



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE  
CENTRO DE CIÊNCIAS EXATAS E DA TERRA  
DEPARTAMENTO DE INFORMÁTICA E MATEMÁTICA APLICADA  
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS E COMPUTAÇÃO  
MESTRADO ACADÊMICO EM SISTEMAS E COMPUTAÇÃO



# Detecção de faltas internas em SCIG utilizando Sistemas Inteligentes

Anderson Egberto Cavalcante Salles

Natal-RN  
Janeiro de 2022

Anderson Egberto Cavalcante Salles

## Detecção de faltas internas em SCIG utilizando Sistemas Inteligentes

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Sistemas e Computação do Departamento de Informática e Matemática Aplicada da Universidade Federal do Rio Grande do Norte como requisito parcial para a obtenção do grau de Mestre em Sistemas e Computação.

*Linha de pesquisa:*

Sistemas Integrados e Distribuídos

Orientador: Prof. Dr. Márcio Eduardo Kreutz

Coorientador: Prof. Dr. Luciano Sales Barros

PPGSC – PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS E COMPUTAÇÃO  
DIMAP – DEPARTAMENTO DE INFORMÁTICA E MATEMÁTICA APLICADA  
CCET – CENTRO DE CIÊNCIAS EXATAS E DA TERRA  
UFRN – UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

Natal-RN

Janeiro de 2022

Universidade Federal do Rio Grande do Norte - UFRN  
Sistema de Bibliotecas - SISBI  
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Salles, Anderson Egberto Cavalcante.

Detecção de faltas internas em SCIG utilizando sistemas inteligentes / Anderson Egberto Cavalcante Salles. - 2022.  
85 f. : il.

Dissertação (mestrado) - Universidade Federal do Rio Grande do Norte, Centro de Ciências Exatas e da Terra, Programa de Pós-Graduação em Sistemas e Computação, Natal, RN, 2022.

Orientador: Prof. Dr. Márcio Eduardo Kreutz.

Coorientador: Prof. Dr. Luciano Sales Barros.

1. Redes Neurais Artificiais - Dissertação. 2. Falhas Internas - Dissertação. 3. Gerador de Indução com rotor em gaiola - Dissertação. 4. Rede neural convolucional - Dissertação. I. Kreutz, Márcio Eduardo. II. Barros, Luciano Sales. III. Título.

RN/UF/BCZM

CDU 004.7(043.3)

Dissertação de Mestrado sob o título *Detecção de faltas internas em SCIG utilizando Sistemas inteligentes* apresentada por Anderson Egberto Cavalcante Salles e aceita pelo Programa de Pós-Graduação em Sistemas e Computação do Departamento de Informática e Matemática Aplicada da Universidade Federal do Rio Grande do Norte, sendo aprovada por todos os membros da banca examinadora abaixo especificada:

---

Prof. Dr. Márcio Eduardo Kreutz  
Presidente

DIMAp – Departamento de Informática e Matemática Aplicada  
UFRN – Universidade Federal do Rio Grande do Norte

---

Profª. Dra. Anne Magály de Paula Canuto  
Examinador

DIMAp – Departamento de Informática e Matemática Aplicada  
UFRN – Universidade Federal do Rio Grande do Norte

---

Profª. Dra. Monica Magalhães Pereira  
Examinador

DIMAp – Departamento de Informática e Matemática Aplicada  
UFRN – Universidade Federal do Rio Grande do Norte

---

Prof. Dr. Ivanovitch Medeiros Dantas da Silva  
Examinador

IMD – Instituto Metr pole Digital  
UFRN – Universidade Federal do Rio Grande do Norte

---

Prof. Dr. Alvaro De Medeiros Maciel  
Examinador

IFPB – Instituto Federal da Paraiba

---

Prof. Dr. Luciano Sales Barros  
Coorientador

DSC - Departamento de Sistemas de Computa o  
UFPB – Universidade Federal da Para ba

Natal-RN, 31, Janeiro de 2022.



# Agradecimentos

Agradeço aos meus amigos, família, especialmente a minha mãe que passou por muitas dificuldades durante a pandemia, e aos professores.

*A liberdade não é um luxo dos tempos de bonança; é, sobretudo, o maior elemento de estabilidade das instituições.*

Ruy Barbosa

# Detecção de faltas internas em SCIG utilizando Sistemas inteligentes

Autor: Anderson Egberto Cavalcante Salles  
Orientador: Prof. Dr. Márcio Eduardo Kreutz  
Coorientador: Prof. Dr. Luciano Sales Barros

## RESUMO

As Máquinas elétricas, eventualmente, vão apresentar alguma falha e dentro das possibilidades que podem ocorrer, as falhas nas bobinas do estator põem em risco a sua correta operação. Estas faltas podem evoluir rapidamente, danificando de forma irreversível a bobina e causando prejuízos econômicos. Na literatura diferentes caminhos para solucionar o problema já foram implementados como: utilização de lógica fuzzy, modelos de predição, análise de assinatura de corrente, entre outros. Este trabalho consiste na implementação e avaliação de sistemas inteligentes para detecção das faltas no estator do tipo espira-espira e espira-terra da máquina de indução com rotor em gaiola operando como gerador eólico. Para tanto, é proposta a implementação de dois modelos de aprendizado de máquina, uma rede neural artificial e uma rede neural convolucional, com o propósito de aprenderem as características das correntes elétricas do estator e diferenciar uma máquina saudável de uma danificada. Os sistemas são treinados com dados artificiais provenientes de simulações e estas se baseiam em modelos dos componentes principais de um sistema de geração eólico como: sistemas de controle, chave de comando de acionamento, modelo mecânico da turbina e modelo elétrico do gerador com as faltas. Todas as faltas avaliadas têm fração menor ou igual a 10% dos enrolamentos danificados. Para análise dos resultados foi utilizado o método k-fold, sendo observado um melhor desempenho das redes convolucionais em comparação com as redes neurais artificiais da ordem de 15,95 pontos percentuais.

*Palavras-chave:* Falhas Internas, SCIG, Redes Neurais Artificiais, Rede neural convolucional.

# Internal Fault Detection in SCIG using Intelligent Systems

Autor: Anderson Egberto Cavalcante Salles  
Orientador: Prof. Dr. Márcio Eduardo Kreutz  
Coorientador: Prof. Dr. Luciano Sales Barros

## ABSTRACT

electrical machines, eventually, will present some failure and within the possibilities that may occur, failures in the stator coils jeopardize their correct operation. These faults can evolve quickly, irreversibly damaging the coil and causing economic losses. In the literature, different ways to solve the problem have already been implemented, such as: use of fuzzy logic, prediction models, current signature analysis, among others. This work consists of the implementation and evaluation of intelligent systems for fault detection in the turn-turn and turn-to-ground stator of the squirrel-cage induction machine operating as a wind generator. Therefore, it is proposed the implementation of two machine learning models, an artificial neural network and a convolutional neural network, with the purpose of learning the characteristics of the stator electrical currents and differentiating a healthy machine from a damaged one. The systems are trained with artificial data from simulations and these are based on models of the main components of a wind generation system such as: control systems, actuation command switch, mechanical model of the turbine and electrical model of the generator with faults. All faults evaluated have a fraction less than or equal to 10% of the damaged windings. To analyze the results, the k-fold method was used, with a better performance of convolutional networks in comparison with artificial neural networks in the order of 15.95 percentage points.

*Keywords:* Internal faults, SCIG, Artificial Neural Networks, Convolutional neural network.

# Lista de figuras

1	Sistema eólico. . . . .	p. 22
2	Tipos de Falta. . . . .	p. 23
3	Faltas no Estator. . . . .	p. 24
4	Imagens das faltas espira-espira e espira-terra . . . . .	p. 24
5	Falta espira-terra. . . . .	p. 25
6	Falta espira-espira. . . . .	p. 26
7	Neurônio Biológico. . . . .	p. 27
8	Perceptron. . . . .	p. 27
9	Perceptron Multicamadas. . . . .	p. 29
10	Função logística e sua derivada. . . . .	p. 31
11	Uma fase do Estator. . . . .	p. 32
12	Aplicação do filtro. . . . .	p. 32
13	Camada de Pooling. . . . .	p. 33
14	Arquitetura RNC. . . . .	p. 34
15	Metodologia. . . . .	p. 44
16	Uma fase do Estator. . . . .	p. 46
17	Bobinas do Estator e do Rotor. . . . .	p. 47
18	Máquina Saudável. . . . .	p. 49
19	Máquina com a Falta Espira-Espira. . . . .	p. 49
20	Máquina saudável . . . . .	p. 52
21	Máquina com a Falta Espira-Terra. . . . .	p. 52
22	Ilustração. . . . .	p. 55

23	Função $F_{pos}(\theta_t)$ . . . . .	p. 56
24	Diagramado do Controle do Lado do Gerador. . . . .	p. 59
25	Diagramado do Controle do Lado da Rede. . . . .	p. 61
26	Inversor . . . . .	p. 62
27	Mapa de Estados no Plano Complexo. . . . .	p. 62
28	Instância Sem Falta. . . . .	p. 65
29	Instância Totalmente em Falta. . . . .	p. 66
30	Instância Com Falta Em Um Quartos da Janela de Tempo. . . . .	p. 66
31	Instância Com Falta Na Metade da Janela de Tempo. . . . .	p. 67
32	Instância Com Falta Em Três Quartos da Janela de Tempo. . . . .	p. 67
33	Processo de Amostragem. . . . .	p. 68
34	Componentes Principais. . . . .	p. 69
35	Base de Dados. . . . .	p. 70
36	K-fold. . . . .	p. 71
37	Comparativo de resultados. . . . .	p. 74

# Lista de tabelas

1	Resumo dos Trabalhos que utilizam redes neurais. . . . .	p. 38
2	Resumo dos Trabalhos Relacionados. . . . .	p. 39
3	Mapa de Estados . . . . .	p. 61
4	Resultados RNA. . . . .	p. 72
5	Resultados RNC. . . . .	p. 73

# Lista de abreviaturas e siglas

CNUMAD – Conferência das Nações sobre o Meio-Ambiente e Desenvolvimento

SCEE – Sistemas de Conversão de Energia Eólica

SCIG – *Squirrel Cage Induction Generator*

RNA – Rede Neural Artificial

RNC – Rede Neural Convolutiva

MLP – Perceptron Multicamadas

MCSA – *Motor Current Signature Analysis*

# Lista de símbolos

$i_{pc}$  – Corrente de fase

$i_{fc}$  – Corrente de falta

$i_{cs}$  – Corrente no trecho danificado

$\hat{y}_i$  – Saída da rede

$y_i$  – Saída desejada

$x_i$  – Vetor das entradas

$w_i$  – Pesos sináptico

$w'_i$  – Pesos sinápticos na interação subsequente

$w_0$  – Peso do viés

$\eta$  – Taxa de aprendizagem

$\delta_i$  – Erro do neurônio

$e_q$  – Erro quadrático

$f'_a$  – Derivada da função de ativação

$\delta_k$  – Soma dos erros da camada seguinte

$C_{int}$  – Conjunto dos neurônios da camada intermediária

$C_{sai}$  – Conjunto dos neurônios da camada de saída

$L_s$  – Indutância do Estator

$L_r$  – Indutância do Rotor

$R_s$  – Resistência do Estator

$R_s$  – Resistência do Rotor

$R_s$  – Resistência do Rotor

$V_{s123}$  – Corrente Trifásicas do Estator

$V_{r123}$  – Corrente Trifásicas do Rotor

$R_{cc}$  – Resistência de Falta

$T_e$  – Torque Elétrico

# Sumário

<b>1</b>	<b>Introdução</b>	p. 17
1.1	Justificativa . . . . .	p. 19
1.2	Questão Norteadora . . . . .	p. 19
1.3	Hipótese de Pesquisa . . . . .	p. 20
1.4	Objetivo geral e objetivos específicos . . . . .	p. 20
1.5	Organização do trabalho . . . . .	p. 20
<b>2</b>	<b>Referencial Teórico</b>	p. 21
2.1	Geradores Eólicos Baseados na Máquina de Indução com Rotor em Gaiola	p. 21
2.2	Faltas Internas . . . . .	p. 22
2.2.1	Conceitos Básicos . . . . .	p. 22
2.3	Faltas no Estator . . . . .	p. 23
2.4	Redes Neurais Artificiais . . . . .	p. 26
2.4.1	Inspiração Neurobiológica . . . . .	p. 26
2.4.2	Redes Neurais Artificiais . . . . .	p. 26
2.4.3	Perceptron Multicamadas . . . . .	p. 28
2.5	Rede Neural Convolucional . . . . .	p. 31
2.5.1	Camada de Pooling . . . . .	p. 33
2.5.2	Arquetetura Geral da RNC . . . . .	p. 33
2.6	Conclusão . . . . .	p. 34
<b>3</b>	<b>Trabalhos Relacionados</b>	p. 35

3.1	Estado da Arte . . . . .	p. 35
3.2	Conclusão . . . . .	p. 40
<b>4</b>	<b>Metodologia</b>	<b>p. 41</b>
4.1	Introdução . . . . .	p. 41
4.2	Princípio . . . . .	p. 42
4.3	Conclusão . . . . .	p. 44
<b>5</b>	<b>Modelagem</b>	<b>p. 45</b>
5.1	Modelo Convencional da Máquina de Indução . . . . .	p. 45
5.2	Modelo Para Falta Epira-espira . . . . .	p. 49
5.3	Modelo Falta Epira-terra . . . . .	p. 52
5.4	Modelo Mecânico . . . . .	p. 54
5.4.1	Modelo Aerodinâmico . . . . .	p. 54
5.4.2	Modelo do eixo . . . . .	p. 56
5.5	Modelo do controle . . . . .	p. 57
5.5.1	Controle do lado do gerador . . . . .	p. 57
5.5.2	Controle do Lado da Rede . . . . .	p. 59
5.5.3	Modulação PWM . . . . .	p. 61
5.5.4	Filtro do PWM . . . . .	p. 63
5.5.5	Conclusão . . . . .	p. 63
<b>6</b>	<b>Resultados</b>	<b>p. 64</b>
6.1	Aquisição dos dados . . . . .	p. 64
6.2	Multi-layer Perceptron . . . . .	p. 68
6.2.1	Pré-processamento . . . . .	p. 68
6.3	Projeto MLP . . . . .	p. 69
6.3.1	Avaliação dos resultados MLP . . . . .	p. 70

6.3.2	Intervalo de Confiança . . . . .	p. 71
6.3.3	Resultados RNA . . . . .	p. 72
6.4	Rede Neural Convolutacional . . . . .	p. 72
6.4.1	Projeto da Rede Neural Convolutacional . . . . .	p. 73
6.4.2	Resultados . . . . .	p. 73
6.5	Conclusão . . . . .	p. 74
<b>7</b>	<b>Considerações finais</b>	p. 76
7.1	Principais contribuições . . . . .	p. 76
7.2	Trabalhos Futuros . . . . .	p. 77
7.3	Resultado da pesquisa . . . . .	p. 77
	<b>Referências</b>	p. 78

# 1 Introdução

Os geradores eólicos são elementos de conversão de energia mecânica em elétrica a partir do vento sendo o vento resultado da movimentação de massas de ar causadas pelo aquecimento irregular da superfície do planeta. O primeiro aerogerador foi construído em 1887, na cidade de Glasgow, pelo engenheiro eletricitista e professor James Blyth (1839 – 1906) do Anderson’s College atual Universidade Strathclyde (PINTO et al., 2013). Blyth em 1891 conseguiu a patente britânica da sua turbina (PINTO et al., 2013).

A atenção crescente da sociedade nas decisões socioambientais ocasiona pressões políticas por responsabilidade ambiental nos processos de produção de energia e alguns eventos importantes demonstram essa perspectiva, por exemplo, segundo Barbieri (2007) a Conferência de Estocolmo foi um marco de mudança de comportamento e pode ser considerada a primeira grande conferência internacional sobre meio ambiente, além disso, em 1992, no Brasil, ocorreu a Conferência das Nações sobre o Meio Ambiente e Desenvolvimento (CNUMAD) e em dezembro de 1997 o Protocolo de Quioto foi aprovado, porém entrou em vigor em 2005 depois da ratificação da Rússia e esse acordo demonstra um avanço na gestão ambiental ao nível global, pois nele houve a implementação de metas para reduzir as emissões de poluentes.

Concomitante existe um contínuo avanço da demanda energética global. Nesse contexto, diferentes países vêm aumentando o interesse em fontes renováveis de energia e os Sistemas de Conversão de Energia Eólica (SCEEs) chamam atenção por não gerarem subprodutos poluentes, assim, mitigam riscos em sua utilização. Só o Brasil apresentou um incremento de 971 MW de capacidade instalada em 2019 proveniente das plantas de geração eólica (ENEEL, 2020).

Dentre os geradores eólicos presentes no mercado temos o gerador baseado na máquina de indução com rotor em gaiola (SCIG, do inglês *Squirrel Cage Induction Generator*) por sua simplicidade de funcionamento, robustez, baixo custo e plano de manutenção menos frequente, pela ausência de escovas e anéis coletores apresenta boas perspectivas para o

uso em SCEEs (FITZGERALD, 2014), porém, como todo sistema real, pode apresentar falhas como as faltas internas no estator.

Junto ao crescente interesse nas usinas eólicas também surgem novos desafios tecnológicos a serem resolvidos voltados a confiabilidade e a eficiência durante a operação dos parques. Um dos desafios impostos para a proteção dos aerogeradores é o caso das faltas no estator. Essas faltas podem causar um impacto importante no funcionamento das máquinas elétricas causando vibrações, aquecimento e podendo iniciar um ciclo potencialmente destrutivo ao gerador. Esses danos trazem prejuízos econômicos importantes tanto pela avaria ao gerador como pelo tempo de interrupção do seu funcionamento, particularmente, em geradores de baixa tensão a detecção ainda é mais difícil (ALBIZU et al., 2004). No contexto desse trabalho são abordadas as faltas espira-espira e espira-terra.

As faltas espira-espira e espira-terra ocorrem quando um pequeno conjunto de espiras do estator perdem o isolamento e a partir desse instante o calor gerado pela falta tende a degradar mais outras espiras tornando a falta mais severa (BONNETT; SOUKUP, 1992). Essas faltas podem ocorrer por vibração ou picos de tensão que são eventos comuns de acontecer, causando prejuízos importantes. Devido a essa natureza da falta a detecção no início é um ponto relevante para proteção do estator (THOMSON; FENGER, 2001).

Desenvolver um algoritmo tradicional para inferir se um dado sinal é de uma máquina com falta é demasiadamente complexo, pois é necessário observar diferentes cenários operacionais e identificar todas as condições que diferenciam um sinal de uma máquina saudável de outra com falta e assim certamente o algoritmo ficaria muito extenso dificultando o entendimento e a manutenção em aplicações reais. Diferentes abordagens vêm tentando melhorar a proteção do estator dos aerogeradores como: a análise de assinatura de corrente, medição de resistência de isolamento e sistemas baseados em lógica *fuzzy* (ALI et al., 2019).

Existem muitas opções possíveis, mas uma que vem ganhando destaque são as técnicas orientadas por dados (ALI et al., 2019). São atraentes em virtude da sua habilidade de devolver o modelo em resposta aos dados apresentados e de lidar com casos complexos. Dentre as diversas técnicas uma das mais populares para detecção de faltas são as Redes Neurais Artificiais (RNA) (ALI et al., 2019). Outro campo que atrai bastante atenção é o das Redes Neurais Convolucionais (RNC) sendo bem-sucedidas em muitas tarefas de reconhecimento de padrões (SUN et al., 2017).

As RNAs consistem de um conjunto de unidades de processamento denominadas neurônios que são interconectados por pesos que representam o conhecimento armazenado

de forma distribuída. Suas principais características residem na capacidade de generalização das soluções e na habilidade de classificar e agrupar padrões semelhantes (SIMON, 2001). Com essas virtudes as RNAs tornam-se uma ferramenta poderosa para soluções envolvendo diagnóstico de faltas uma vez que as redes podem aprender os padrões das assinaturas elétricas nos sinais de correntes que apresentam falhas, pois quando a falta é estabelecida as correntes do estator sofrem distorções. Já as RNCs adotam conexões locais inspiradas no funcionamento biológico dos olhos (GÉRON, 2019). O funcionamento das duas redes será comentado em capítulos posteriores.

Os resultados obtidos nessa pesquisa poderão ser aplicados na indústria visando melhorar a confiabilidade e eficiência das turbinas eólicas e, conseqüentemente, diminuindo custos operacionais.

## 1.1 Justificativa

A principal motivação para sustentar o projeto de pesquisa reside em observar alternativas que possam melhorar a disponibilidade dos aerogeradores e diminuir custos de manutenção, pois o aumento da penetração de plantas eólicas no sistema elétrico leva a necessidade de examinar a operação dos geradores.

