric vehicles charging impacts on residential low voltage distribution grid in hungary. In: IEEE. **2018 6th International Istanbul Smart Grids and Cities Congress and Fair (ICSG)**. [S.l.], 2018. p. 105–109.

RAUL. **Understanding Categorical Cross-Entropy Loss, Binary Cross-Entropy Loss, Softmax Loss, Logistic Loss, Focal Loss and all those confusing names**. 2018. Disponível em [https://gombu.github.io/2018/05/23/cross\\_entropy\\_loss](https://gombu.github.io/2018/05/23/cross_entropy_loss). Acessado em 16/01/2019.

RENEWABLES, D. **Tecnologia Vehicle to Grid (V2G)**. 2018. Disponível em <https://dandelionrenewables.com/vehicle-to-grid-technology-v2g>. Acessado em 18/12/2019.

RESMI, R.; VANITHA, V.; ARAVIND, E.; HARITHAA, S. *et al.* Detection, classification and zone location of fault in transmission line using artificial neural network. In: IEEE. **2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT)**. [S.l.], 2019. p. 1–5.

ROMAGUERA, L. V. **Segmentação do miocárdio em imagens de MRI cardíaca utilizando redes neurais convolutivas**. Dissertação (Mestrado) — Universidade Federal do Amazonas, 2017.

RUDER, S. An overview of gradient descent optimization algorithms. **arXiv preprint arXiv:1609.04747**, 2016.

RUFINO, M. P. **Implementação de uma Rede Neural Artificial para Classificação de Sinais Mielétricos**. Dissertação (Mestrado) — Universidade Federal da Paraíba, 2017.

SALAMA, H. S.; SAID, S. M.; VOKONY, I.; HARTMANN, B. Impact of different plug-in electric vehicle categories on distribution systems. In: IEEE. **2019 7th International Istanbul Smart Grids and Cities Congress and Fair (ICSG)**. [S.l.], 2019. p. 109–113.

SALDAÑA, G.; MARTIN, J. I. S.; ZAMORA, I.; ASENSIO, F. J.; OÑEDERRA, O. Electric vehicle into the grid: Charging methodologies aimed at providing ancillary services considering battery degradation. **Energies**, Multidisciplinary Digital Publishing Institute, v. 12, n. 12, p. 2443, 2019.

SANCHEZ, E. C. M. **Controle por aprendizado acelerado e neuro-fuzzy de sistemas servo-hidráulicos de alta frequência**. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio de Janeiro - PUC-RIO, 2018.

SANTOS, A. **Câmeras de reconhecimento facial acham criminoso no Carnaval de Salvador**. 2018. Disponível em <https://noticias.uol.com.br/cotidiano/ultimas-noticias/2019/03/05/cameras-de-reconhecimento-facial-acham-criminoso-no-carnaval-de-salvador.html>. Acessado em 24/12/2019.

SENGER, E. C.; KAISER, W.; SANTOS, J. C.; BURT, P. M.; MALAGODI, C. V. S. Broken conductors protection system using carrier communication. **IEEE Transactions on Power Delivery**, IEEE, v. 15, n. 2, p. 525–530, 2000.

SHMUELI, B. **Multi-Class Metrics Made Simple, Part : the F1-score**. 2019. Disponível em <https://towardsdatascience.com/multi-class-metrics-made-simple-part-ii-the-f1-score-ebe8b2c2ca1>. Acessado em 15/05/2020.

SILVA, A. M. L. da; RESENDE, L. C. de; MANSO, L. A. da F.; MIRANDA, V. Composite reliability assessment based on monte carlo simulation and artificial neural networks. **IEEE Transactions on Power Systems**, IEEE, v. 22, n. 3, p. 1202–1209, 2007.

SILVA, E.; OLIVEIRA, A. C. d. **Dicas para a configuração de redes neurais**. [S.l.], 2001.

SIROJAN, T.; LU, S.; PHUNG, B.; ZHANG, D.; AMBIKAI RAJAH, E. High impedance fault detection by convolutional deep neural network. In: IEEE. **2018 IEEE International Conference on High Voltage Engineering and Application (ICHVE)**. [S.l.], 2018. p. 1–4.

SOUZA, M. E. M. de. **Impactos da geração distribuída nas redes de baixa tensão**. Dissertação (Mestrado), 2012. Monografia (Engenharia Elétrica), Universidade Federal de Minas Gerais.

SOUZA, R. C.; MARCATO, A.; DIAS, B.; OLIVEIRA, F.; FERREIRA, P.; BRANDI, R. da S.; RAMOS, T. Planejamento da operação de sistemas hidrotérmicos no brasil: geração de cenários e otimização. **Ed. Rio de Janeiro: PUC-Rio**, 2014.

- SREERAMA, R.; SWARUP, K. S. Detection, localization and fault diagnosis using petrinets for smart power distribution grids. In: IEEE. **2017 7th International Conference on Power Systems (ICPS)**. [S.l.], 2017. p. 596–600.
- STRUBEN, J.; STERMAN, J. D. Transition challenges for alternative fuel vehicle and transportation systems. **Environment and Planning B: Planning and Design**, SAGE Publications Sage UK: London, England, v. 35, n. 6, p. 1070–1097, 2008.
- TEIXEIRA, J. d. F.; GONZALES, M. E. Q. Inteligência artificial e teoria de resolução de problemas. **Trans/Form/Ação**, SciELO Brasil, p. 45–52, 1983.
- THOMAS, A. **Uma introdução à entropia, entropia cruzada e divergência de KL no aprendizado de máquina**. 2019. Disponível em <https://adventuresinmachinelearning.com/cross-entropy-kl-divergence/>. Acessado em 19/12/2019.
- TODOROV, D.; GILEV, B. Fault section estimation in electric power distribution system with elman neural network. In: IEEE. **2018 20th International Symposium on Electrical Apparatus and Technologies (SIELA)**. [S.l.], 2018. p. 1–4.
- TRINDADE, F. C.; FREITAS, W.; VIEIRA, J. C. Fault location in distribution systems based on smart feeder meters. **IEEE transactions on Power Delivery**, IEEE, v. 29, n. 1, p. 251–260, 2013.
- VARSHOSAZ, F.; MOAZZAMI, M.; FANI, B.; SIANO, P. Day-ahead capacity estimation and power management of a charging station based on queuing theory. **IEEE Transactions on Industrial Informatics**, PP, p. 1–1, 03 2019.
- XU, L.; CHOW, M.-Y. A classification approach for power distribution systems fault cause identification. **IEEE Transactions on Power Systems**, IEEE, v. 21, n. 1, p. 53–60, 2006.
- ZHANG, A.; LIPTON, Z. C.; LI, M.; SMOLA, A. J. Dive into deep learning. **Unpublished draft**. Retrieved, v. 3, p. 319, 2019.
- ZHANG, K.; XU, L.; OUYANG, M.; WANG, H.; LU, L.; LI, J.; LI, Z. Optimal decentralized valley-filling charging strategy for electric vehicles. **Energy conversion and management**, Elsevier, v. 78, p. 537–550, 2014.