



ISAQUE FERNANDO PEREIRA ALCÂNTARA

**DETECÇÃO E CLASSIFICAÇÃO DE DISTÚRBIOS EM
QUALIDADE DE ENERGIA USANDO MODELOS NARX
NEURAIIS**

LAVRAS – MG

2020

ISAQUE FERNANDO PEREIRA ALCÂNTARA

**DETECÇÃO E CLASSIFICAÇÃO DE DISTÚRBIOS EM QUALIDADE DE ENERGIA
USANDO MODELOS NARX NEURAI**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, para obtenção do título de Mestre.

Prof. Dr. Bruno Henrique Groenner Barbosa

Orientador

Prof. Dr. Danton Diego Ferreira

Coorientador

LAVRAS – MG

2020

**Ficha catalográfica elaborada pela Coordenadoria de Processos Técnicos
da Biblioteca Universitária da UFLA**

Alcântara, Isaque Fernando Pereira
DETECÇÃO E CLASSIFICAÇÃO DE DISTÚRBIOS EM
QUALIDADE DE ENERGIA USANDO MODELOS NARX
NEURALS / Isaque Fernando Pereira Alcântara. – Lavras :
UFLA, 2020.
63 p. : il.

Dissertação(mestrado)–Universidade Federal de Lavras,
2020.

Orientador: Prof. Dr. Bruno Henrique Groenner Barbosa.
Bibliografia.

1. Distúrbios Elétricos. 2. Redes Neurais Artificiais
NARX. 3. Classificação. 4. Séries Temporais. I. Universidade
Federal de Lavras. II. Título.

ISAQUE FERNANDO PEREIRA ALCÂNTARA

**DETECÇÃO E CLASSIFICAÇÃO DE DISTÚRBIOS EM QUALIDADE DE ENERGIA
USANDO MODELOS NARX NEURAI
DETECTION AND CLASSIFICATION OF DISTURBANCES IN POWER QUALITY
USING NARX NEURAL MODELS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, para obtenção do título de Mestre.

APROVADA em 07 de Outubro de 2020.



Prof. Dr. Bruno Henrique Groenner Barbosa	UFLA
Prof. Dr. Danton Diego Ferreira	UFLA
Prof. Dra. Thais Martins Mendes	UNILAVRAS
Prof. Dr. Joaquim Paulo da Silva	UFLA

Prof. Dr. Bruno Henrique Groenner Barbosa
Orientador

Prof. Dr. Danton Diego Ferreira
Co-Orientador

**LAVRAS – MG
2020**

*Dedico a Deus todo o reconhecimento, por ter me
Sustentado até aqui, ajudando a vencer as dificuldades e provações.*

DEUS É FIEL!

AGRADECIMENTOS

A Deus acima de tudo, por ter sustentado a minha vida em caminhos muito abençoados.

Ao professor e orientador Bruno, pela atenção, seriedade e paciência na realização das atividades acadêmicas.

Ao professor e coorientador Danton, pelo apoio e experiência cedidos nesta pesquisa.

À minha companheira amada Sarah Mattos, que com amor me apoiou até aqui e me ajudou em todos os momentos difíceis.

À família, amigos, colegas e pessoas próximas que sempre me deram apoio para seguir em frente.

Até aqui nos ajudou o Senhor. (1 Samuel 7:12)

RESUMO

O estudo da área de Qualidade de Energia Elétrica (QEE) tem crescido muito nos últimos anos. O aumento no uso de conversores de alta potência e de cargas não lineares com potência elevada causam perturbações no sinal elétrico (corrente e tensão), chamadas de distúrbios, provocando danos em equipamentos. Este trabalho apresenta dois sistemas, sendo o primeiro para detecção e o segundo para a classificação de distúrbios de qualidade da energia elétrica (QEE), baseados em modelos neurais NARX (*Nonlinear Autoregressive with eXogenous inputs*). As redes NARX estimam o valor do sinal um passo à frente e, por meio da análise de resíduos destes modelos, o distúrbio é detectado ou classificado. Um total de 6 classes de distúrbios foram testadas, das quais foram *Notch*, *Sag*, *Swell*, *Spike*, Harmônico e Transitório Oscilatório, e uma classe de sinais sem distúrbios, para detectar o sinal nominal. Para estes sinais foram considerados também, testes em diferentes níveis de ruído (40 dB, 50 dB, 60 dB e 70 dB). O detector apresentou resultados rápidos e inéditos na literatura, com uso de 6 a 7 amostras do sinal na detecção de distúrbios, com acurácia média de 91,8%, enquanto o classificador alcançou, com 1/4 de ciclo (64 amostras), uma acurácia média de 84,2%, mostrando a eficácia do método proposto considerando o número reduzido de amostras utilizadas.

Palavras-chave: Qualidade de Energia, Modelos NARX, Redes Neurais Artificiais.