Dentre as faltas que podem afetar as máquinas elétricas 38% ocorrem no estator (NANDI; TOLIYAT; LI, 2005), (KIA et al., 2013) demonstrando que essas faltas são um problema recorrente e como tendem a evoluir com o tempo é importante que ocorra a detecção precoce das faltas para tentar diminuir os danos ao núcleo do estator. Quanto antes as faltas são detectadas menos espiras são danificadas e, conseqüentemente, menor é o custo de manutenção.

Essa pesquisa busca contribuir com o tema propondo modelos que possam simular condições de falta e avaliando as RNAs e RNCs na detecção.

## 1.2 Questão Norteadora

Para a detecção de faltas espira-espira e espira-terra qual melhor rede é a melhor de ser utilizada entre uma rede neural artificial e uma rede neural convolucional?

### 1.3 Hipótese de Pesquisa

Parte-se da hipótese que as redes neurais artificiais e as redes neurais convolucionais podem aprender características das faltas espira-espira e espira-terra no SCIG, pois quando as faltas são estabelecidas as correntes do estador se desviam do seu comportamento esperado e as redes devem detectar essa mudança no comportamento e distinguir uma máquina saudável de uma em falta. Os dados artificiais gerados por simulação apresentam diferentes condições de operação da máquina que auxiliam no processo de detecção.

### 1.4 Objetivo geral e objetivos específicos

Como objetivo geral esse trabalho busca avaliar o emprego de sistemas inteligentes, nesse caso redes neurais artificiais e redes neurais convolucionais, na detecção das faltas espira-espira e espira-terra no estator de geradores eólicos baseados na máquina de indução com rotor em gaiola utilizando dados artificiais provenientes de simulação.

Já os objetivos específicos são:

- Implementar a simulação dos modelos de falta;
- Desenvolver o banco de dados;
- Implementar o modelo da RNA e da RNC;
- Comparar as redes.

### 1.5 Organização do trabalho

O presente texto está organizado em 6 capítulos. O capítulo 1 apresenta as motivações e os principais objetivos deste trabalho. No capítulo 2 são apresentados os conceitos e fundamentos referentes ao desenvolvimento da pesquisa. No capítulo 3 são comentados os principais trabalhos relacionados. No capítulo 4 são apresentados os modelos para as simulações. No capítulo 5 são apresentados os resultados da pesquisa. O capítulo 6 se refere à conclusão do texto. Por último, é destinada uma seção para as referências.

## 2 Referencial Teórico

O ponto central deste trabalho consiste na identificação de faltas internas nos geradores eólicos baseados na máquina de indução com rotor em gaiola mediante a implementação de algoritmos de sistemas inteligentes. Em decorrência desse fato, a descrição dos conceitos fundamentais sobre o funcionamento do gerador, das faltas internas e das RNAs e RNCs fornecem as bases essenciais para o desdobramento dos próximos passos da pesquisa, portanto, serão tópicos abordados nesse capítulo.

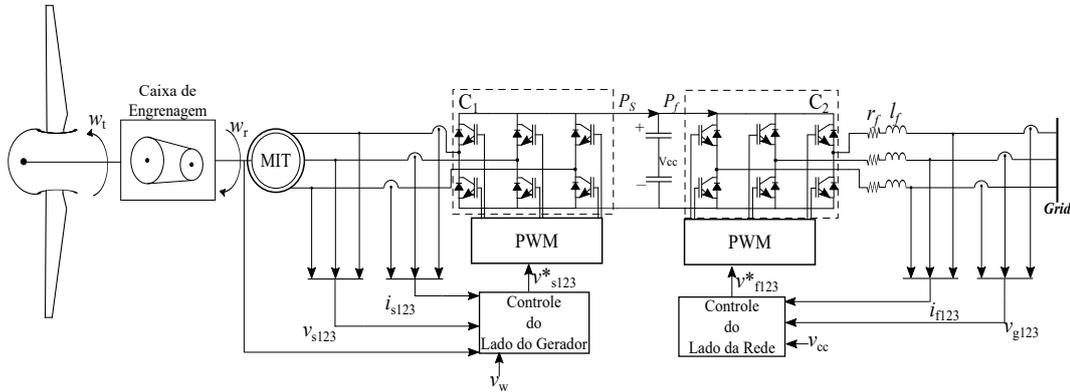
### 2.1 Geradores Eólicos Baseados na Máquina de Indução com Rotor em Gaiola

Os geradores eólicos são componentes presentes no sistema elétrico que utilizam a força aerodinâmica do vento na conversão em energia elétrica. Nesse cenário as diferentes categorias de geradores se diferenciam fundamentalmente pela máquina acoplada ao eixo para conversão eletromecânica de energia, no caso desse trabalho, os modelos utilizados para gerar as instâncias são baseados na máquina de indução com rotor em gaiola a qual é amplamente utilizada em aplicações de geração (ROYO; ARCEGA, 2007).

Embora as máquinas de indução sejam muito utilizadas como motores nos últimos anos verificou-se que os geradores de indução são bastante adequados em aplicações ligadas a energia eólica (FITZGERALD, 2014). As máquinas de indução que apresentam o rotor em gaiola possuem esse nome, pois o rotor é formado por barras curto-circuitadas e sem conexão externa. Essa construção resulta em equipamentos baratos, com baixo custo de manutenção e altamente confiáveis (FITZGERALD, 2014).

A Figura 1 apresenta a ilustração de um sistema de geração eólico, com um gerador gaiola de esquilo. Os componentes apresentados são: a turbina eólica com a parte aerodinâmica, o gerador, o controle do lado da rede, o controle do lado do gerador e os conversores com as chaves e diodos de proteção.

Figura 1: Sistema eólico.



Fonte: Elaborado pelo autor.

## 2.2 Faltas Internas

Comportamentos não desejados em sistemas reais são inevitáveis, mas suas consequências precisam ser minimizadas para não haver o colapso no fornecimento dos serviços. As plantas industriais, os sistemas de informação, os sistemas de geração e transmissão de energia, entre outros aumentaram a dependência tecnológica da sociedade, como consequência, verificou-se a necessidade de estudos ligados à área de diagnóstico e prevenção de falhas.

Os sistemas de alta complexidade necessitam de diferentes técnicas para garantir de maneira formal a qualidade do seu funcionamento e ainda são historicamente recentes, logo, alguns termos passam por um processo de popularização. Essa seção trata de algumas terminologias básicas na área de diagnóstico e prevenção de falhas baseada nos trabalhos de Laprie (1985) e Weber (2002).

### 2.2.1 Conceitos Básicos

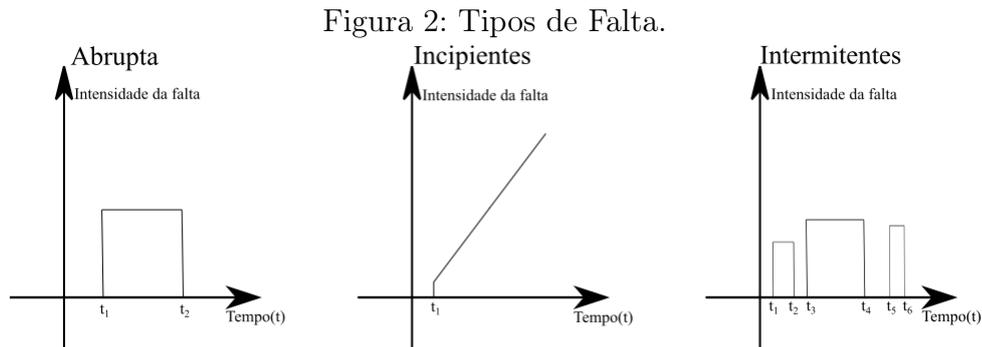
Defeito (*failure*) — é definido como um desvio da especificação do serviço, a especificação do serviço seria o serviço esperado pelo usuário, sendo o usuário outro sistema ou um humano. É dito que um sistema está operando erroneamente quando o processamento a partir desse estado pode conduzir a um defeito. Por último, a falha ou falta (*fault*) é a causa física ou algorítmica do erro.

É importante lembrar que falhas são inevitáveis, pois componentes físicos reais sofrem com o passar do tempo e com a interferência ambiental ou humana.

Em sistemas elétricos de potência muitas vezes os termos: defeito (*failure*), falta ou

falha (*fault*) e curto-circuito (*Short Circuit*) são usados como sinônimos. Esse trabalho vai adotar os termos falta, falha e curto-circuito por entender que são mais coerentes com a definição, pois os curtos-circuitos são fenômenos que ocorrem em sistemas elétricos e estão restritos ao universo de eventos físicos assim como a definição de falta ou falha (*fault*).

Outra definição importante é a classificação das falhas quanto ao intervalo de tempo que elas ocorrem podendo ser classificadas como: abrupta, incipientes e intermitentes. As faltas abruptas ocorrem de modo agressivo podendo causar algum acidente ou imprevisto grave, essa falta altera o comportamento do processo rapidamente, portanto, exige ações velozes e eficazes para mitigar as consequências. Já as faltas incipientes ocorrem a partir de pequenos desvios podendo ser facilmente mascaradas pelos controles e assim sendo negligenciada pelos operadores. Por último, as faltas intermitentes são falhas que ocorrem durante um período tempo, em seguida, cessam, e voltam a ocorrer, elas podem ser causadas por perturbações periódicas ou situações repetitivas. A Figura 2 apresenta essas categorias de faltas.



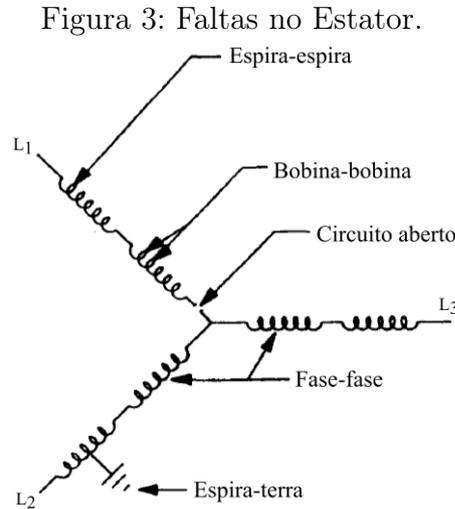
Fonte: Elaborado pelo autor.

As faltas tratadas nesse trabalho são do tipo incipientes, pois podem iniciar como um pequeno curto e devido ao calor e vibração gerados tendem a se agravar com o tempo se nada for feito. Nas máquinas elétricas 38% das faltas ocorrem no estator (NANDI; TOLIYAT; LI, 2005).

## 2.3 Faltas no Estator

Segundo Bonnett e Soukup (1992) as falhas relacionadas as bobinas do estator podem ocorrer de cinco formas, as quais são: (i) entre espiras, (ii) entre bobinas, (iii) circuito aberto, (iv) fase-fase e (v) fase-terra. A Figura 3 apresenta uma ilustração das diferentes faltas no estator, é apresentado a falta espira-terra a qual ocorre entre uma bobina do estator e a carcaça da máquina, a falta fase-fase em que o curto é estabelecido entre

duas fases da mesma máquina, a falta de circuito aberto em que existe o rompimento de uma das fases, a falta espira-espira onde espiras de uma mesma bobina entram em curto-circuito e a falta entre bobinas que ocorre entre bobinas de uma mesma fase.

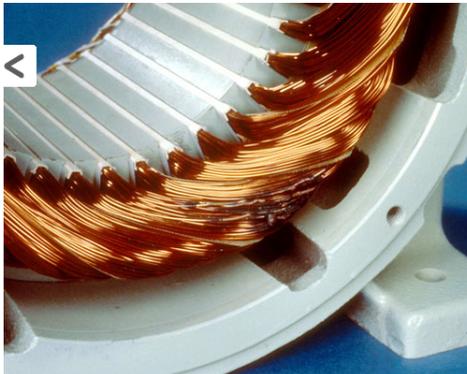


Fonte: A Figura foi extraída do artigo do (BONNETT; SOUKUP, 1992). Modificado pelo autor.

Em condição de falha as correntes de curto-circuito tendem a aumentar a degradação do isolamento devido ao sobreaquecimento provocado por pontos quentes, isto é, o curto-circuito continua evoluindo até que uma área maior do sistema de isolamento seja danificada e cause avarias mais severas, ao final, causando a degradação total da operação da máquina. Em geral essas faltas não são perceptíveis sendo negligenciadas pelos dispositivos de proteção (BONNETT; SOUKUP, 1992). A Figura 4 apresenta um estator afetado pela falta espira-espira e espira-terra.

Figura 4: Imagens das faltas espira-espira e espira-terra

(a) Falta Espira-espira



(b) Falta Espira-terra



Fonte: Disponível em: <<https://easa.com/resources/failures-in-three-phase-stator-windings>>. Acesso: 30 set. 2021

Foi demonstrado em Kaufhold et al. (2002) que a utilização de conversores de frequência para o acionamento de máquinas de indução pode causar até dez vezes mais estresse

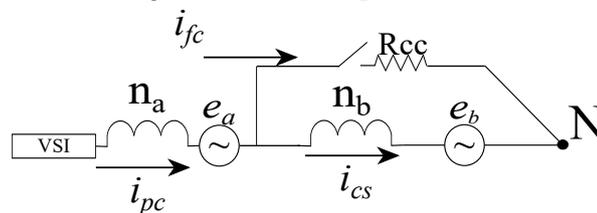
as bobinas do estator comparada a alimentação de linha. Isso ocorre devido ao baixo tempo de comutação da ordem de microssegundos que causa distribuições não lineares de tensão acarretando mais estresse elétrico entre espiras ou na terminação das bobinas (KAUFHOLD et al., 2002). Esse fato vem de encontro com os sistemas de conversores eletrônicos utilizados nos geradores eólicos tipo SCIG.

Além do efeito dos conversores as faltas estudadas podem ocorrer pela perda da capacidade de isolamento devido a fatores ambientais e operacionais como: temperaturas elevadas, desgaste do material isolante pelo tempo, sobrecarga, contaminação por produtos químicos, umidade, entre outros (BONNETT; SOUKUP, 1992). Nesse trabalho são analisadas faltas com duas origens principais. A primeira, a falta espira-espira, que ocorre quando as espiras de uma mesma bobina estão em curto. A segunda, a falta espira-terra, a qual ocorre entre as espiras e a carcaça do gerador.

Nas Figuras 5 e 6 é possível observar dois trechos distintos nas bobinas. O primeiro em que o curto foi de fato estabelecido e um segundo ainda saudável, apesar de sofrer ação da falta. Esses trechos distintos interagem entre si e com as outras bobinas presentes na máquina cada trecho tem sua força contraeletromotriz correspondente.

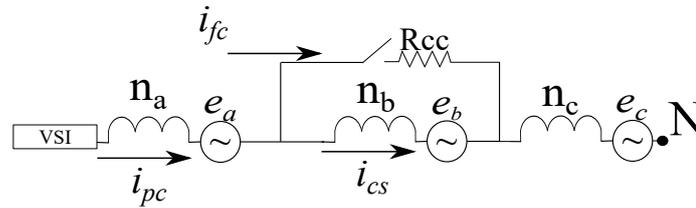
Nas bobinas em curto também podemos observar três correntes. A primeira,  $i_{pc}$  é a corrente que entra na bobina. A segunda,  $i_{fc}$  é a corrente estabelecida pela falta e está associada a uma resistência de falta  $R_{cc}$ . Por último, temos a corrente  $i_{fc}$  a qual corresponde a corrente que flui no interior do trecho do condutor em falta. A corrente  $i_{fc}$  e  $i_{fc}$  só podem ser mensuradas através de simulação ou em laboratório, pois existem várias dificuldades técnicas de fazer essa medição das correntes em campo, visto que seria necessário prever em que ponto da bobina iria ocorrer a falta antes dela acontecer.

Figura 5: Falta espira-terra.



Fonte: Elaborado pelo autor.

Figura 6: Falta espira-espira.



Fonte: Elaborado pelo autor.

## 2.4 Redes Neurais Artificiais

As RNAs consistem em um método baseado em otimização, pois o algoritmo mais comum de treinamento, na busca pela hipótese que descreve os dados, recorre à otimização de uma função do erro entre a resposta da rede e o rótulo de uma dada instância de treinamento correspondente (CARVALHO et al., 2011).

### 2.4.1 Inspiração Neurobiológica

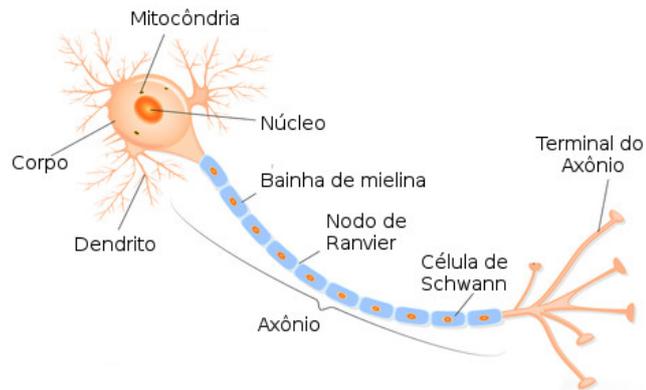
As RNAs apresentam forte inspiração neurobiológica, pois ao pensar em sistemas que podem aprender com a experiência é natural observar os sistemas biológicos.

A unidade básica do cérebro é o neurônio biológico o qual pode ser subdividido, de modo simplificado, em dendritos, corpo celular e axônio. Os dendritos são filamentos celulares bastante ramificados e especializados na recepção de estímulos nervosos os quais são transmitidos ao corpo celular. Já no corpo celular, dependendo da quantidade e frequência dos estímulos recebidos, é gerado um novo impulso o qual é enviado pelo axônio a outro neurônio. O axônio apresenta uma superfície lisa, com menor número de ramificações, sendo bastante longo e fino, em comparação com outras estruturas do neurônio, é o responsável pela condução de impulsos elétricos (SIMON, 2001). O nome dado ao contato entre o axônio e o dendrito, de diferentes neurônios, é sinapse. A Figura 7 ilustra os componentes básicos do neurônio biológico.

### 2.4.2 Redes Neurais Artificiais

As RNAs foram introduzidas pela primeira em McCulloch e Pitts (1943) em um estudo pioneiro o qual compreendia o comportamento do neurônio biológico objetivando a criação do modelo matemático correspondente. McCulloch e Pitts apresentaram um modelo computacional simplificado utilizando lógica proposicional de como os neurônios

Figura 7: Neurônio Biológico.

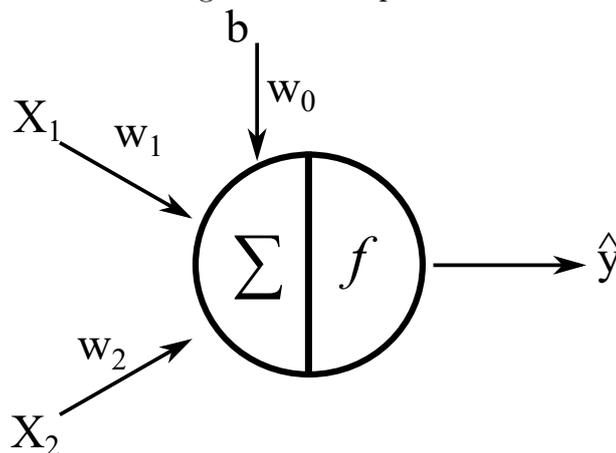


Fonte: Disponível em: <<https://www.infoescola.com/sistema-nervoso/neuronios/>>. Acesso: 04 dez. 2021

podem trabalhar juntos na realização de cálculos complexos, todavia não é possível treinar esses neurônios, pois não possuem parâmetros livres (GÉRON, 2019).

Outra grande contribuição foi dada por Frank Rosenblatt na década de cinquenta ao propor o perceptron. Nesse neurônio cada conexão de entrada está associada a um peso. O perceptron calcula uma soma ponderada das entradas e em seguida aplicada uma função de ativação,  $h(x)$ , sobre o somatório (ROSENBLATT, 1958). Uma ilustração de um perceptron é apresentada na Figura 8.

Figura 8: Perceptron.



Fonte: Elaborado pelo autor.

O treinamento do perceptron é inspirada na regra de Hebb. Donald Hebb em 1949 sugere que quando um neurônio biológico estimula outro com frequência as conexões entre eles ficam mais forte. No perceptron a interpretação dessa regra é usada para avaliar o erro gerado pela rede e não reforçar conexões que levam a saídas erradas (GÉRON, 2019).

Para o treinamento do perceptron temos a primeira etapa, previsão do modelo, matematicamente definida como:

$$\hat{y}_i = h\left(\sum w_i \cdot x_i + w_0\right). \quad (2.1)$$

Os ajustes do modelo no processo de treinamento podem ser definidos por:

$$\Delta w_i = \eta(y_i - \hat{y}_i)x_i \quad (2.2)$$

$$w'_i = \Delta w_i + w_i. \quad (2.3)$$

Onde:

- $\hat{y}_i$  é a saída do perceptron;
- $y_i$  é a saída desejada;
- $x_i$  é o vetor das entradas;
- $w_i$  são os pesos sinápticos;
- $w'_i$  são os pesos sinápticos na interação subsequente;
- $w_0$  é valor do viés;
- $\eta$  é a taxa de aprendizagem.

Apesar do otimismo à época limitações do perceptron foram apresentadas em 1969 por Marvin Minsky e Seymour Papert destacando-se a impossibilidade de resolver problemas não linearmente separáveis alguns particularmente simples como a solução do problema do OU Exclusivo (CARVALHO et al., 2011). Com o, conseqüente, desapontamento dos pesquisadores iniciou um período conhecido como inverno da inteligência artificial.

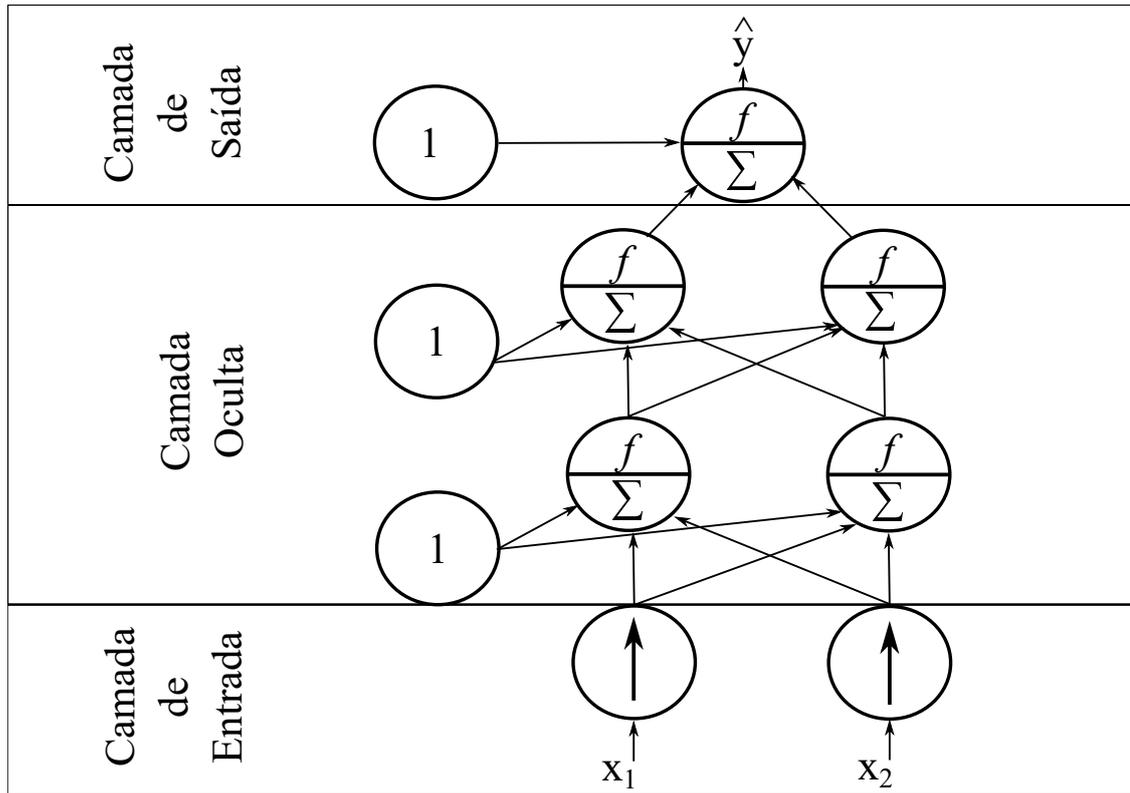
Entretanto, parte das limitações do perceptron podem ser eliminadas ao empilhar camadas de perceptron na rede e a RNA resultante é conhecida como perceptron multicamadas (MLP).

### 2.4.3 Perceptron Multicamadas

Uma MLP é formado por uma camada de entrada, uma camada intermediária, que pode conter várias camadas no seu interior e uma cama de saída. Uma dada camada

é sempre totalmente conectada com a camada subsequente. Com exceção da camada de entrada, em geral, todas as outras costumam ter um neurônio diferente chamada de neurônio de viés o qual permite alterar o limiar de disparo do perceptron. A Figura 9 apresenta uma ilustração de uma MLP, omitindo os pesos.

Figura 9: Perceptron Multicamadas.



Fonte: Elaborado pelo autor.

No fim da década de oitenta é apresentado um inovador algoritmo de treinamento utilizando a ideia de retropropagação (RUMELHART; HINTON; WILLIAMS, 1986), hoje é descrito como método do gradiente descendente.

No primeiro momento o algoritmo alimenta uma dada instância de treinamento na rede e calcula a saída de cada neurônio, em cada camada, e esse resultado é repassado para camada subsequente. Em uma segunda etapa ele mede o erro de saída da rede, ou seja, a diferença entre a saída real e a saída desejada e estima o quanto cada neurônio contribuiu para o erro dos neurônios da sua camada anterior, esse passo se repete até a camada de entrada. Durante essa passagem reversa é mensurado o gradiente do erro em todos os pesos da rede (GÉRON, 2019). No seu último passo o algoritmo ajusta os pesos das conexões para minimizar o erro (GÉRON, 2019).

O ajuste dos pesos é dado pela equação (2.4).

$$w'_{ij} = w_{ij} + \eta \cdot x \cdot \delta_i \quad (2.4)$$

Na equação (2.4),  $w_{ij}$  representa o peso entre um neurônio  $i$  e uma  $j$ -ésima conexão,  $w'_{ij}$  é o peso ajustado para próxima iteração,  $\delta_i$  indica o erro do neurônio  $i$  e  $x$  representa a entrada recebida pelo neurônio. O cálculo do erro,  $\delta_i$ , é diferente para neurônios da camada de saída em relação a neurônios da camada de intermediária, mas podemos resumir os dois casos pela equação (2.5).

$$\delta_j = \begin{cases} f'_a \cdot e_q & \text{se } n_i \in C_{sai} \\ f'_a \cdot \sum w_{ik} \delta_k & \text{se } n_i \in C_{int} \end{cases} \quad (2.5)$$

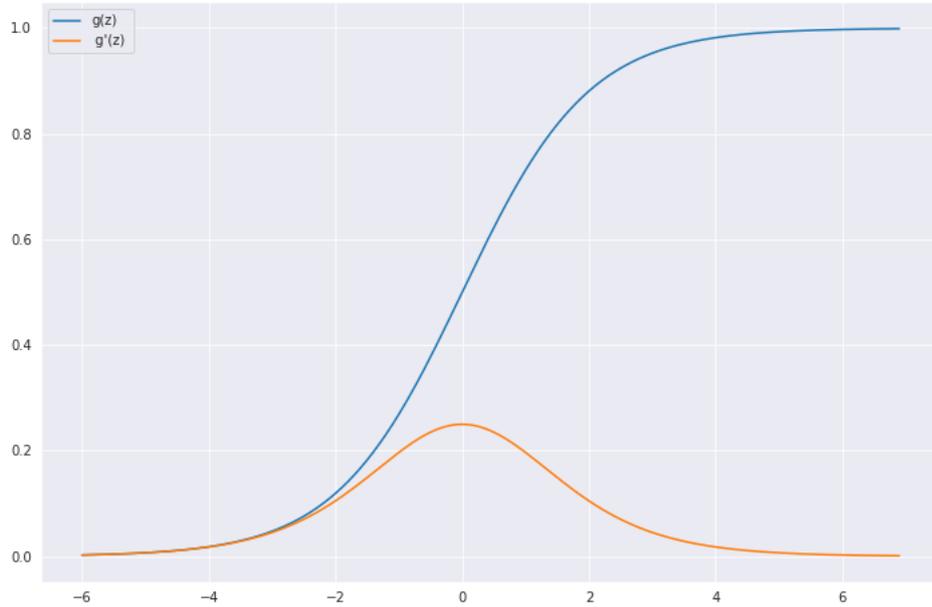
Na equação anterior,  $\delta_k$  é a soma dos erros da camada seguinte, para um neurônio da camada intermediária,  $f'_a$  é a derivada parcial da função de ativação,  $C_{sai}$  é o conjunto dos neurônios da camada de saída,  $C_{int}$  é o conjunto dos neurônios da camada intermediária e  $n_i$  representa um neurônio da rede. O erro de um dado neurônio da camada de saída, em relação à resposta desejada, é definido por:

$$e_q = \frac{1}{2} \sum_{i=1}^k (y_i - \hat{y}_i)^2 \quad (2.6)$$

Para o correto funcionamento do algoritmo ocorreu a alteração da função de ativação, os autores substituíram a função degrau pela função logística,  $g(z)$ , a função degrau possui apenas segmentos planos, ou seja, não possui gradiente para se trabalhar enquanto a função logística possui um gradiente bem definido (GÉRON, 2019). Atualmente existem outras funções usadas como função de ativação, um exemplo, é a função tangente hiperbólica. A função logística e sua derivada são apresentadas na Figura 10.

As RNAs são versáteis, robustas e escaláveis, podem ser usadas para reconhecimento de linguagem natural, classificação de imagens, recomendação de conteúdo publicitário e em diferentes aplicações interdisciplinares (Geron, A/2019).

Figura 10: Função logística e sua derivada.



Fonte: Elaborado pelo autor.

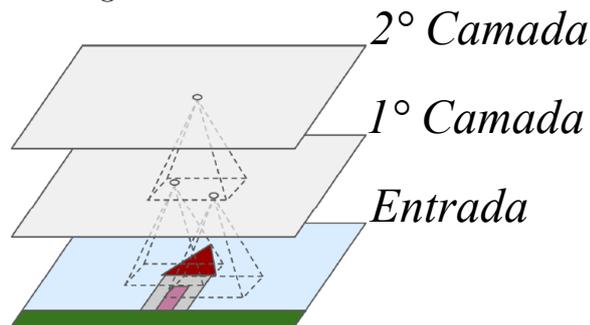
## 2.5 Rede Neural Convolutiva

As redes convolucionais assim como as RNA's são biologicamente inspiradas emergem dos estudos em gatos e macacos de David H. Hubel e Torsten Wiesel sobre o córtex visual (HUBEL, 1959),(HUBEL; WIESEL, 1959),(HUBEL; WIESEL, 1968), estudos que proporcionaram o prêmio Nobel aos autores em 1981. Os autores demonstraram que muitos neurônios no córtex visual possuem um pequeno campo receptivo local o que significa que eles reagem apenas a estímulos visuais localizados em determinada área do campo visual. Os campos receptivos de diferentes neurônios podem se sobrepor e formar o campo visual. Os autores também demonstraram que alguns neurônios têm campos receptivos maiores que outros e reagem a padrões mais complexos que são combinações dos padrões de níveis inferiores. Essa poderosa arquitetura inspirou o neognitson (FUKUSHIMA; MIYAKE, 1982) que gradualmente evoluiu para o que hoje são as RNCs que são largamente utilizadas em processamento de linguagem natural, reconhecimento de voz, sistemas automáticos de classificação de vídeos, pesquisas com imagens, entre outros (GÉRON, 2019).

Na RNC o bloco mais importante é a camada convolutiva. Os neurônios da primeira camada não estão relacionados a todos os *pixels* da imagem, mas estão relacionados aos

*pixels* dos seus respectivos campos receptivos, no que lhe concerne, cada neurônio da segunda camada está conectado apenas a neurônios localizados dentro de um pequeno retângulo da primeira camada. Essas relações entre duas camadas e a imagem é explicada na Figura 11. Essas características da RNC permite que a rede se concentre, nas primeiras camadas, em características de baixo nível e em camadas superiores nas características de alto nível (GÉRON, 2019).

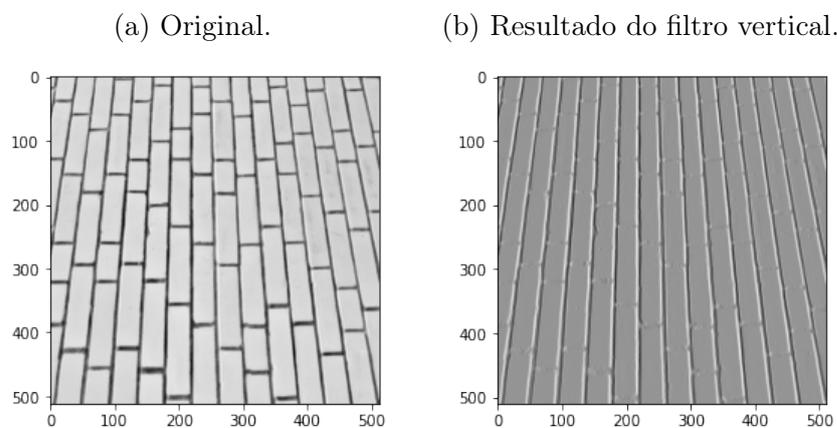
Figura 11: Uma fase do Estator.



Fonte: Modificado pelo autor. Imagem do Livro (GÉRON, 2019).

Os pesos nas RNC são representados por filtros. Quando neurônios da mesma camada possuem todos o mesmo filtro temos um mapa de característica o qual destaca determinada característica em uma imagem. Na Figura 12 temos uma imagem antes e depois da aplicação de um filtro, é possível perceber que a aplicação do filtro destaca linhas verticais. Durante o treinamento a RNC busca encontrar os filtros mais uteis para uma determinada tarefa e aprende a combiná-los em padrões mais complexos (GÉRON, 2019).

Figura 12: Aplicação do filtro.



Fonte: Elaborado pelo autor.

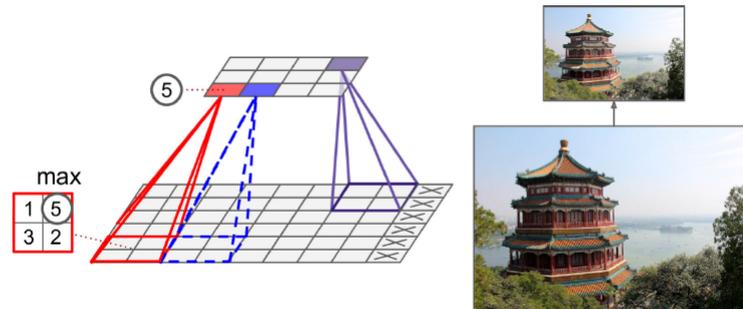
A camada convolucional é uma estrutura que contém vários mapas de características, uma determinada camada convolucional aplica simultaneamente vários filtros as entradas conseguindo destacar várias características importantes para a rede. Em geral, ao final da

camada convolucional é utilizada uma camada relacionada a uma função de ativação, por exemplo, a função ReLu.

### 2.5.1 Camada de Pooling

Outra estrutura importante para as RNC é a camada de pooling. O objetivo da camada de pooling é subamostrar a imagem de entrada para reduzir a carga computacional, o uso de memória e o número de parâmetros e desse modo limitar o risco de sobreajuste (*overfitting*). Semelhante aos neurônios da camada convolucional os neurônios na camada de pooling possuem um campo receptivo, mas nesse caso não possuem pesos, mas sim uma função de agregação comumente as funções utilizadas fazem a média dos *pixels* de uma região da imagem ou obtém o pixel de maior valor. A Figura 13 demonstra o funcionamento da camada de *pooling* usando a função que escolhe o maior valor de um determinado conjunto de *pixels*.

Figura 13: Camada de Pooling.



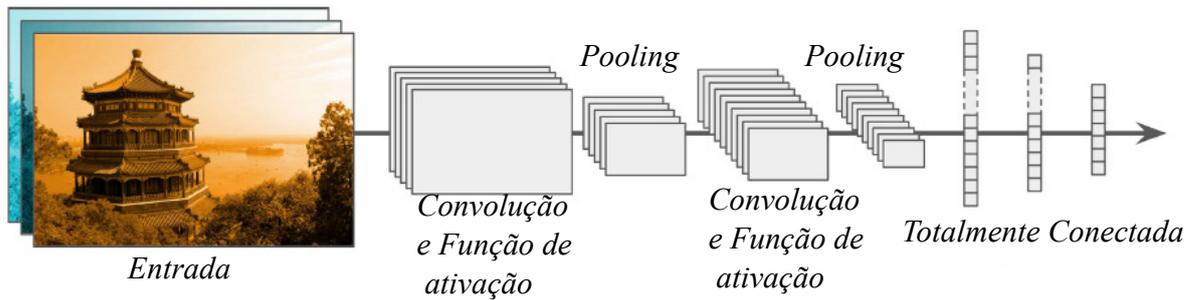
Fonte: Modificado pelo autor. Imagem do Livro (GÉRON, 2019).

### 2.5.2 Arquitetura Geral da RNC

Geralmente empilham camadas convolucionais com uma camada ReLu, depois uma camada de pooling, depois outra camada convolucional e assim por diante. Ao empilhar essas camadas a imagem fica menor ao caminhar pela rede devido às camadas de pooling, mas também se torna mais profunda devido aos mapas de características geradas pelas camadas convolucionais. Ao final das sucessivas camadas de convolução e pooling é utilizada uma rede totalmente conectada. A Figura 14 apresenta a arquitetura convencional de uma RNC.

Existem algumas vantagens dessa arquitetura frente a MLP, pois quando é necessário trabalhar com um grande volume de dados a MLP, geralmente, apresenta um processo de

Figura 14: Arquitetura RNC.



Fonte: Modificado pelo autor. Imagem do Livro (GÉRON, 2019).

treinamento mais lento (GÉRON, 2019). Por exemplo, utilizando uma imagem como uma matriz quadrada de ordem  $256 \times 256$  teríamos uma camada de entrada com  $n^2$  neurônios e a camada escondida poderia também ter  $n^2$  neurônios e para formar uma rede totalmente conectada precisaríamos de  $n^4$  pesos, logo,  $256^4$  pesos isso resulta em mais de 4 bilhões de pesos. No processo de treinamento poderia ser necessário atualizar esses pesos o que eleva o custo computacional e também da quantidade de memória para armazenar a rede.

## 2.6 Conclusão

Nesse capítulo foram abordados os temas mais relevantes para o entendimento de como funcionam as máquinas de indução, o que são as faltas na bobina do estator, o princípio de funcionamento das redes neurais artificiais e das redes neurais convolucionais.

## 3 Trabalhos Relacionados

Esse capítulo resume os principais trabalhos relacionados ao diagnóstico de faltas no bobinamento estatórico da máquina de indução com rotor em gaiola.

### 3.1 Estado da Arte

Equipamentos reais necessitam de manutenção, pois eventualmente apresentam alguma falha. Na indústria para contornar os transtornos gerados pelas falhas são utilizados, geralmente, dois métodos. No primeiro método são realizadas manutenções periódicas, em intervalos fixos, porém não se sabe se existe a real necessidade para a interrupção o que resulta em uma menor disponibilidade dos equipamentos. No segundo método a equipe de manutenção reage à falha quando elas ocorrerem, mas pode ocorrer uma falta grave que ponha em risco equipamentos e processos, causando perdas econômicas relevantes, ou até acidentes com pessoas no ambiente fabril (SINGH et al., 2003).

Na tentativa de minimizar custos e aumentar a disponibilidade na operação é utilizada a manutenção baseada em condições a qual busca identificar faltas em estágio inicial observando sinais que tem seu comportamento conhecido em determinado ponto de operação. No entanto, o problema dessa abordagem é a contínua necessidade da interpretação dos sinais pelo operador, mas para não depender da tomada de decisão humana em processos complexos surge a necessidade do desenvolvimento de sistemas automáticos para detecção de faltas (SINGH et al., 2003). Também é importante ressaltar que não é economicamente viável ter máquinas redundantes (WU; CHOW, 2004). A área de aprendizado de máquina pode auxiliar as indústrias a desenvolverem sistemas de detecção automática de falhas que não sejam totalmente dependentes da avaliação humana (SIDDIQUE; YADAVA; SINGH, 2003).

Devido aos fenômenos envolvidos no funcionamento das máquinas elétricas, alguns deles discutidos no capítulo 4, a literatura aponta para a necessidade de técnicas não invasivas para a avaliação das faltas, pois as medições são mais baratas, não afetam a

estrutura construtiva da máquina e são mais facilmente implementadas em campo (GRADIN; BURSTEIN, 1993),(WU; CHOW, 2004). Os sistemas orientados por dados podem ser treinados com dados provenientes de medições não intrusivas.