ABSTRACT

The study of the area of power quality (PQ) has grown recently. The increasing use of high power converters and of nonlinear loads cause changes in the electrical signal (current and-voltage), which are often called disturbances, damaging equipment. This work presents two systems, one for detection and another for the classification of power quality (PQ) disturbances, based on NARX neural network models (nonlinear autoregressive with eXogenous inputs). The NARX networks predict the voltage signal value one step ahead and by analyzing the residuals of these models, the disturbance is detected or classified. A total of 6 classes of disturbances were tested: notch, sag, swell, spike harmonic, oscillatory transient, and a class of signals without disturbances to detect the nominal signal. For these signals, tests at different noise levels (40 dB, 50 dB, 60 dB and 70 dB) were carried out. The detector presented fast and unprecedented results in the literature, with the use of 6 to 7 samples of the signal in the detection of disturbances, with an average accuracy of 91.8%, while the classifier achieved with 1/4 of a cycle (64 samples), an average accuracy of 84.2%, showing the effectiveness of the proposed method considering the reduced number of samples used.

Keywords: NARX models, Neural Networks, Power Quality.

LISTA DE FIGURAS

Figura 2.1 – Distúrbios Elétricos	17
Figura 2.2 – Transitório Impulsivo	19
Figura 2.3 – Transitório Oscilatório advindo de um chaveamento de banco de capacitores	20
Figura 2.4 – Conjunto de modelos de identificação	28
Figura 2.5 – Camadas de uma RNA MLP	30
Figura 2.6 – Estrutura de uma RNA NARX	31
Figura 3.1 – Método de detecção de distúrbios proposto.	33
Figura 3.2 – Método de classificação de distúrbios proposto.	34
Figura 3.3 – Comparação entre estrutura das redes utilizadas para treinamento do detec- tor e do classificador.	34
Figura 3.4 – Filtro <i>Notch</i> e sua respectiva resposta em frequência.	37
Figura 3.5 – Configuração e seleção da composição do classificador.	38
Figura 3.6 – Redes componentes do classificador de distúrbios.	39
Figura 4.1 – Erro médio quadrático obtido na execução do <i>k-fold</i> , em que as barras re- presentam o desvio padrão, das 10 redes estimadas em (a) dados de trei- namento e (b) dados de validação. Linhas contínuas em preto representam redes com 3 atrasos e linhas tracejadas em vermelho representam redes com 7 atrasos.	41
Figura 4.2 – Acerto do detector em padrões com <i>sag</i> e <i>swell</i> em função do número de amostras desde o início da ocorrência do distúrbio (ruído igual a 50dB). . .	44
Figura 4.3 – ANOVA e melhores desempenhos de redes NARX MLP	45
Figura 4.4 – Média e desvio padrão de cada classificador para seu respectivo distúrbio em 70dB.	46
Figura 4.5 – Comparação do desempenho do classificador de distúrbio <i>notch</i> com dife- rentes configurações, em dados de validação.	49
Figura 1 – Banco de dados sintéticos em ruído gaussiano branco de 40db.	55
Figura 2 – Banco de dados sintéticos em ruído gaussiano branco de 50db.	55
Figura 3 – Banco de dados sintéticos em ruído gaussiano branco de 60db.	56
Figura 4 – Banco de dados sintéticos em ruído gaussiano branco de 70db.	56
Figura 5 – Média e desvio padrão de cada classificador para seu respectivo distúrbio em 40dB.	57

Figura 6 – Média e desvio padrão de cada classificador para seu respectivo distúrbio em 50dB	57
Figura 7 – Média e desvio padrão de cada classificador para seu respectivo distúrbio em 60dB.	58
Figura 8 – Modelo de Neurônio Biológico	59
Figura 9 – Rede Neural Simples: <i>Perceptron</i> de Rosembat	60
Figura 10 – Tipos de funções de ativação utilizadas na camada de saída das redes neurais	61
Figura 11 – Erro médio quadrático EMQ e critério de parada	63

LISTA DE TABELAS

Tabela 2.1 – Tabela de Distúrbios	18
Tabela 4.1 – Percentual de acertos do comitê de 10 detectores nas 6 primeiras amostras de distúrbios com ruído 40dB.	42
Tabela 4.2 – Percentual de acertos do comitê de 10 detectores nas 6 primeiras amostras de distúrbios com ruído 50dB.	42
Tabela 4.3 – Percentual de acertos do comitê de 10 detectores nas 6 primeiras amostras de distúrbios com ruído 60dB.	43
Tabela 4.4 – Percentual de acertos do comitê de 10 detectores nas 6 primeiras amostras de distúrbios com ruído 70dB.	43
Tabela 4.5 – Melhor configuração do classificador operando em ruído 70 dB (acertos em %),	47
Tabela 4.6 – Melhor configuração do classificador operando em ruído 60 dB (acertos em %),	47
Tabela 4.7 – Melhor configuração do classificador operando em ruído 50 dB (acertos em %),	47
Tabela 4.8 – Melhor configuração do classificador operando em ruído 40 dB (acertos em %),	48