Nas máquinas elétricas diferentes faltas podem ocorrer. Percentualmente as faltas mais comuns são divididas basicamente em: 40% faltas de rolamento, 38% faltas no estator, 10% faltas no rotor e 12% todas as outras faltas (NANDI; TOLIYAT; LI, 2005), (KIA et al., 2013).

Para a detecção de faltas na máquina de indução três estratégias apresentam destaque na literatura. A primeira, a abordagem baseada em assinatura tenta obter o estado da máquina observado sinais no domínio do tempo ou da frequência. A segunda, abordagem baseada em modelo utiliza modelagem matemática para prever o comportamento das máquinas. A última, abordagem baseada em conhecimento utiliza técnicas de inteligência computacional para avaliar as condições da máquina tanto em aplicações *on-line* quanto *off-line* (ALI et al., 2019).

De modo geral, os métodos convencionais para monitoramento das condições das máquinas de indução são baseados na análise de assinatura de corrente do motor (MCSA, do inglês *Motor Current Signature Analysis*), ou seja, seguindo uma abordagem baseada em assinatura utilizam as componentes espectrais da corrente do estator para inferir o diagnóstico das condições da máquina. No entanto, alguns trabalhos demonstraram matematicamente e experimentalmente que as componentes espectrais geradas por curto-circuito nas bobinas do estator não são um indicador exato para definir falhas nos enrolamentos, pois o enrolamento faltoso do estator pode produzir harmônicas especiais no campo do entreferro, porém todas variam numa mesma frequência, ou seja, na frequência da fonte, logo, uma falta no estator pode mudar a amplitude das harmônicas da corrente do estator, mas não produz uma nova frequência (JOKSIMOVIC; PENMAN, 2000), (SANTOS; SILVA; SUETAKE, 2012),(ROYO; ARCEGA, 2007). Esse fato leva a dúvida sobre a falta já que pode ser confundida com outros eventos como: a variação de carga, desequilíbrio da fonte, saturação magnética, entre outros, logo, as componentes não podem ser usadas como uma solução definitiva para avaliar a ocorrência de curto-circuito nos enrolamentos do estator (ROYO; ARCEGA, 2007), (JOKSIMOVIC; PENMAN, 2000).

A abordagem baseada em modelos, geralmente, avalia as condições das máquinas em regime permanente e a qualidade da avaliação depende da precisão do modelo (SAPENABANO et al., 2018),(ALI et al., 2019).

Outros métodos são utilizados para avaliar o sistema de isolamento como a medição da

resistência de isolamento, porém esse método não é *on-line*, isto é, requer que a máquina seja retirada do processo e também outra desvantagem é que não tem como saber se o enrolamento está prestes a falhar. Outra opção são os ensaios de surto de tensão, mas esse método apesar de poder ser aplicado de modo *on-line* ele também não informa se o componente está prestes a falhar. Também existem métodos baseados em estimativa de parâmetro, porém depende de modelos matemáticos precisos e com isso necessita de um especialista (GOODE; CHOW, 1995a).

Na abordagem baseada em conhecimento os algoritmos de inteligência computacional necessitam de uma grande base de dados para poderem treinar e obter um bom desempenho em seus resultados. Devido ao grande número de fenômenos envolvidos quando uma falta elétrica ocorre diferentes métodos foram propostos tendo como diferenças os sinais e os algoritmos.

Durante os últimos anos os métodos de aprendizado de máquina mais relatados para diagnóstico de falhas de máquinas de indução são as RNA (ALI et al., 2019). Os primeiros trabalhos com as RNA buscaram destacar a possibilidade do desenvolvimento de uma *interface* com motores reais para detecção de faltas (CHOW; YEE, 1991), mas outros pontos importantes são a facilidade de implementação, utilização de diferentes sinais, robustez ao ruído e facilidade de automação (GHATE; DUDUL, 2010)(SANTOS; SILVA; SUETAKE, 2012) (GHATE; DUDUL, 2010). Já entre os sinais mais utilizados para avaliar as faltas estão as correntes do estator e o sinal de vibração (ALI et al., 2019),(RAD; TORABIZADEH; NOSHADI, 2011).

Mas outros estudos foram em direções distintas, por exemplo, a utilização dos vetores de Park (NEJJARI; BENBOUZID, 2000) e Clarke (MARTINS; PIRES; PIRES, 2007) das correntes do estator. Alguns trabalhos desenvolvem algoritmos híbridos utilizando mais de uma estratégia para a detecção das faltas (SCHOEN et al., 1995), (DEMIAN; CIRRINCIONE; CAPOLINO, 2002), (WU; CHOW, 2004)(OLIVEIRA; PONTES; MEDEIROS, 2013), (SUN et al., 2017). Além dos trabalhos que usam imagens para avaliar as faltas (CHEN et al., 2020)(SHAO et al., 2020). A Tabela 1 resume as principais contribuições desses trabalhos.

Outros trabalhos foram importantes para a compreensão dos fenômenos envolvidos nas faltas (THOMSON; FENGER, 2001),(JOKSIMOVIC; PENMAN, 2000). Alguns autores utilizaram a lógica fuzzy junto as redes neurais para desenvolver um sistema de detecção (GOODE; CHOW, 1995a),(GOODE; CHOW, 1995b),(BALLAL et al., 2007),(ALTUG; CHEN; TRUSSELL, 1999). Em Ali et al. (2019) foi avaliado diversos classificadores. A Tabela 2 resume esses trabalhos.

Tabela 1: Resumo dos Trabalhos que utilizam redes neurais.

<b>Trabalhos</b>	<b>Estratégia</b>	<b>Contribuições</b>
(CHOW; YEE, 1991)	Utiliza um classificador que apresenta dois estágios utilizando redes neurais artificiais.	Uma das primeiras contribuições a desenvolver uma metodologia para detecção <i>on-line</i> de faltas em motores de indução tipo gaiola de esquilo utilizando redes neurais artificiais.
(SCHOEN et al., 1995)	Rede Neural Artificial.	Utiliza uma RNA associado a um filtro baseado em conhecimento de um especialista.
(NEJJARI; BENBOUZID, 2000)	Rede Neural Artificial.	Utiliza os vetores da transformada de Park.
(DEMIAN; CIRINCIONE; CAPOLINO, 2002)	Rede Neural Artificial	Utiliza o MCSA com as redes neurais artificiais.
(WU; CHOW, 2004)	Rede Neural Artificial.	Utiliza o SOM para selecionar os melhores hiperparâmetros.
(MARTINS; PIRES; PIRES, 2007)	Rede Neural Artificial não supervisionada.	Utiliza os vetores da transformada de Clarke.
(GHATE; DUDUL, 2010)	Rede Neural Artificial	Adiciona ruído aos sinais e avalia a classificação.
(OLIVEIRA; PONTES; MEDEIROS, 2013)	Rede Neural Artificial	Utiliza as redes neurais artificiais associadas ao padrão de frequências Thomson.
(VIEIRA; MEDEIROS; SILVA, 2016)	Rede Neural Artificial	Separa as instâncias observando o aspecto de impedância das faltas.
(SUN et al., 2017)	Rede Neural Convolutiva	Utiliza um classificador com dois estágios uma rede convolutiva e um SVM.
(SHAO et al., 2020)	Rede Neural Convolutiva	Utiliza imagens térmicas em infravermelho.
(CHEN et al., 2020)	Rede Neural Convolutiva	Utiliza a análise de frequência nos sinais de vibração.

Tabela 2: Resumo dos Trabalhos Relacionados.

<b>Trabalhos</b>	<b>Contribuições</b>
(GOODE; CHOW, 1995a) (GOODE; CHOW, 1995b)	Descreve uma metodologia que busca extrair as vantagens das redes neurais e dos sistemas fuzzy.
(ALTUG; CHEN; TRUSSELL, 1999)	Avalia métodos populares de sistemas lógica fuzzy com redes neurais para o processo de detecção de faltas.
(JOKSIMOVIC; PENMAN, 2000)	Demonstra que o MCSA não é definitivo para a detecção de faltas.
(THOMSON; FENGER, 2001)	Descreve o MCSA qualitativamente e quantitativamente.
(BALLAL et al., 2007)	Utiliza uma abordagem fuzzy neural adaptativa.
(ALI et al., 2019)	Compara diversos classificadores.

Esse estudo propõe desenvolver dois classificadores utilizando RNA e RNC para avaliar faltas no bobinamento estatórico dos geradores eólicos baseados na máquina de indução com rotor em gaiola tendo como diferença fundamental para trabalhos anteriores a utilização de dados artificiais. Os classificadores desenvolvidos devem identificar se as instâncias são de um gerador com o estator em falta ou de um gerador saudável.

A utilização de dados artificiais também pode contribuir para aumentar o tamanho das bases de dados além de aumentar a diversificação de casos no conjunto de treinamento e teste. Em laboratório questões práticas impedem a criação de bases com grande diversificação, por exemplo, ter máquinas com diferentes potências.

Esse trabalho se localiza como um híbrido das abordagens já apresentadas, pois utiliza um modelo matemático, que gera sinais de corrente no tempo, e os classificadores que são baseados em sistemas inteligentes. Essa abordagem busca unir dois elementos a possibilidade do uso de modelos matemático para criar instâncias e com isso o custo para obter as instâncias é reduzido, pois não é necessário realizar curtos em uma máquina real, já pelo lado do sistema de detecção ao utilizar uma inteligência artificial é possível criar um classificador automático que auxilie os operadores na investigação das faltas.

## 3.2 Conclusão

Nessa seção foram apresentados os principais trabalhos desenvolvidos sobre o tema de detecção de faltas na máquina de indução observando às três principais abordagens que a literatura apresenta. Essa seção também busca localizar o presente trabalho apresentando suas diferenças, como a utilização de dados artificiais, para as soluções já apresentadas.

## 4 Metodologia

Essa seção descreve a metodologia proposta nesse trabalho para a detecção das faltas espira-espira e espira-terra em geradores eólicos baseados na máquina de indução com rotor em gaiola.

### 4.1 Introdução

Sistemas físicos reais podem apresentar diferentes categorias de faltas e elas diminuem a disponibilidade dos equipamentos e, conseqüentemente, diminuem a produtividade. Apesar de não ser possível eliminar totalmente o risco de ocorrência das faltas, pois geralmente elas ocorrem por algum estresse físico inerente ao próprio processo industrial, é necessário investir na identificação e em processos para mitigar seus efeitos evitando que evoluam, danifiquem outros sistemas e, em casos mais graves, causem óbitos. As faltas estudadas, como comentadas no capítulo dois, podem evoluir rapidamente e causar danos severos ao estator da máquina, além dos danos financeiros por interrupções não programadas. Nessa metodologia propõe-se o treinamento de sistemas inteligentes que busquem identificar as faltas espira-espira e espira-terra utilizando dados sintetizados a partir de modelos matemáticos e simulação.

Sistemas reais, com maior ou menor complexidade, podem ser modelados matematicamente com a finalidade de representar as falhas mais preocupantes ou mais comuns. No caso desse trabalho, as faltas foram escolhidas por serem consideradas graves dado o prejuízo causado a operação da máquina em poucos minutos. Essas faltas também são comuns, pois ocorrem por vibrações, elevação de temperatura e picos de tensão e esses eventos são frequentes em sistemas elétricos.

O aumento de poder de processamento dos computadores aliado ao avanço das linguagens de programação resultou em ferramentas de simulação mais poderosas. As novas tecnologias permitem simular modelos matemáticos mais complexos, fazer o compartilha-

mento com outros grupos de pesquisa, ter mais precisão, obter resultados mais rápidos e, conforme o rigor da modelagem ou necessidade, incluir fenômenos inicialmente não modelados em modelos anteriores sem precisar refazer todo o modelo. Os modelos desenvolvidos nesse trabalho são comentados detalhadamente no capítulo cinco e o sistema foi simulado no Matlab/Simulink.

## 4.2 Princípio

Inicialmente, na metodologia proposta, são modeladas as faltas e os sistemas. Nesse trabalho, são modeladas as faltas espira-espira e espira-terra em um gerador eólico. Nesse contexto, como as análises sobre as faltas são realizadas em um gerador eólico foi necessário modelar os principais componentes de um sistema eólico completo. Assim, foi incluído na simulação o modelo aerodinâmico da turbina eólica com o efeito de sombreamento e a torção no eixo. Em outra etapa, foi incluído o funcionamento das chaves eletrônicas dos conversores e depois os sistemas de controle tanto do lado da rede como do lado do gerador. Por último, foi modelado as faltas a partir do circuito elétrico equivalente do estator faltoso tanto no caso espira-espira como espira-terra. Cada uma dessas etapas são detalhadas matematicamente no capítulo cinco. Ao desenvolver um modelo matemático é preciso apreciar sua fundamentação teórica e ele precisa ser representativo da situação que pretende retratar. Por exemplo, os modelos citados anteriormente são baseados nas leis de Kirchhoff e na física newtoniana.

De modo geral, podem ser selecionadas faltas em que os dados sejam difíceis de serem obtidos. Por exemplo, faltas financeiramente custosas de serem realizadas em sistemas reais, faltas em sistemas críticos e faltas que são tecnicamente difíceis de serem medidas em campo e em laboratório. Ainda assim, é melhor ter-se dados reais, porém, no caso de as condições para se conseguir as instâncias reais serem adversas, pode-se optar por uma modelagem dos sistemas e as faltas que produza dados artificiais. No contexto desse trabalho, realizar-se curtos-circuitos sucessivos em máquinas de indução, para obter as instâncias em diferentes pontos de operação, provoca um dano severo ao estator. Além disso não ser financeiramente viável, a medição de algumas correntes em campo não são viáveis como, por exemplo, a corrente de falta. Por outro lado, na modelagem (como descrito no capítulo cinco) é possível se ter acesso à essa grandeza.

Após realizar a etapa de modelagem das faltas e dos sistemas é necessário escolher uma ferramenta para simular o modelo. Nesse momento, escolher ferramentas que são mais

conhecidas e mais atualizadas ajudará a incluir novos fenômenos em melhorias futuras, diminuir o tempo de simulação e facilitar o compartilhamento com outros profissionais e grupos de pesquisa. Nesse trabalho foi utilizado o Matlab/Simulink como ferramenta de simulação.

Durante a etapa de simulação também é fundamental escolher o tipo de dado de saída, pois esse é um ponto importante do fluxo dos dados, pois os dados serão utilizados na etapa de treinamento do sistema de detecção. No caso desse trabalho, ao final da simulação foi extraído do Matlab/Simulink duas saídas, uma imagem e um arquivo CSV (do inglês, comma-separated-values ). A imagem será utilizada no treinamento da rede convolucional e o arquivo CSV na rede neural artificial. De modo geral, o formato de saída da simulação vai depender da etapa subsequente onde esse dado será utilizado.

Após escolher os dados de saída da simulação é importante iniciar o pré-processamento adequado para cada tipo de dado observando o sistema de detecção que será alimentado com essas informações e, quando for necessário, é preciso avaliar os hiperparâmetros que serão utilizados e como será realizado o treinamento. Nesse trabalho, foram escolhidas uma RNA e uma RNC sendo utilizada a função GridSearchCV do Scikit-Learn para escolher os melhores hiperparâmetros. Detalhes sobre o pré-processamento, treinamento e avaliação utilizados nesse trabalho são comentados no capítulo seis.

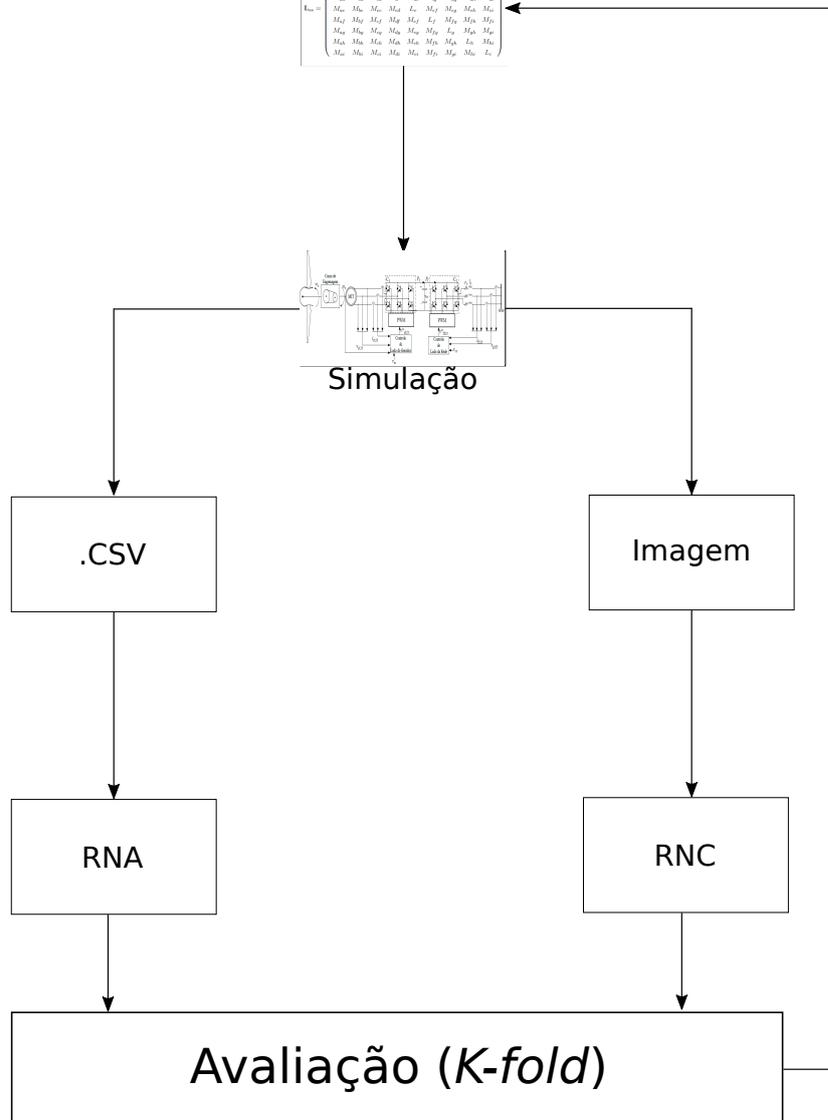
Na etapa de avaliação é possível comparar os resultados dos métodos de detecção propostos e investigar qual foi o melhor, se a necessidade de evoluir o modelo de treinamento e quais fenômenos ainda não modelados precisam ser incluídos para aumentar o desempenho. Nesse estudo, o método de avaliação utilizado para analisar o desempenho das redes neurais foi o *k-fold* que divide o conjunto de dados, mantendo a divisão de classes do banco de dados original, e treina cada subconjunto novo. O *k-fold* é bastante utilizado em estatística, pois garante que a ordem dos dados não influencia nos resultados observados.

A Figura 15 apresenta essa metodologia e cada etapa explicada anteriormente. É importante lembrar que a adoção de dados artificiais não exclui a utilização de dados reais, pois bases com instâncias reais podem ser expandidas utilizando simulação. A incorporação de dados artificiais pode diminuir o tempo para construção de bases maiores, ampliar a variedade das amostras e conseqüentemente tornar o sistema de detecção mais robusto, pois será testado em um número maior de condições diferentes.

Figura 15: Metodologia.

**Modelo Matemático**

$$L_{m,n} = \begin{pmatrix} L_{m,n} & M_{m,n} \\ M_{m,n} & L_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} \\ M_{m,n} & L_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} \\ M_{m,n} & M_{m,n} & L_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} \\ M_{m,n} & M_{m,n} & M_{m,n} & L_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} \\ M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & L_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} \\ M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & L_{m,n} & M_{m,n} & M_{m,n} \\ M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & M_{m,n} & L_{m,n} & M_{m,n} \\ M_{m,n} & L_{m,n} \end{pmatrix}$$



Elaborado pelo autor.

### 4.3 Conclusão

Esse capítulo busca resumir a metodologia proposta nesse trabalho e detalhar como cada etapa foi desenvolvida. Vale lembrar que essa metodologia não se resume ao universo de máquinas elétricas ou sistemas elétricos também é possível pensar em diversas outras aplicações industriais como, por exemplo, as falhas mecânicas em mancais e em partes moveis.

## 5 Modelagem

Nessa seção será apresentado o modelo convencional da máquina de indução, posteriormente, será apresentado os modelos para as faltas estudadas, e por fim os outros componentes da turbina eólica, ou seja, o modelo aerodinâmico, os subsistemas de controle do lado do gerador e do lado da rede e os conversores PWM (do inglês, *do inglês, Pulse Width Modulation*).

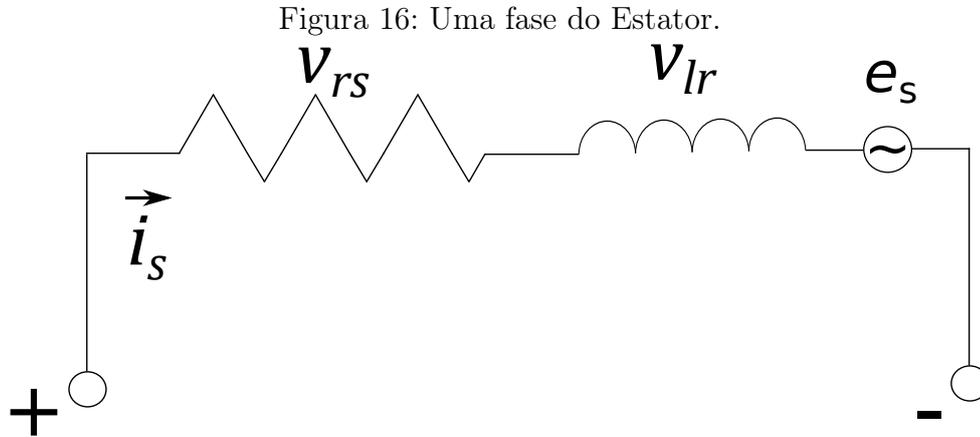
### 5.1 Modelo Convencional da Máquina de Indução

Para a devida representação matemática da máquina em estudo, serão feitas algumas hipóteses simplificadoras, sem as quais a formulação tornar-se extremamente complexa (BARBI, 1985).

Hipótese de estudo:

- Os três enrolamentos estatóricos são iguais entre si;
- Os três enrolamentos rotóricos são iguais entre si;
- Os ângulos elétricos entre os enrolamentos são iguais, tanto no estator quanto no rotor;
- O entreferro é considerado constante;
- O circuito magnético é considerado ideal, ou seja, a saturação não é considerada;
- A distribuição da densidade de fluxo magnético no entreferro é radial e senoidal;
- Não serão consideradas as perdas magnéticas.

Primeiro cada enrolamento pode ser representado como uma resistência em série com uma indutância. A Figura 16 representa uma ilustração de uma dada fase do estator.



Fonte: Modificado pelo autor.

A queda de tensão nesse circuito pode ser escrita como:

$$V_s = V_{rs} + V_{ls} \quad (5.1)$$

$$V_s = R_s \cdot i_s + \frac{d\lambda_s}{dt} \quad (5.2)$$

Onde:

- $V_s$ ,  $V_{rs}$  e  $V_{ls}$  são, respectivamente, a queda de tensão na fase, queda de tensão no resistor e a queda de tensão no indutor;
- $R_s$  e  $i_s$  são, respectivamente, a resistência e a corrente da fase;
- $\lambda_s$  é o fluxo magnético no indutor.

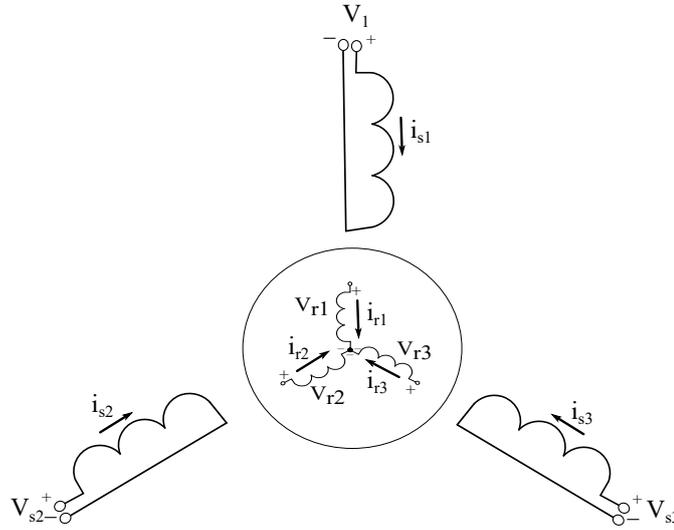
No entanto, é importante lembrar do acoplamento magnético que existe entre as bobinas do estator e do rotor, logo, o termo que descreve o fluxo em cada bobina precisa conter a interação entre as bobinas da máquina. A Figura 17 representa as bobinas do rotor e do estator.

Para facilitar o entendimento a notação será padronizada. Notações:

- $L_s$ ,  $L_r$  são as indutâncias própria da bobina do estator e do rotor, respectivamente. Sabendo que:  $L_{s1} = L_{s2} = L_{s3} = L_s$  e  $L_{r1} = L_{r2} = L_{r3} = L_r$ ;
- $M_s$  e  $M_r$  representam as indutâncias mútuas entre um par de bobinas do estator e um par de bobinas do rotor, respectivamente. Suponto que:  $M_{s12} = M_{s23} = M_{s31} = M_s$  e  $M_{r12} = M_{r23} = M_{r31} = M_r$ ;

- $M_{rs}\cos(\theta_r)$  é a indutância mútua entre um enrolamento do estator e um do rotor, lembrando que o rotor é a parte móvel e assim vai existir uma distância angular  $\theta_r$ ;
- $R_s$  e  $R_r$  são a resistência das bobinas do estator e do rotor, respectivamente. Considerando que:  $R_{s1} = R_{s2} = R_{s3} = R_s$  e  $R_{r1} = R_{r2} = R_{r3} = R_r$ .
- $v_{s123}$  e  $v_{r123}$  são as quedas de tensão nos enrolamentos do estator e do rotor, respectivamente.

Figura 17: Bobinas do Estator e do Rotor.



Fonte: Elaborado pelo autor.

A equação (5.3), (5.4) e (5.5) representam as equações de fluxo para o estator, de modo semelhante é possível escrever as equações de fluxo para o rotor.

$$\lambda_{s1} = L_s i_{s1} + M_s i_{s2} + M_s i_{s3} + M_{sr} \cos(\theta_r) i_{r1} + M_{sr} \cos(\theta_r + \frac{2\pi}{3}) i_{r2} + M_{sr} \cos(\theta_r + \frac{4\pi}{3}) i_{r3} \quad (5.3)$$

$$\lambda_{s2} = M_s i_{s1} + L_s i_{s2} + M_s i_{s3} + M_{sr} \cos(\theta_r + \frac{4\pi}{3}) i_{r1} + M_{sr} \cos(\theta_r) i_{r2} + M_{sr} \cos(\theta_r + \frac{2\pi}{3}) i_{r3} \quad (5.4)$$

$$\lambda_{s3} = M_s i_{s1} + M_s i_{s2} + L_s i_{s3} + M_{sr} \cos(\theta_r + \frac{2\pi}{3}) i_{r1} + M_{sr} \cos(\theta_r + \frac{4\pi}{3}) i_{r2} + M_{sr} \cos(\theta_r) i_{r3} \quad (5.5)$$

As equações dos fluxos podem ser reescritas na forma matricial e obtém-se a seguinte representação:

$$\lambda_{s123} = \overline{L_{ss}} \cdot i_{s123} + \overline{L_{sr}} \cdot i_{r123} \quad (5.6)$$

$$\lambda_{r123} = \overline{L_{rr}} \cdot i_{r123} + \overline{L_{rs}} \cdot i_{s123} \quad (5.7)$$

Observando a equação (5.2) podemos escrever uma forma matricial para a equação de queda de tensão para as fases do estator e do rotor e temos:

$$v_{s123} = \overline{R}_s \cdot i_{s123} + \frac{d\lambda_{s123}}{dt} \quad (5.8)$$

$$v_{r123} = \overline{R}_r \cdot i_{r123} + \frac{d\lambda_{r123}}{dt} \quad (5.9)$$

Utilizando as equações do fluxo (5.3), (5.4) e (5.5) podemos reescrever as equações (5.10) e (5.11) e temos:

$$v_{s123} = \overline{R}_s \cdot i_{s123} + \overline{L}_{ss} \frac{di_{s123}}{dt} + \overline{L}_{sr} \frac{di_{r123}}{dt} + \omega_r \frac{d\overline{L}_{sr}}{d\theta_r} i_{r123} \quad (5.10)$$

$$v_{r123} = \overline{R}_r \cdot i_{r123} + \overline{L}_{rr} \frac{di_{r123}}{dt} + \overline{L}_{rs} \frac{di_{s123}}{dt} + \omega_r \frac{d\overline{L}_{rs}}{d\theta_r} i_{s123} \quad (5.11)$$

onde:

$$\overline{L}_{ss} = \begin{bmatrix} L_s & M_s & M_s \\ M_s & L_s & M_s \\ M_s & M_s & L_s \end{bmatrix} \quad (5.12)$$

$$\overline{L}_{rr} = \begin{bmatrix} L_r & M_r & M_r \\ M_r & L_r & M_r \\ M_r & M_r & L_r \end{bmatrix} \quad (5.13)$$

$$\overline{L}_{sr} = M_{sr} \begin{bmatrix} \cos(\theta_r) & \cos(\theta_r + \frac{2 \cdot \pi}{3}) & \cos(\theta_r + \frac{4 \cdot \pi}{3}) \\ \cos(\theta_r + \frac{4 \cdot \pi}{3}) & \cos(\theta_r) & \cos(\theta_r + \frac{2 \cdot \pi}{3}) \\ \cos(\theta_r + \frac{2 \cdot \pi}{3}) & \cos(\theta_r + \frac{4 \cdot \pi}{3}) & \cos(\theta_r) \end{bmatrix} \quad (5.14)$$

$$\frac{d\overline{L}_{sr}}{dt} = -M_{sr} \begin{bmatrix} \sin(\theta_r) & \sin(\theta_r + \frac{2 \cdot \pi}{3}) & \sin(\theta_r + \frac{4 \cdot \pi}{3}) \\ \sin(\theta_r + \frac{4 \cdot \pi}{3}) & \sin(\theta_r) & \sin(\theta_r + \frac{2 \cdot \pi}{3}) \\ \sin(\theta_r + \frac{2 \cdot \pi}{3}) & \sin(\theta_r + \frac{4 \cdot \pi}{3}) & \sin(\theta_r) \end{bmatrix} \quad (5.15)$$

Podemos dizer que:

$$\overline{L_{rs}} = \overline{L_{sr}}^T \quad (5.16)$$

$$\frac{\overline{L_{rs}}}{dt} = \frac{\overline{L_{sr}}^T}{dt} \quad (5.17)$$

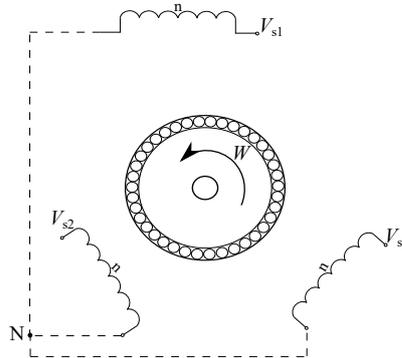
Por último, o conjugado elétrico é descrito por:

$$T_e = P \cdot i_{s123}^t \cdot \left[ \frac{d\overline{L_{sr}}}{d\theta_r} \right] \cdot i_{r123} \quad (5.18)$$

## 5.2 Modelo Para Falta Espira-espira

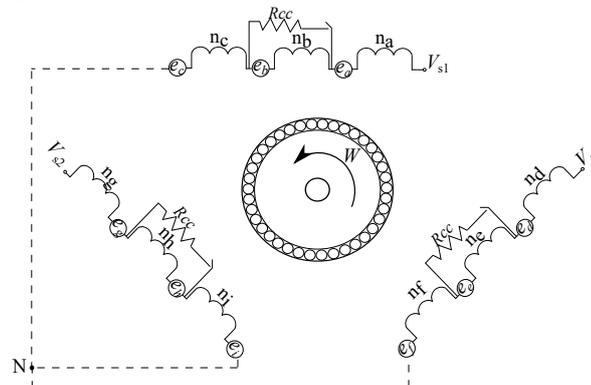
A falta espira-espira ocorre quando existe a ruptura do sistema de isolamento em espiras de uma mesma bobina. A Figura 18 ilustra as espiras de uma máquina saudável e a Figura 19 ilustra uma máquina genérica com a falta espira-espira.

Figura 18: Máquina Saudável.



Fonte: Elaborado pelo autor.

Figura 19: Máquina com a Falta Espira-Espira.



Fonte: Elaborado pelo autor.

Com essas informações, podemos escrever as matrizes que descrevem o comportamento da máquina em falta, as matrizes para falta espira-espira são:

$$\mathbf{L}_{ss} = \begin{pmatrix} L_a & M_{ab} & M_{ac} & M_{ad} & M_{ae} & M_{af} & M_{ag} & M_{ah} & M_{ai} \\ M_{ab} & L_b & M_{bc} & M_{bd} & M_{be} & M_{bf} & M_{bg} & M_{bh} & M_{bi} \\ M_{ac} & M_{bc} & L_c & M_{cd} & M_{ce} & M_{cf} & M_{cg} & M_{ch} & M_{ci} \\ M_{ad} & M_{bd} & M_{cd} & L_d & M_{de} & M_{df} & M_{dg} & M_{dh} & M_{di} \\ M_{ae} & M_{be} & M_{ec} & M_{ed} & L_e & M_{ef} & M_{eg} & M_{eh} & M_{ei} \\ M_{af} & M_{bf} & M_{cf} & M_{df} & M_{ef} & L_f & M_{fg} & M_{fh} & M_{fi} \\ M_{ag} & M_{bg} & M_{cg} & M_{dg} & M_{eg} & M_{fg} & L_g & M_{gh} & M_{gi} \\ M_{ah} & M_{bh} & M_{ch} & M_{dh} & M_{eh} & M_{fh} & M_{gh} & L_h & M_{hi} \\ M_{ai} & M_{bi} & M_{ci} & M_{di} & M_{ei} & M_{fi} & M_{gi} & M_{hi} & L_i \end{pmatrix}$$

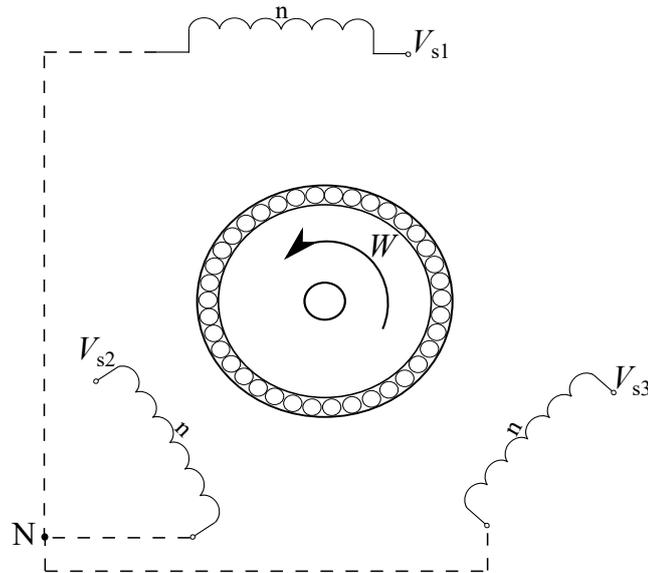
$$\mathbf{L}_{sr} = \begin{pmatrix} \frac{na}{n} \cdot \cos(\theta) & \frac{na}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{na}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) \\ \frac{nb}{n} \cdot \cos(\theta) & \frac{nb}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{nb}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) \\ \frac{nc}{n} \cdot \cos(\theta) & \frac{nc}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{nc}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) \\ \frac{nd}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nd}{n} \cdot \cos(\theta) & \frac{nd}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) \\ \frac{ne}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{ne}{n} \cdot \cos(\theta) & \frac{ne}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) \\ \frac{nf}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nf}{n} \cdot \cos(\theta) & \frac{nf}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) \\ \frac{ng}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{ng}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{ng}{n} \cdot \cos(\theta) \\ \frac{nh}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{nh}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nh}{n} \cdot \cos(\theta) \\ \frac{ni}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{ni}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{ni}{n} \cdot \cos(\theta) \end{pmatrix}$$

$$\mathbf{dL}_{\text{sr}} = \begin{pmatrix}
\frac{na}{n} \cdot -\text{sen}(\theta) & \frac{na}{n} \cdot -\text{sen}\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{na}{n} \cdot -\text{sen}\left(\theta + \frac{4 \cdot \pi}{3}\right) \\
\frac{nb}{n} \cdot -\text{sen}(\theta) & \frac{nb}{n} \cdot -\text{sen}\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{nb}{n} \cdot -\text{sen}\left(\theta + \frac{4 \cdot \pi}{3}\right) \\
\frac{nc}{n} \cdot -\text{sen}(\theta) & \frac{nc}{n} \cdot -\text{sen}\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{nc}{n} \cdot -\text{sen}\left(\theta + \frac{4 \cdot \pi}{3}\right) \\
\frac{nd}{n} \cdot -\text{sen}\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nd}{n} \cdot -\text{sen}(\theta) & \frac{nd}{n} \cdot -\text{sen}\left(\theta + \frac{2 \cdot \pi}{3}\right) \\
\frac{ne}{n} \cdot -\text{sen}\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{ne}{n} \cdot -\text{sen}(\theta) & \frac{ne}{n} \cdot -\text{sen}\left(\theta + \frac{2 \cdot \pi}{3}\right) \\
\frac{nf}{n} \cdot -\text{sen}\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nf}{n} \cdot -\text{sen}(\theta) & \frac{nf}{n} \cdot -\text{sen}\left(\theta + \frac{2 \cdot \pi}{3}\right) \\
\frac{ng}{n} \cdot -\text{sen}\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{ng}{n} \cdot -\text{sen}\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{ng}{n} \cdot -\text{sen}(\theta) \\
\frac{nh}{n} \cdot -\text{sen}\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{nh}{n} \cdot -\text{sen}\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nh}{n} \cdot -\text{sen}(\theta) \\
\frac{ni}{n} \cdot -\text{sen}\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{ni}{n} \cdot -\text{sen}\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{ni}{n} \cdot -\text{sen}(\theta)
\end{pmatrix}$$

### 5.3 Modelo Falta Espira-terra

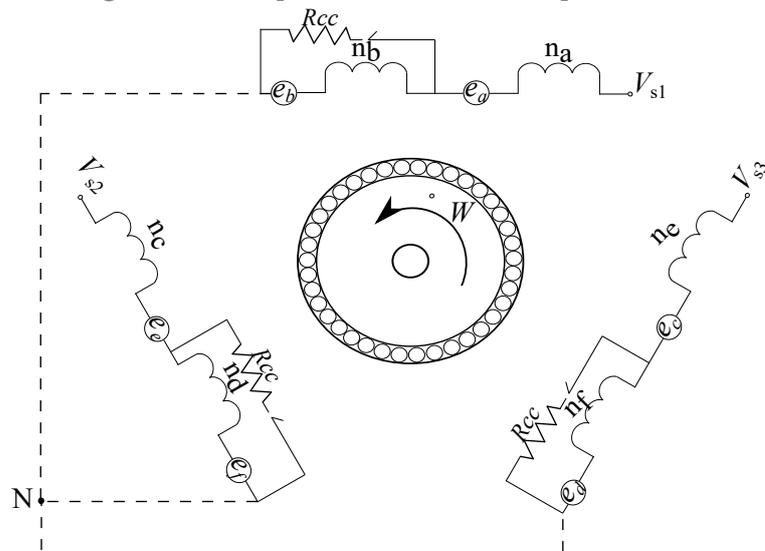
A falta espira-terra ocorre quando se verifica a falta entre um conjunto de espiras do estator e a carcaça onde as bobinas são fixadas. A Figura 20 apresenta novamente a ilustração das bobinas de uma máquina saudável e a Figura 21 representa o modelo de falta espira-terra generalizado.

Figura 20: Máquina saudável .



Fonte: Elaborado pelo autor.

Figura 21: Máquina com a Falta Espira-Terra.



Fonte: Elaborado pelo autor.

As matrizes que descrevem o comportamento da falta espira-terra são:

$$\mathbf{L}_{ss} = \begin{pmatrix} L_a & M_{ab} & M_{ac} & M_{ad} & M_{ae} & M_{af} \\ M_{ab} & L_b & M_{bc} & M_{bd} & M_{be} & M_{bf} \\ M_{ac} & M_{bc} & L_c & M_{cd} & M_{ce} & M_{cf} \\ M_{ad} & M_{bd} & M_{cd} & L_d & M_{de} & M_{df} \\ M_{ae} & M_{be} & M_{ce} & M_{ed} & L_e & M_{ef} \\ M_{af} & M_{bf} & M_{cf} & M_{df} & M_{ef} & L_f \end{pmatrix}$$

$$\mathbf{L}_{sr} = \begin{pmatrix} \frac{na}{n} \cdot \cos(\theta) & \frac{na}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{na}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) \\ \frac{nb}{n} \cdot \cos(\theta) & \frac{nb}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{nb}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) \\ \frac{nc}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nc}{n} \cdot \cos(\theta) & \frac{nc}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) \\ \frac{nd}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nd}{n} \cdot \cos(\theta) & \frac{nd}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) \\ \frac{ne}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{ne}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{ne}{n} \cdot \cos(\theta) \\ \frac{nf}{n} \cdot \cos\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{nf}{n} \cdot \cos\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nf}{n} \cdot \cos(\theta) \end{pmatrix}$$

$$\mathbf{dL}_{sr} = \begin{pmatrix} \frac{na}{n} \cdot -sen(\theta) & \frac{na}{n} \cdot -sen\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{na}{n} \cdot -sen\left(\theta + \frac{4 \cdot \pi}{3}\right) \\ \frac{nb}{n} \cdot -sen(\theta) & \frac{nb}{n} \cdot -sen\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{nb}{n} \cdot -sen\left(\theta + \frac{4 \cdot \pi}{3}\right) \\ \frac{nc}{n} \cdot -sen\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nc}{n} \cdot -sen(\theta) & \frac{nc}{n} \cdot -sen\left(\theta + \frac{2 \cdot \pi}{3}\right) \\ \frac{nd}{n} \cdot -sen\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nd}{n} \cdot -sen(\theta) & \frac{nd}{n} \cdot -sen\left(\theta + \frac{2 \cdot \pi}{3}\right) \\ \frac{ne}{n} \cdot -sen\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{ne}{n} \cdot -sen\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{ne}{n} \cdot -sen(\theta) \\ \frac{nf}{n} \cdot -sen\left(\theta + \frac{2 \cdot \pi}{3}\right) & \frac{nf}{n} \cdot -sen\left(\theta + \frac{4 \cdot \pi}{3}\right) & \frac{nf}{n} \cdot -sen(\theta) \end{pmatrix}$$

## 5.4 Modelo Mecânico

O modelo mecânico da turbina é constituído de duas partes principais. O primeiro, o modelo aerodinâmico, possui a curva  $C_p$  x  $\lambda$  e as perdas de sombreamento. Já o segundo, o modelo do eixo de transmissão de duas massas, conecta dois momentos de inércia diferentes, um para o eixo das pás e outro do gerador, pois os esforços aos quais o eixo está submetido influenciam na capacidade do sistema extrair potência.

### 5.4.1 Modelo Aerodinâmico

O torque mecânico do vento sobre a turbina,  $T_m$ , é dado por:

$$T_m = \frac{1}{2} \cdot \rho \cdot \pi \cdot R^3 \cdot \frac{C_p(\beta, \lambda)}{\lambda} \cdot V_w^2 \quad (5.19)$$

onde:

$$\lambda = \frac{W_t}{V_w} \cdot R. \quad (5.20)$$

Em que:

- $\rho$  - densidade do ar ( $\text{kg/m}^3$ );
- $R$  - comprimento da pá (m);
- $C_p$  - coeficiente de potência da turbina;
- $\lambda$  - razão de velocidade na ponta da pá;
- $\beta$  - ângulo de pitch ( $^\circ$ );
- $V_w$  - velocidade do vento (m/s);
- $W_t$  - velocidade da turbina (rad/s).

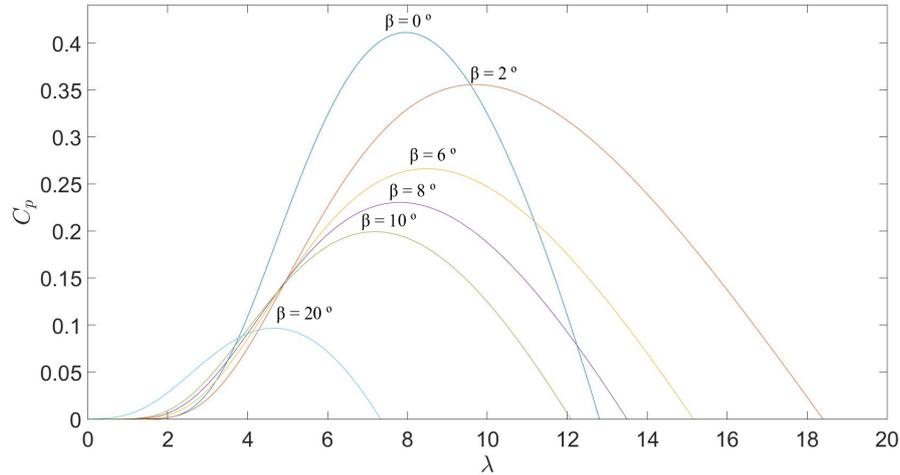
O coeficiente de potência,  $C_p$ , é um parâmetro relacionado ao percentual da potência do vento que será convertido em potência aerodinâmica de entrada. A Figura 22 apresenta a curva  $C_p$  em condições de  $\beta$  fixo. A equação que descreve  $C_p$  é:

$$C_p(\beta, \lambda) = 0,5 \cdot \left( \frac{116}{\lambda_i} - 0,4 \cdot \beta - 5 \right) \cdot e^{\frac{-21}{\lambda_i}} \quad (5.21)$$

Em que:

$$\frac{1}{\lambda_i} = \frac{1}{\lambda + 0,08 \cdot \beta} - \frac{0,035}{\beta^3 + 1} \quad (5.22)$$

Figura 22: Ilustração.



Fonte: Elaborado pelo autor.

O sombreamento é um efeito importante a ser considerado, visto que causa a degradação da qualidade de energia. Esse fenômeno ocorre cada vez que uma pá passa à frente da torre, causando redução do torque e conseqüentemente perda de potência. A modelagem desse fenômeno é dado pela seguinte equação:

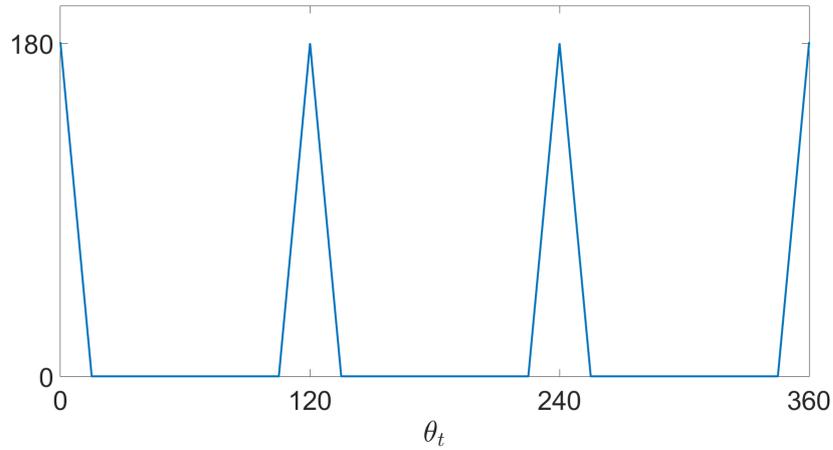
$$T_{ts} = K_{ts} \cdot \left( \frac{1}{2} \cdot \cos(FPOS(\theta_t)) - \frac{1}{2} \right) \cdot T_m \quad (5.23)$$

onde:

- $T_{ts}$  é o torque devido ao sombreamento da torre (N.M);
- $K_{ts}$  é o fator de perda devido ao sombreamento;
- $Fpos(\theta_t)$  é a função que apresenta os valores mostrados na Figura 23 conforme as pás da turbina rotacionam de acordo com o ângulo  $\theta_t$  do rotor.

O torque do sombreamento afeta o torque total,  $T_t$ , resultando em:

$$T_t = T_m - T_{ts}. \quad (5.24)$$

Figura 23: Função  $F_{pos}(\theta_t)$ .

Fonte: Elaborado pelo autor.

### 5.4.2 Modelo do eixo

Os momentos de inércia do gerador e da turbina, são respectivamente  $J_m$  e  $J_t$ . As equações dinâmicas que descrevem o comportamento do eixo da turbina são:

$$T_t - T_{toro} = J_t \cdot \frac{dw_t}{dt} + F_t \cdot w_t \quad (5.25)$$

$$T_{toro} - T_e = J_m \cdot \frac{dw_m}{dt} + F_m \cdot w_m \quad (5.26)$$

$$T_{toro} = K_{toro} \cdot \int (w_t - w_m) dt. \quad (5.27)$$

Em que:

- $T_{toro}$  - torque de torção (N.m);
- $K_{toro}$  - constante de torção do eixo;
- $F_t$  - coeficiente de atrito da turbina (N.m.s);
- $F_m$  - coeficiente de atrito da máquina (N.m.s);
- $T_e$  - torque eletromagnético da máquina (N.m);
- $w_m$  - velocidade de rotação da máquina (rad/s).

## 5.5 Modelo do controle

O controle do gerador é formado por dois subsistemas: o controle do lado do gerador e o controle do lado da rede, controlando dois conversores respectivamente  $C_1$  e  $C_2$ .

### 5.5.1 Controle do lado do gerador

No controle do lado do gerador é implementado o MPPT. Para isso é necessário controlar a velocidade da turbina,  $w_t$ , em resposta a flutuações na velocidade do vento, para manter  $\lambda$  no valor ótimo (BARROS et al., 2015) e assim captar o máximo de potência possível para uma dada velocidade do vento. Esse controle é feito a partir do controle do torque eletromecânico do gerador, pois existe um acoplamento mecânico entre o rotor da turbina e o do gerador.

Na simulação o modelo da máquina está em um referencial ABC, mas essa representação apresenta redundância de informações que dificultam o projeto de controle com bom desempenho dinâmico. Um modelo mais simples é obtido pela transformada de Park, gerando um novo sistema de três eixos desacoplados 0, d e q onde os vetores resultantes estão em um referencial genérico, g, como apresentado nas seguintes equações:

$$v_s^g = r_s \cdot i_s^g + \frac{d\lambda_s^g}{dt} + jw_g \cdot \phi_s^g \quad (5.28)$$

$$0 = r_r \cdot i_r^g + \frac{d\lambda_{sr}^g}{dt} + j(w_g - w_r) \cdot \phi_r^g \quad (5.29)$$

$$\lambda_{ss}^g = l_s \cdot i_r^g + l_m \cdot i_r^g \quad (5.30)$$

$$\lambda_{sr}^g = l_r \cdot i_r^g + l_m \cdot i_s^g \quad (5.31)$$

$$T_e = P \cdot i_s \cdot \phi_s \cdot \sin(\delta_i - \delta_a) \quad (5.32)$$

A estratégia utilizada é a de controle de fluxo e conjugado por escorregamento com fluxo estatórico (JACOBINA; LIMA, 1996). As equações de (5.28) até (5.32) foram manipuladas para se obter as equações (5.33) a (5.34), no referencial adequado. O vetor de fluxo estatórico é dado por:

$$\lambda_s^* = \lambda_s^* \cdot e^{j \cdot \delta_a^*} \quad (5.33)$$

$$\delta_a^* = \int_t^0 w_{ar}^*(\tau) d\tau + \int_t^0 w_r^*(\tau) d\tau \quad (5.34)$$

Manipulando as equações (5.28) , (5.31) e (5.32), temos:

$$v_s = \frac{r_s}{\sigma \cdot l_s} \cdot \phi_s^g + \frac{d\phi_s^g}{dt} + jw_g \cdot \phi_s^g - \frac{l_m \cdot r_s}{\sigma \cdot l_s \cdot l_r} \cdot \phi_r^g \quad (5.35)$$

A estratégia de controle por fluxo estatórico pode ser implementado em um referencial arbitrário, no entanto, para evitar o acoplamento entre as componentes d e q foi adotado o referencial estatórico, e assim temos:

$$v_{sd}^s = \frac{r_s}{\sigma \cdot l_s} \cdot \lambda_{sd}^s + \frac{d\lambda_{sd}^s}{dt} - \frac{l_m \cdot r_s}{\sigma \cdot l_s \cdot l_r} \cdot \lambda_{rd}^s \quad (5.36)$$

$$v_{sq}^s = \frac{r_s}{\sigma \cdot l_s} \cdot \lambda_{sq}^s + \frac{d\lambda_{sq}^s}{dt} - \frac{l_m \cdot r_s}{\sigma \cdot l_s \cdot l_r} \cdot \lambda_{rq}^s \quad (5.37)$$

O conjugado eletromagnético para condições de pequeno escorregamento é dado por:

$$T_e = \frac{P \cdot l_m^2 \cdot w_{ar} \cdot \lambda_s^2}{r_r \cdot l_s^2}. \quad (5.38)$$

Onde:

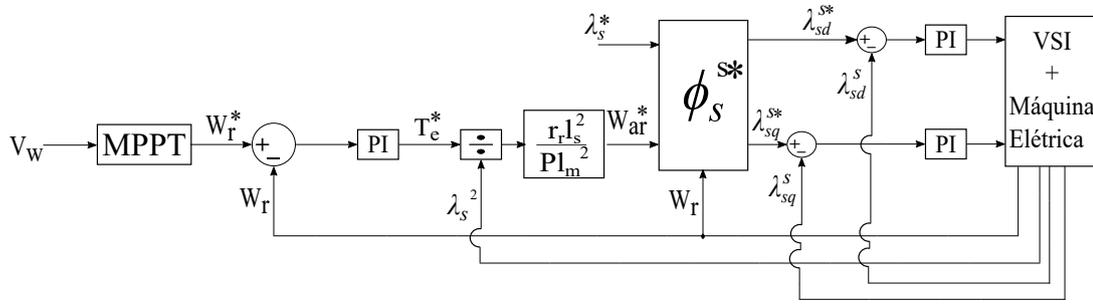
- $v_s$  é vetor tensão do estator;
- $i_s$  e  $i_r$  são os vetores da corrente estatórica e corrente rotórica, respectivamente;
- $\lambda_s$  e  $\lambda_r$  são os vetores fluxo estatórico e rotórico, respectivamente;
- $r_r$  e  $r_s$  são as resistências do rotor e do estator, respectivamente;
- $w_g$  é velocidade angular em um referencial genérico;
- $l_s = L_s - M_s$  é a indutância cíclica estatórica;
- $l_r = L_r - M_r$  é a indutância cíclica rotórica;
- $l_m = \frac{3}{2} \cdot M_{sr}$  é a indutância cíclica mútua;
- $w_{ar} = w_a - w_r$  é o vetor frequência de escorregamento estatórico;
- $\delta_a$  é a posição angular do vetor fluxo estatórico;

- $\sigma = 1 - \frac{l_m^2}{l_s \cdot l_r}$  é o coeficiente de dispersão.

De acordo com (5.38) o controle do torque da máquina pode ser efetuado por  $w_{ar}$  se  $\lambda_s$  for mantido constante. O controle do fluxo por sua vez é realizado pelas componentes d e q, equações (5.37) e (5.36). Os termos  $\frac{l_m \cdot r_s}{\sigma \cdot l_s \cdot l_r} \cdot \phi_{rd}^s$  e  $\frac{l_m \cdot r_s}{\sigma \cdot l_s \cdot l_r} \cdot \phi_{rq}^s$  podem ser vistos como perturbações a ser compensadas.

O controle gera os sinais das tensões de referência os quais são aplicados ao estator da máquina pelo conversor  $C_1$ . A Figura 24 apresenta o diagrama de blocos do sistema de controle.

Figura 24: Diagramado do Controle do Lado do Gerador.



Fonte: Elaborado pelo autor.

## 5.5.2 Controle do Lado da Rede

O controle do lado da rede tem o objetivo de entregar à rede a potência demandada pelo operador nacional do sistema (ONS), assim, existe a necessidade de controlar o saldo de potência no elo CC. A conexão à rede é feita utilizando um filtro RL trifásico. O modelo do filtro em 0, d e q no referencial de tensão da rede,  $\theta_g$ , é dado por:

$$V_{fd} = r_f \cdot i_{fd} + l_f \cdot \frac{di_{fd}}{dt} - w_g \cdot l_f \cdot i_{fq} + v_g \quad (5.39)$$

$$V_{fq} = r_f \cdot i_{fq} + l_f \cdot \frac{di_{fq}}{dt} - w_g \cdot l_f \cdot i_{fd}. \quad (5.40)$$

Em que:

- $r_f$  e  $l_f$  é a resistência e indutância do filtro, respectivamente;
- $v_{fd}$  e  $v_{fq}$  são as tensões em dq na saída de  $C_2$ ;

- $i_{fd}$  e  $i_{fq}$  são as correntes em dq do filtro;
- $w_g$  é a frequência da rede;
- $v_g$  é o módulo do vetor tensão da rede.

No referencial tensão da rede a potência ativa,  $P_g$ , e reativa,  $Q_g$ , entregue no ponto de conexão, são dadas por:

$$P_g = v_{gd} \cdot i_{fd} \quad (5.41)$$

$$Q_g = -v_{gd} \cdot i_{fd}. \quad (5.42)$$

Onde  $v_{gd}$  e  $v_{gq}$  são os vetores de tensão d e q, respectivamente, no ponto de acoplamento. A tensão no elo CC,  $V_{cc}$ , pode ser descrita por:

$$C \cdot \frac{dv_{cc}}{dt} = \frac{P_s - P_f}{v_{cc}}. \quad (5.43)$$

Em que:

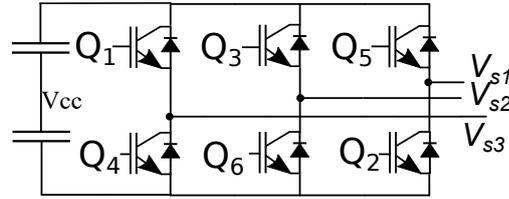
- $C$  é a capacitância do capacitor do elo CC (F);
- $P_s$  é a potência oriunda de  $C_1$  (W);
- $P_f$  é a potência na saída de  $C_2$  (W).

É importante observar que a primeira parte do controle do lado da rede utiliza o PLL (do inglês, *phase locked loop*) apresentado em Kaura e Blasko (1997). Esse sistema de controle gera a partir de um sinal de entrada um sinal de saída com frequência e fase sincronizado com o sinal de entrada. Tal sistema pode ser utilizado para rastrear uma frequência do sinal de entrada e assim gerar frequências múltiplas da entrada sendo uma parte importante do sistema de controle do lado da rede.

O controle da potência entregue à rede é apresentada em Barros e Barros (2017). A entrega de potência ativa é realizada por duas malhas, uma externa e outra interna, a primeira é responsável por manter a tensão no capacitor, enquanto a malha mais interna controla a corrente de eixo direto para injetar a potência ativa na rede. Já o controle de potência reativa possui apenas uma malha e é obtido controlando a corrente de eixo em quadratura. As malhas de controle são apresentadas na Figura 25.



Figura 26: Inversor

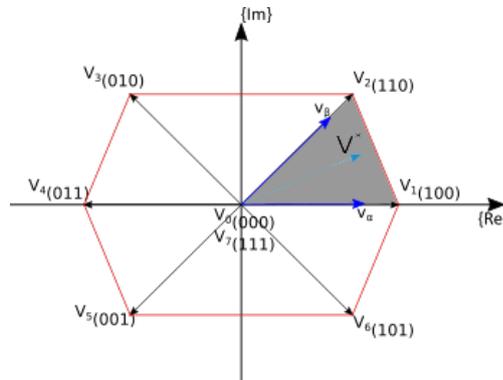


Fonte: Elaborado pelo autor.

Com os resultados da Tabela 3 é possível observar cada um desses estados como vetor e depois colocar os vetores no plano complexo, assim, temos o resultado da Figura 27. Tendo esses vetores é possível sintetizar o vetor de referência,  $V^*$ , que vem dos controladores, essa referência é definida como um vetor de sequência positiva de uma forma de onda trifásica.

$$V^* = \frac{2}{3}(v_a^* + av_b^* + a^2v_c^*), \text{ onde, } a = e^{j\frac{2\pi}{3}} \quad (5.44)$$

Figura 27: Mapa de Estados no Plano Complexo.



Fonte: Elaborado pelo autor.

Para sintetizar o vetor de referência é possível separar o plano complexo em setores, como a área cinza na Figura 27, e depois decompor o vetor de referência em função dos estados, como resultado da decomposição temos os vetores  $V_\beta$  e  $V_\alpha$  que são descritos matematicamente pelas equações 5.45 e 5.46.

$$V_\alpha = \frac{2}{\sqrt{3}}V^* \text{sen}\left(\frac{\pi}{3} - \phi\right) \quad (5.45)$$

$$V_\beta = \frac{2}{3}V^* \text{sen}(\phi) \quad (5.46)$$

Considerando um tempo  $T_c$  no qual a tensão média de saída deve se igualar a  $V^*$

obtém-se os tempos de aplicação dos vetores adjacentes e dos vetores de tensão nula:

$$t_a = \frac{V_a}{V_1} \cdot T_c \quad (5.47)$$

$$t_b = \frac{V_b}{V_2} \cdot T_c \quad (5.48)$$

$$t_0 = T_c - (t_a + t_b) \quad (5.49)$$

#### 5.5.4 Filtro do PWM

O Espectro harmônico apresenta em baixa frequência a componente da onda modulante, ou seja, a fundamental e em alta frequência o ruído provocado pela forma de onda quadrada do PWM, mas com um filtro passa baixa é possível atenuar o conteúdo de alta frequência, contudo, para caso particular de acionamento de máquinas elétricas é importante lembrar que o estator da máquina é um conjunto de indutores com uma impedância que cresce com as altas frequências, ou seja, o estator da máquina funciona como o filtro.

#### 5.5.5 Conclusão

Esse capítulo é dedicado a apresentar os modelos matemáticos empregados na simulação das faltas que foram posteriormente utilizados como os dados para treinamento e validação das redes.

## 6 Resultados

Esse capítulo trata do processo de aquisição dos dados, pré-processamento, treinamento e avaliação dos resultados.

### 6.1 Aquisição dos dados

Os avanços das linguagens de computação e do poder de processamento dos computadores permitem simulações mais realistas que ajudam a entender o comportamento dos sistemas físicos. O uso de dados sintéticos abre a possibilidade de simular diferentes condições de falta em distintos pontos de operação da máquina em grande variedade de situações. Esse aspecto é de grande importância para etapa de treinamento em sistemas inteligentes, pois é necessário ter dados representando diferentes situações. Ensaiar em um laboratório todas essas situações podem envolver muitos custos já que é necessário estabelecer curtos internos em uma máquina real que vai causar algumas avarias a máquina ao final dos ensaios, mas utilizando uma simulação adequada é necessário apenas mudar os parâmetros e temos uma máquina nova. Portanto, os dados sintéticos também podem ser utilizados para complementar uma base que já possui dados reais, mas em uma quantidade restrita de situações.

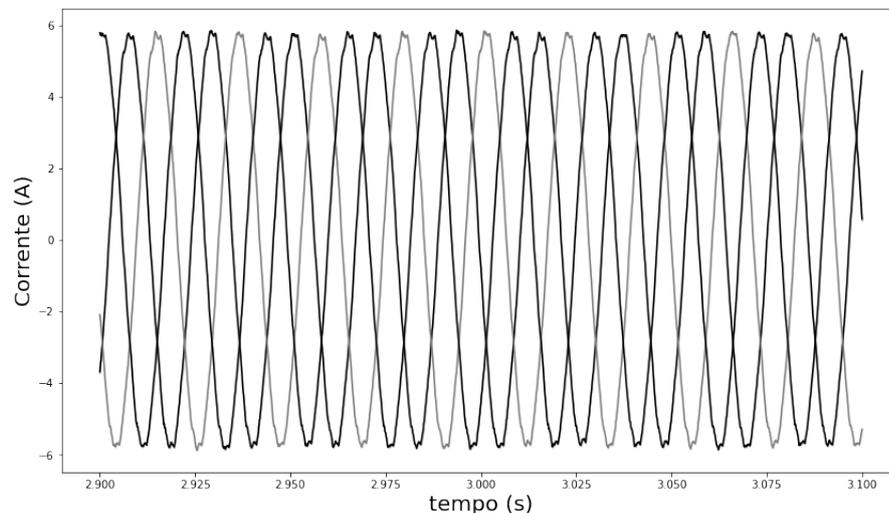
Neste trabalho os dados utilizados para treinar as redes são obtidos através de simulações no Matlab/Simulink. Os sinais utilizados para o treinamento são as correntes do estator as quais já são habitualmente mensurados em aplicações reais não necessitando de novos sensores para obtê-los, essa abordagem também não necessita de medições invasivas e possibilita o monitoramento remoto. A simulação é composta pelo SCIG, que pode apresentar faltas com duas origens, a falta espira-espira a qual ocorre quando as espiras de uma mesma bobina esta em curto e a falta espira-terra a qual ocorre entre as espiras e a carcaça do gerador.

Para gerar as instâncias foram utilizados dois métodos. O primeiro foi mudar os parâmetros da simulação, um dos parâmetros modificados foi a resistência associada à falta

( $R_{cc}$ ), quando  $R_{cc}$  é infinito significa que o curto não foi estabelecido, ou seja, máquina é saudável e  $R_{cc}$  igual a zero indica que a isolação foi completamente degradada, nos casos de falha o  $R_{cc}$  variou de  $0,1 \Omega$  até  $1,5 \Omega$ . Também foi modificado o nível de dano na bobina, em casos de falha o intervalo de percentagem da bobina em curto variou entre 1% e 10%. A velocidade do vento também variou, ficou entre 70% até 100% da plena carga. A frequência dos conversores variou em uma faixa de 1kHz até 10kHz. Por último, foram utilizados dois conjuntos de parâmetros para caracterizar o gerador elétrico, tendo as resistências e indutância diferentes.

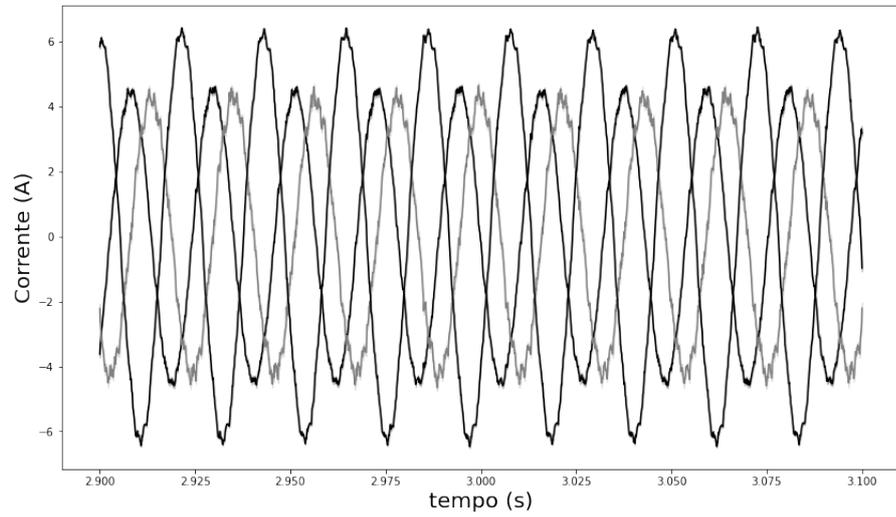
O segundo método utilizado para gerar as instâncias foi variar o instante onde a falta ocorre, assim, é possível detectar faltas já na janela de tempo em que elas são verificadas. A Figura 28 apresenta o sinal de um gerador saudável. A Figura 29 apresenta uma instância onde a falta ocorreu no início da janela de tempo. Já na Figura 30 a falta inicia em um quarto do tempo total da amostra. Na Figura 31 a falta ocorre na metade do intervalo de tempo. Por último, Figura 32 a falta inicia em três quartos da janela de tempo. O intervalo de tempo total de cada amostra é de 0,2 segundos.

Figura 28: Instância Sem Falta.



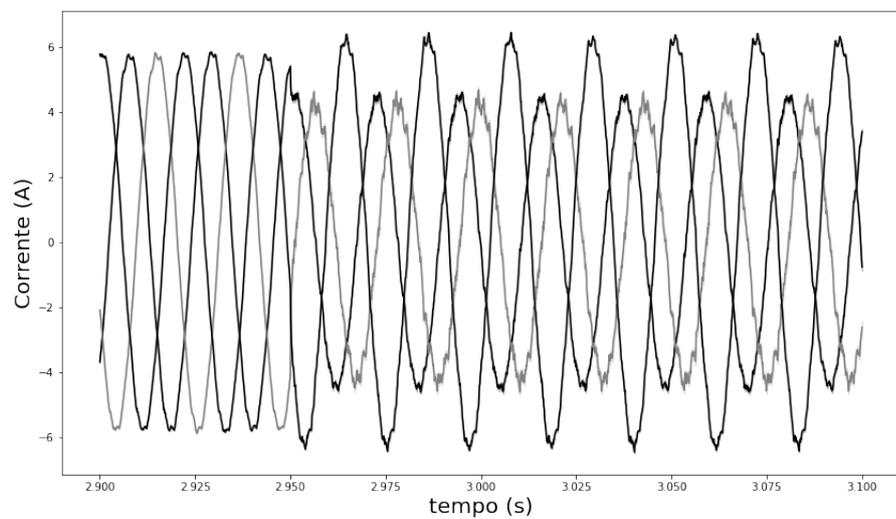
Fonte: Elaborado pelo autor.

Figura 29: Instância Totalmente em Falta.



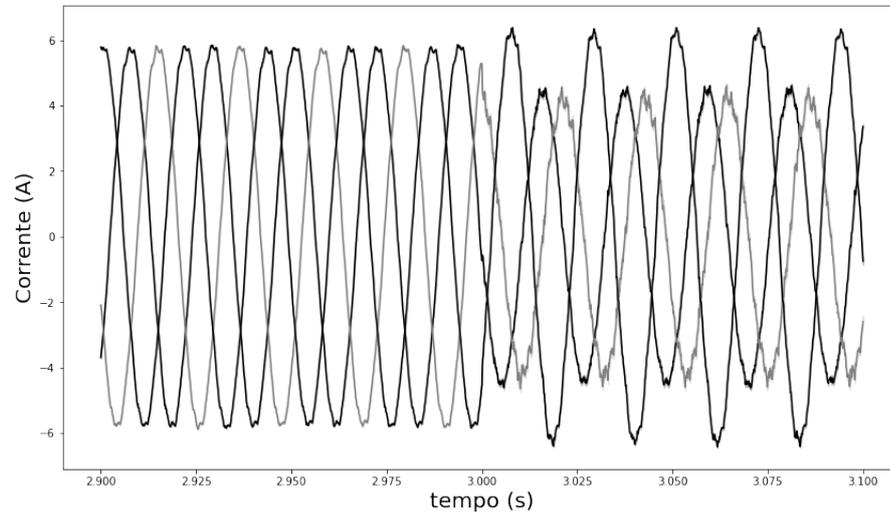
Fonte: Elaborado pelo autor.

Figura 30: Instância Com Falta Em Um Quartos da Janela de Tempo.



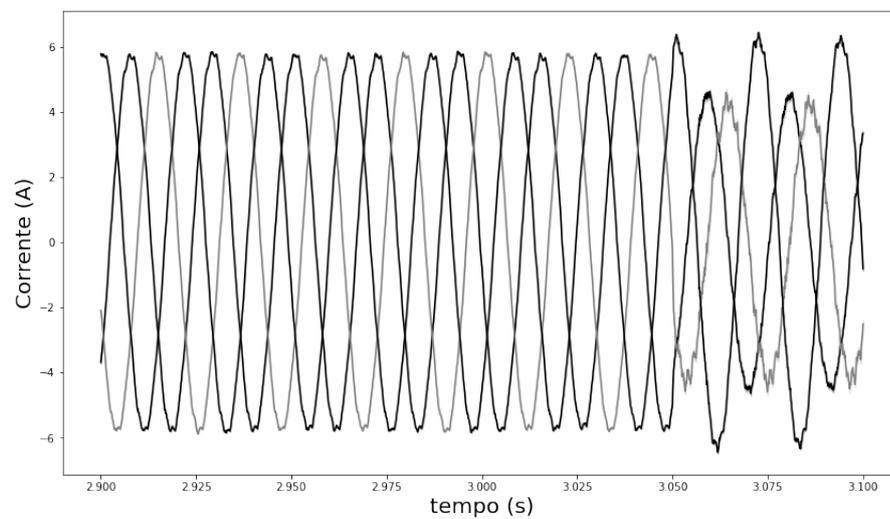
Fonte: Elaborado pelo autor.

Figura 31: Instância Com Falta Na Metade da Janela de Tempo.



Fonte: Elaborado pelo autor.

Figura 32: Instância Com Falta Em Três Quartos da Janela de Tempo.



Fonte: Elaborado pelo autor.

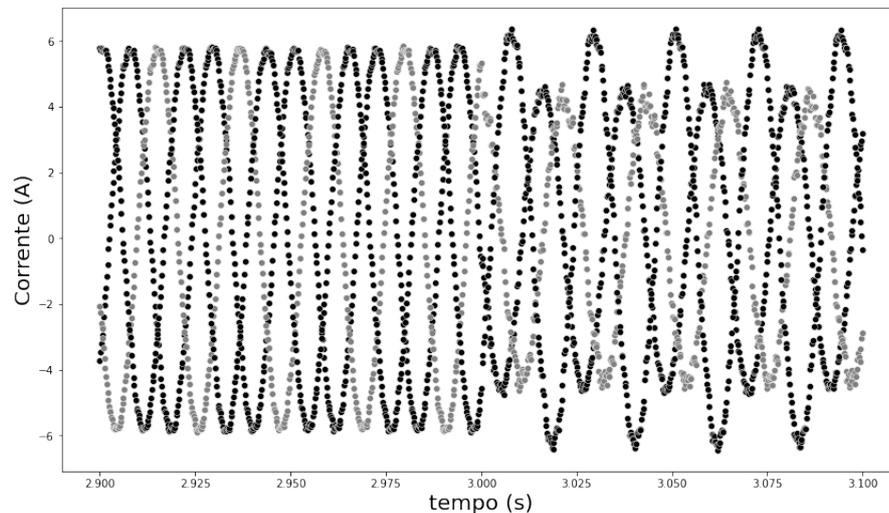
O projeto do sistema de detecção é voltando para manutenção dos geradores, assim, o classificador deve identificar se existe a falha, ou seja, esse classificador não distingue se a falta é espira-espira ou espira-terra, apenas se a instância é de uma máquina saudável ou não.

## 6.2 Multi-layer Perceptron

### 6.2.1 Pré-processamento

Na primeira etapa do pré-processamento os dados passaram por um processo de amostragem o qual visa aproximar os dados da simulação de dados reais que também passam por processos de amostragem para serem armazenados e utilizados em sistemas digitais. O processo de amostragem também é importante para diminuir redundâncias e auxiliar no armazenamento dos dados. A Figura 33 apresenta o sinal da Figura 31 depois do processo de amostragem.

Figura 33: Processo de Amostragem.

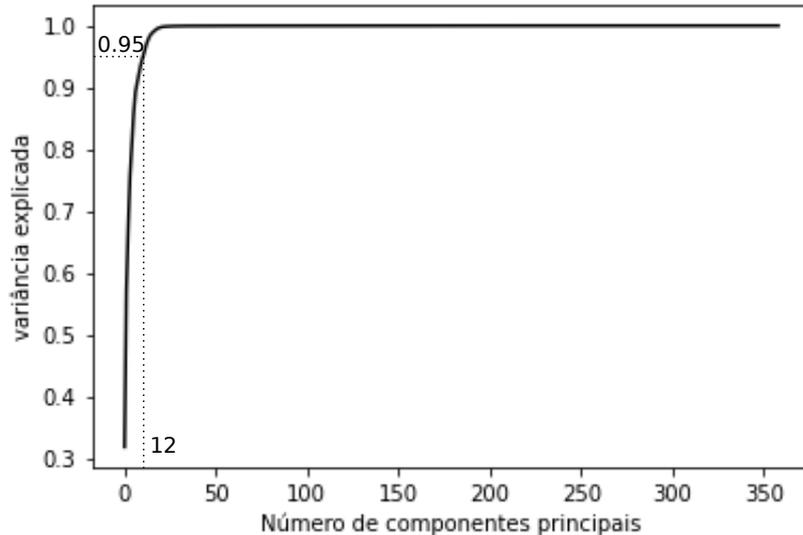


Fonte: Elaborado pelo autor.

Já na segunda etapa do pré-processamento foi utilizada a análise de componentes principais (PCA, do inglês *Principal Component Analysis*) que busca projetar os dados em um espaço de dimensionalidade menor. Ao reduzir a dimensionalidade dos dados é possível evitar problemas relacionados a maldição da dimensionalidade o que auxilia no desenvolvimento de um classificador mais simples e acelerando o processo de treinamento. Como boa prática é aconselhado selecionar uma dimensão que apresente por volta de 95% de variância (GÉRON, 2019). A Figura 34 demonstra que as doze primeiras componentes

principais das amostras guardam 95% da informação da variância dos dados.

Figura 34: Componentes Principais.



Fonte: Elaborado pelo autor.

### 6.3 Projeto MLP

Um ponto desfavorável no projeto da MLP é a escolha dos hiperparâmetros, visto que existe um espaço de busca muito grande para os hiperparâmetros e a escolha desses influenciam de modo diferente no resultado da rede. Na busca de contornar esse obstáculo esse trabalho utilizou a função GridSearchCV do Scikit-Learn, a qual a partir de uma lista pré-definida pelo usuário faz uma busca exaustiva dos melhores hiperparâmetros para a rede. Depois desse estágio houve pequenos ajustes manuais.

Hiperparâmetros utilizados:

- Número de camadas: Foi utilizada uma camada oculta contendo 8 neurônios.
- Função de ativação: A função de ativação utilizada foi a Elu (CLEVERT; UNTERTHINER; HOCHREITER, 2015). Outras funções foram avaliadas como: tangente hiperbólica, unidade linear retificada (ReLU) e Sigmoid. A função Elu é uma função de ativação não saturada o que também evita problemas dos gradientes *vanishing/exploding*.
- Otimizador: O otimizador escolhido foi o Adam (KINGMA; BA, 2014), um método baseado no gradiente descendente estocástico.

- Taxa de aprendizado: A taxa de aprendizado limita a atualização dos pesos na rede, foi definida com um valor igual a 0.001.
- Épocas: Foi utilizado para o treinamento 350 épocas.

A camada de saída é construída por uma função *softmax*, a saída de cada neurônio dessa camada corresponde a probabilidade estimada de cada classe.

A base de dados utilizada é descrita na Figura 35.

Figura 35: Base de Dados.

Instâncias Sem Falta	Instâncias Com Falta	
	Falta Espira-Espira	Falta Espira-Terra
250	125	125

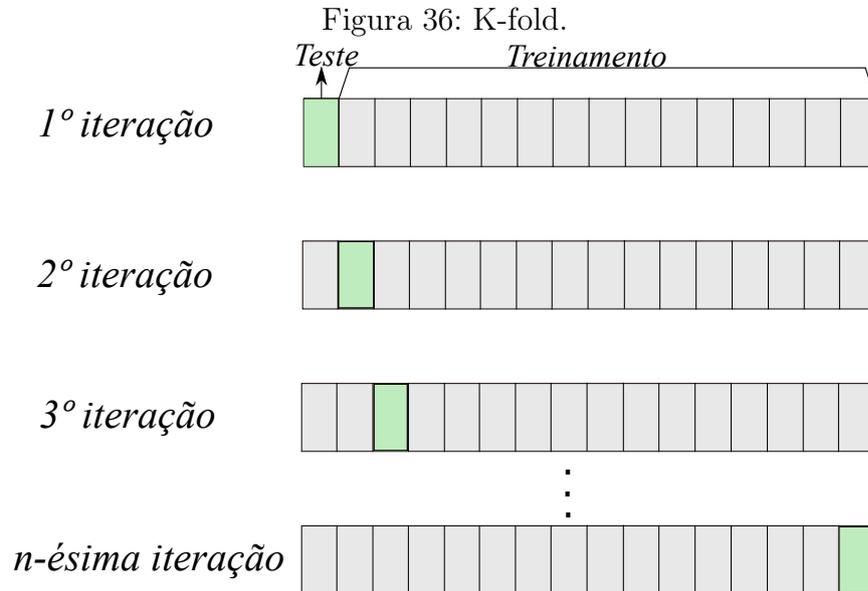
Fonte: Elaborado pelo autor.

### 6.3.1 Avaliação dos resultados MLP

Como descrito na Figura 35 a base tem um total de 500 instâncias, essas instâncias foram subdivididas em três casos. O primeiro caso apresenta todas as instâncias. O segundo caso apresenta apenas as instâncias saudáveis e as instâncias com a falta espira-espira. Por último, o terceiro caso apresenta as instâncias saudáveis e as instâncias com a falta espira-terra.

A técnica para avaliar o modelo foi a validação cruzada *k-fold*, um método bastante utilizado na área de aprendizado de máquina (GÉRON, 2019). Nessa estratégia o banco de dados é subdividido aleatoriamente em  $k$  partes de tamanhos iguais, quando possível, os subconjuntos de dados apresentam instâncias de cada classe na proporção do conjunto original. Durante o procedimento é selecionado um subconjunto  $k_i$  e o mesmo é retirado para a validação do modelo e os  $k-1$  outros subconjuntos são utilizados para o treinamento. O processo de selecionar  $k_i$  para etapa de validação e treinar os outros  $k-1$  subconjuntos é repetido  $k$  vezes até completar todos os dados e ao final de todas as etapas é calculada

a acurácia. Este método é bastante utilizado em estatística dado que garante que a organização dos dados não influencia nos resultados obtidos. A Figura 36 exemplifica o uso da técnica da validação cruzada.



Fonte: Elaborado pelo autor.

Nesse trabalho foi utilizado  $k = 25$  em todos os casos por ter melhores resultados, como a amostra é menor que 30 nesse trabalho foi utilizada a distribuição T de Student (MAGALHÃES; LIMA, 2002). Dos resultados obtidos pela validação cruzada foi calculada a média amostral, o desvio padrão amostral e o intervalo de confiança ao nível de confiança de 95% para a acurácia dos resultados.

### 6.3.2 Intervalo de Confiança

A primeira etapa para o cálculo do intervalo de confiança é calcular a média amostral das acurácias e isso pode ser feito com a equação (6.1).

$$\bar{x} = \frac{\sum f_i \cdot x_i}{n} \quad (6.1)$$

- $\bar{x}$  é a média amostral;
- $f_i$  é a frequência que o valor se repete;
- $x_i$  é a acurácias da i-esima amostra;
- $n$  é o número de amostras.

A segunda etapa é calcular a variância amostral utilizando a equação (6.2).

$$\sigma = \frac{\sum(x_i - \bar{x})^2}{n - 1} \quad (6.2)$$

A terceira etapa é calcular o desvio padrão pela equação (6.3).

$$s = \sqrt{\frac{\sum(x_i - \bar{x})^2}{n - 1}} = \sqrt{\sigma} \quad (6.3)$$

Conhecendo o nível de confiança, nesse caso de 95%, e os graus de liberdade é possível, com a tabela t-student, conhecer o valor crítico,  $tc$ , com esses valores é possível calcular o intervalo de confiança com a equação (6.4).

$$IC = \bar{x} \pm tc \cdot \frac{s}{\sqrt{n}} \quad (6.4)$$

### 6.3.3 Resultados RNA

Na Tabela 3 é possível observar os resultados da RNA e a melhor acurácia média foi no segundo caso e a pior a acurácia média ficou no terceiro caso, o desvio padrão mais elevado ocorreu no terceiro caso.

Tabela 4: Resultados RNA.

Base de dados	Média	Desvio Padrão	Intervalo de Confiança
Primeiro Caso	81,33%	3,69%	[82,85%; 79,80%]
Segundo Caso	83,47%	3,19%	[84,78%; 82,15%]
Terceiro Caso	77,18%	5,24%	[79,34%; 75,01%]

## 6.4 Rede Neural Convolutacional

A forma de aquisição e amostragem dos dados é a mesma da seção anterior, porém nessa seção não foi realizado o processo de redução de dimensionalidade com o PCA, pois como apresentado no capítulo 2 a RNC tem mais facilidade em tratar grandes volumes de dados e ainda utiliza o processo de *pooling* que faz uma subamostragem ao longo da rede selecionando as características mais importantes.

### 6.4.1 Projeto da Rede Neural Convolutacional

Os hiperparâmetros foram selecionados pelo GridSearchCV e depois refinados manualmente e os principais hiperparâmetros foram:

- 64 filtros na primeira cama e função de ativação Relu;
- Camada de *pooling*;
- 34 filtros na segunda camada e função de ativação Relu;
- Camada de *pooling*;
- Camada de normalização (GÉRON, 2019);
- Camada totalmente conectada com 8 neuronios e função de ativação Elu e inicializador He (GÉRON, 2019);
- Camada totalmente conectada com função *softmax*;
- Otimizador Adam;
- Foi utilizado 450 épocas para o treinamento.

### 6.4.2 Resultados

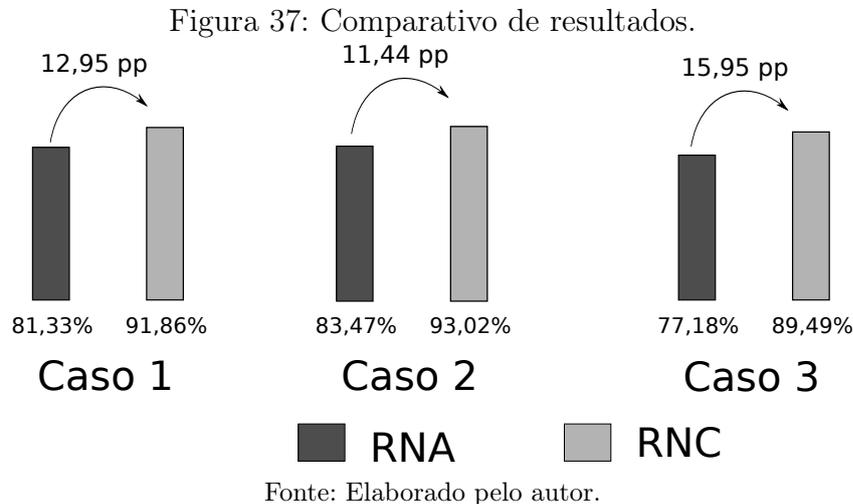
Como a seção anterior também foi utilizado o método *k-fold*, com as mesmas premissas, para avaliar a rede e os resultados são apresentados na Tabela 4. Nessa Tabela são apresentados a média das acurácias para cada caso, o desvio padrão em cada caso e, na última coluna, o intervalo de confiança.

Tabela 5: Resultados RNC.

Base de dados	Média	Desvio Padrão	Intervalo de Confiança
Primeiro Caso	91,86%	5,07%	[93,95%; 89,76%]
Segundo Caso	93,02%	4,66%	[94,94%; 91,09%]
Terceiro Caso	89,49%	7,58%	[92,61%; 86,36%]

Os resultados da Tabela 4 mostram que o segundo caso teve o melhor desempenho e o terceiro caso foi o pior, assim como ocorreu com a RNA. Com os resultados das duas redes podemos avaliar qual teve o melhor desempenho entre a RNA e a RNC. Na Figura 37 são apresentados os resultados das acurácias médias de cada rede para cada caso e

é possível perceber que a RNC teve uma acurácia média melhor em todos os três casos analisados.



## 6.5 Conclusão

Nesse capítulo foram apresentados os resultados das duas redes e é possível perceber que a RNC teve uma melhor acurácia no primeiro caso apresentou uma média de acurácia 12,95 pontos percentuais maior, no segundo caso foi 11,44 pontos percentuais maior e no terceiro caso 15,95 pontos percentuais maior.

As RNAs apresentaram menor desempenho, pois em casos como o deste trabalho essas redes costumam ter mais dificuldade em aprender recursos descritivos de forma eficaz devido às entradas de alta dimensionalidade (CHEN et al., 2020). O PCA diminui a dimensionalidade das instâncias, porém isso tem como consequência algum nível de perda de informação. Contudo, as RNAs possuem alguns pontos importantes, porque uma rápida implementação consegue um desempenho razoável mesmo com uma rede pequena.

Já a RNC apresenta bom desempenho em aplicações com dados de alta dimensionalidade (GÉRON, 2019). Essas redes podem ajudar no desenvolvimento de sistemas de detecção e classificação automática de faltas em máquinas elétricas, pois os dados são, geralmente, séries temporais ou sinais como imagens que são amplamente utilizados em conjunto com as RNCs.

A comparação direta desse trabalho com estudos anteriores fica prejudicada pela natureza dos dados, esse estudo utiliza dados artificiais e os anteriores utilizam apenas dados reais o que pode causar distorções na avaliação. No entanto, é válido notar que a utilização

de simulações pode ajudar que bases de dados que hoje só possuem dados reais possam ser acrescidas de instâncias artificiais para aumentar a quantidade e a variedade de situações.

## 7 Considerações finais

Esse capítulo apresenta as principais contribuições do trabalho e as perspectivas futuras.

### 7.1 Principais contribuições

Na primeira etapa desse trabalho é discutido o desenvolvimento de modelos matemáticos para simulação de faltas, pois as estratégias de aprendizado de máquina necessitam de um grande volume de dados para treinamento e é importante que esses dados também sejam representativos dos diferentes pontos de operação das máquinas. Em laboratório é possível obter os dados das faltas, porém ter um grande volume de dados com grande diversidade é uma tarefa árdua, pois é importante ter máquinas com diferentes potências, parâmetros e avaliar vários pontos de operação. O aumento do poder computacional auxilia a obtenção de simulações mais realistas e facilita a etapa de construção de banco de dados maiores e com grande variedade. É possível ter bancos de dados só com simulações, como nesse trabalho, ou usar as simulações para enriquecer bancos de dados que só possuem instâncias reais.

A segunda etapa apresenta a implementação e avaliação das redes neurais artificiais e das redes neurais convolucionais como método de detecção de faltas. De modo geral os resultados são promissores na busca de um classificador eficaz para as faltas no estator. Os resultados demonstraram que a RNC é superior a RNA para os casos avaliados.

Em relação aos outros trabalhos já presentes na literatura, esse estudo temos uma nova metodologia que buscar utilizar a simulação de modelos matemáticos para obter as instâncias facilitando a construção das bases de dados ou ampliando bases de dados que possuam dados reais.

## 7.2 Trabalhos Futuros

Trabalhos futuros podem evoluir em algumas linhas como: a classificação da gravidade da falta, a comparação com outros modelos de aprendizado de máquina, a inclusão de dados reais na base de dados e a adição de instâncias que possuem perturbações.

## 7.3 Resultado da pesquisa

Como resultado dessa pesquisa houve a publicação de um artigo no simpósio brasileiro de automação inteligente em 2021.

# Referências

- ALBIZU, I. et al. On-line stator winding fault diagnosis in induction generators for renewable generation. In: IEEE. *Proceedings of the 12th IEEE Mediterranean Electrotechnical Conference (IEEE Cat. No. 04CH37521)*. [S.l.], 2004. v. 3, p. 1017–1020.
- ALI, M. Z. et al. Machine learning-based fault diagnosis for single-and multi-faults in induction motors using measured stator currents and vibration signals. *IEEE Transactions on Industry Applications*, IEEE, v. 55, n. 3, p. 2378–2391, 2019.
- ALTUG, S.; CHEN, M.-Y.; TRUSSELL, H. J. Fuzzy inference systems implemented on neural architectures for motor fault detection and diagnosis. *IEEE transactions on industrial electronics*, IEEE, v. 46, n. 6, p. 1069–1079, 1999.
- BALLAL, M. S. et al. Adaptive neural fuzzy inference system for the detection of inter-turn insulation and bearing wear faults in induction motor. *IEEE Transactions on Industrial Electronics*, IEEE, v. 54, n. 1, p. 250–258, 2007.
- BARBI, I. *Teoria fundamental do motor de indução*. [S.l.]: Editora da UFSC Florianópolis, 1985.
- BARBIERI, J. C. *Organizações inovadoras sustentáveis: uma reflexão sobre o futuro das organizações*. [S.l.]: Atlas, 2007.
- BARROS, C. M. V. et al. Mppt de sistemas de conversão de energia eólica baseados em pmc usando controle preditivo. *Eletrônica de Potência*, v. 20, n. 4, p. 364–372, 2015.
- BARROS, L. S.; BARROS, C. M. V. Modificação no controle do lado da rede de geradores eólicos baseados em pmc para ampliar a suportabilidade a afundamentos de tensão. *Eletrônica de Potência*, v. 22, n. 2, p. 167–178, 2017.
- BONNETT, A. H.; SOUKUP, G. C. Cause and analysis of stator and rotor failures in three-phase squirrel-cage induction motors. *IEEE Transactions on Industry applications*, IEEE, v. 28, n. 4, p. 921–937, 1992.
- CARVALHO, A. et al. *Inteligência artificial—uma abordagem de aprendizado de máquina*. Rio de Janeiro: LTC, 2011.
- CHEN, Z. et al. A deep learning method for bearing fault diagnosis based on cyclic spectral coherence and convolutional neural networks. *Mechanical Systems and Signal Processing*, Elsevier, v. 140, p. 106683, 2020.
- CHOW, M.-y.; YEE, S. O. Methodology for on-line incipient fault detection in single-phase squirrel-cage induction motors using artificial neural networks. *IEEE Transactions on Energy Conversion*, IEEE, v. 6, n. 3, p. 536–545, 1991.

- CLEVERT, D.-A.; UNTERTHINER, T.; HOCHREITER, S. Fast and accurate deep network learning by exponential linear units (elus). *arXiv preprint arXiv:1511.07289*, 2015.
- DEMIAN, C.; CIRRINCIONE, G.; CAPOLINO, G. A. A neural approach for the fault diagnostics in induction machines. In: IEEE. *IEEE 2002 28th Annual Conference of the Industrial Electronics Society. IECON 02*. [S.l.], 2002. v. 4, p. 3372–3376.
- ENEEL. *Brasil alcança 170 mil megawatts de capacidade instalada em 2019*. jan. 2020. Jan., 2020. Disponível em: <<http://bit.ly/35IP2Vo>>. Acesso em Dezembro 9, 2020.
- FERNANDES, D. A.; COSTA, F. F.; SANTOS, E. C. dos. Digital-scalar pwm approaches applied to four-leg voltage-source inverters. *IEEE Transactions on Industrial Electronics*, IEEE, v. 60, n. 5, p. 2022–2030, 2012.
- FITZGERALD, A. *Máquinas Elétricas de Fitzgerald e Kingsley-7*. [S.l.]: AMGH Editora, 2014.
- FUKUSHIMA, K.; MIYAKE, S. Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. In: *Competition and cooperation in neural nets*. [S.l.]: Springer, 1982. p. 267–285.
- GÉRON, A. *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*. Alta Books, 2019. ISBN 9788550809021. Disponível em: <<https://books.google.com.br/books?id=Z0mvDwAAQBAJ>>.
- GHATE, V. N.; DUDUL, S. V. Optimal mlp neural network classifier for fault detection of three phase induction motor. *Expert Systems with Applications*, Elsevier, v. 37, n. 4, p. 3468–3481, 2010.
- GOODE, P. V.; CHOW, M.-y. Using a neural/fuzzy system to extract heuristic knowledge of incipient faults in induction motors. part i-methodology. *IEEE transactions on industrial Electronics*, IEEE, v. 42, n. 2, p. 131–138, 1995.
- GOODE, P. V.; CHOW, M.-y. Using a neural/fuzzy system to extract heuristic knowledge of incipient faults in induction motors: Part ii-application. *IEEE Transactions on Industrial Electronics*, IEEE, v. 42, n. 2, p. 139–146, 1995.
- GRADIN, L. P.; BURSTEIN, N. Assessment of containment fan cooler degradation by motor current signature analysis. In: IEEE. *1993 IEEE Conference Record Nuclear Science Symposium and Medical Imaging Conference*. [S.l.], 1993. p. 990–994.
- HUBEL, D. H. Single unit activity in striate cortex of unrestrained cats. *The Journal of physiology*, Wiley Online Library, v. 147, n. 2, p. 226–238, 1959.
- HUBEL, D. H.; WIESEL, T. N. Receptive fields of single neurones in the cat's striate cortex. *The Journal of physiology*, Wiley Online Library, v. 148, n. 3, p. 574–591, 1959.
- HUBEL, D. H.; WIESEL, T. N. Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, Wiley Online Library, v. 195, n. 1, p. 215–243, 1968.

- JACOBINA, C. B.; LIMA, A. M. Estratégias de controle para sistemas de acionamento com máquina assíncrona. *Controle & Automação*, v. 7, n. 1, p. 15–28, 1996.
- JOKSIMOVIC, G. M.; PENMAN, J. The detection of inter-turn short circuits in the stator windings of operating motors. *IEEE Transactions on Industrial electronics*, IEEE, v. 47, n. 5, p. 1078–1084, 2000.
- KAUFHOLD, M. et al. Interface phenomena in stator winding insulation-challenges in design, diagnosis, and service experience. *IEEE Electrical insulation magazine*, IEEE, v. 18, n. 2, p. 27–36, 2002.
- KAURA, V.; BLASKO, V. Operation of a phase locked loop system under distorted utility conditions. *IEEE Transactions on Industry applications*, IEEE, v. 33, n. 1, p. 58–63, 1997.
- KIA, M. Y. et al. Hybrid modelling of doubly fed induction generators with inter-turn stator fault and its detection method using wavelet analysis. *IET Generation, Transmission & Distribution*, IET, v. 7, n. 9, p. 982–990, 2013.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- LAPRIE, J.-C. Dependable computing and fault-tolerance. *Digest of Papers FTCS-15*, v. 10, n. 2, p. 124, 1985.
- MAGALHÃES, M. N.; LIMA, A. C. P. D. *Noções de probabilidade e estatística*. [S.l.]: Editora da Universidade de São Paulo, 2002.
- MARTINS, J. F.; PIRES, V. F.; PIRES, A. J. Unsupervised neural-network-based algorithm for an on-line diagnosis of three-phase induction motor stator fault. *IEEE Transactions on Industrial Electronics*, IEEE, v. 54, n. 1, p. 259–264, 2007.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943.
- NANDI, S.; TOLIYAT, H. A.; LI, X. Condition monitoring and fault diagnosis of electrical motors—a review. *IEEE transactions on energy conversion*, IEEE, v. 20, n. 4, p. 719–729, 2005.
- NEJJARI, H.; BENBOUZID, M. E. H. Monitoring and diagnosis of induction motors electrical faults using a current park’s vector pattern learning approach. *IEEE Transactions on industry applications*, IEEE, v. 36, n. 3, p. 730–735, 2000.
- OLIVEIRA, Á. G. de; PONTES, R. S. T.; MEDEIROS, C. M. de S. Neural network used to stator winding interturn short-circuit fault detection in an induction motor driven by frequency converter. In: IEEE. *2013 BRICS Congress on Computational Intelligence and 11th Brazilian Congress on Computational Intelligence*. [S.l.], 2013. p. 459–464.
- PINTO, M. d. O. et al. Fundamentos de energia eólica. *Rio de Janeiro: LTC*, 2013.
- RAD, M. K.; TORABIZADEH, M.; NOSHADI, A. Artificial neural network-based fault diagnostics of an electric motor using vibration monitoring. In: IEEE. *Proceedings 2011 International Conference on Transportation, Mechanical, and Electrical Engineering (TMEE)*. [S.l.], 2011. p. 1512–1516.

- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, American Psychological Association, v. 65, n. 6, p. 386, 1958.
- ROYO, J.; ARCEGA, F. Machine current signature analysis as a way for fault detection in squirrel cage wind generators. In: IEEE. *2007 IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*. [S.l.], 2007. p. 383–387.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *nature*, Nature Publishing Group, v. 323, n. 6088, p. 533–536, 1986.
- SANTOS, F. M. d. C.; SILVA, I. N. d.; SUETAKE, M. Sobre a aplicação de sistemas inteligentes para diagnóstico de falhas em máquinas de indução-uma visão geral. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, SciELO Brasil, v. 23, p. 553–569, 2012.
- SAPENA-BANO, A. et al. Induction machine model with space harmonics for fault diagnosis based on the convolution theorem. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 100, p. 463–481, 2018.
- SCHOEN, R. R. et al. An unsupervised, on-line system for induction motor fault detection using stator current monitoring. *IEEE Transactions on Industry Applications*, IEEE, v. 31, n. 6, p. 1280–1286, 1995.
- SHAO, H. et al. Intelligent fault diagnosis of rotor-bearing system under varying working conditions with modified transfer convolutional neural network and thermal images. *IEEE Transactions on Industrial Informatics*, IEEE, v. 17, n. 5, p. 3488–3496, 2020.
- SIDDIQUE, A.; YADAVA, G.; SINGH, B. Applications of artificial intelligence techniques for induction machine stator fault diagnostics. In: IEEE. *4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2003. SDEMPED 2003*. [S.l.], 2003. p. 29–34.
- SIMON, H. Redes neurais—princípios e prática. *Bookman*, 2001.
- SINGH, G. et al. Induction machine drive condition monitoring and diagnostic research—a survey. *Electric Power Systems Research*, Elsevier, v. 64, n. 2, p. 145–158, 2003.
- SUN, W. et al. Convolutional discriminative feature learning for induction motor fault diagnosis. *IEEE Transactions on Industrial Informatics*, IEEE, v. 13, n. 3, p. 1350–1359, 2017.
- THOMSON, W. T.; FENGER, M. Current signature analysis to detect induction motor faults. *IEEE Industry Applications Magazine*, Ieee, v. 7, n. 4, p. 26–34, 2001.
- VIEIRA, R. G.; MEDEIROS, C. M.; SILVA, E. T. Classification and sensitivity analysis to detect fault in induction motors using an mlp network. In: IEEE. *2016 International Joint Conference on Neural Networks (IJCNN)*. [S.l.], 2016. p. 796–802.
- WEBER, T. S. Um roteiro para exploração dos conceitos básicos de tolerância a falhas. *Relatório técnico, Instituto de Informática UFRGS*, 2002.

WU, S.; CHOW, T. W. Induction machine fault detection using som-based rbf neural networks. *IEEE Transactions on Industrial Electronics*, IEEE, v. 51, n. 1, p. 183–194, 2004.