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivos	15
1.2	Estrutura do Trabalho	16
1.3	Lista de Publicações	16
2	REFERENCIAL TEÓRICO	17
2.1	Distúrbios elétricos e qualidade de energia no SEP	17
2.1.1	Transitórios	17
2.1.1.1	Transitórios Impulsivos (<i>Spikes</i>)	18
2.1.1.2	Transitórios Oscilatórios	19
2.1.2	Variações de Tensão de Curta Duração	20
2.1.2.1	Variações Instantâneas	20
2.1.2.2	Variações Momentâneas	20
2.1.2.3	Variações Temporárias	21
2.1.3	Variações de Tensão de Longa Duração	21
2.1.3.1	Interrupções Sustentadas	21
2.1.3.2	Subtensões Sustentadas	22
2.1.3.3	Sobretensões Sustentadas	23
2.1.4	Desequilíbrios de Tensão	23
2.1.5	Distorções da Forma de Onda	23
2.1.5.1	Compensações CC	24
2.1.5.2	Harmônicos	24
2.1.5.3	<i>Notching</i>	24
2.1.5.4	Ruídos	24
2.1.5.5	Flutuações de Tensão	25
2.1.5.6	Variações da Frequência do Sistema	25
2.1.6	Equações e Modelagem dos distúrbios	25
2.2	Identificação de Sistemas	27
2.2.1	Etapas da identificação de sistemas	28
2.2.2	Modelo NARX polinomial	29
2.2.3	Redes Neurais MLP	29
2.2.4	Redes NARX MLP	30

2.3	Configuração das redes NARX MLP utilizando teste ANOVA	30
3	MATERIAIS E MÉTODOS	32
3.1	Banco de dados simulados	35
3.2	Detector de Distúrbios	35
3.2.1	Filtro <i>Notch</i>	36
3.3	Sistema de Classificação de Distúrbios	36
3.3.1	Configurações das Redes NAR	37
3.3.2	Seleção das redes e ANOVA	38
4	RESULTADOS E DISCUSSÃO	40
4.1	Detector Neural	40
4.1.1	Treinamento	40
4.1.2	Validação	40
4.1.3	Discussão	43
4.2	Classificador Neural	44
4.2.1	Análise da estrutura dos classificadores através de testes estatísticos	44
4.2.2	Desempenho do Classificador Neural NAR	46
4.2.3	Discussão	48
5	CONCLUSÃO	50
5.1	Perspectivas	50
	REFERÊNCIAS	52
	APENDICE A – Banco de dados Sintéticos e gráficos de erros	55
	APENDICE B – Redes Neurais Artificiais (RNAs)	59

1 INTRODUÇÃO

A Qualidade da Energia Elétrica (QEE), do inglês *Power Quality (PQ)*, estuda as variações em regime permanente que provocam desequilíbrio no sinal de tensão ou de corrente causadas por falhas na rede elétrica (GHOSH; LEDWICH, 2012). O crescente fluxo de dados em sistemas de energia, conforme apontado por Mendes et al. (2019), tem exigido mais desempenho das ferramentas para monitoramento da qualidade de energia. O estudo desses fenômenos em QEE iniciou-se na década de 90, motivado pela crescente introdução de cargas não lineares nas malhas elétricas, com estudos inovadores para a época como Ward et al. (1990) e as normas Board (1995) e Communication (1990), nas quais foram caracterizados distúrbios elétricos como as elevações (*swells*) e afundamentos (*sags*) de tensão, harmônicos, inter-harmônicos, interrupções, transientes, *notches*, entre outros, tais como supra-harmônicos e *flickers*, que vem surgindo com o crescimento e a diversificação de equipamentos nos atuais sistemas elétricos.

As causas dos distúrbios em QEE podem ser as fontes chaveadas, as descargas atmosféricas, a sobrecarga de equipamentos ligados simultaneamente, o chaveamento de banco de capacitores, curtos circuitos, má operação da rede, o uso de fontes de geração distribuída, entre outras, como apontado por Ribeiro et al. (2018).

As consequências da baixa qualidade da energia elétrica podem causar danos financeiros. Nesse ponto é interessante ressaltar os prejuízos citados por Bollen e Gu (2006), que vão desde a queima de eletrônicos, a inoperância de equipamentos, a perda do conjugado de motores, o decaimento do fator de potência, o aquecimento de condutores (em especial o neutro), a queima de fusíveis e peças de computadores, entre outros. Para a solução dos problemas de QEE, as redes inteligentes em sistemas de distribuição, denominadas de *Smart Grids*, são apontadas como uma boa opção (AMARIPADATH et al., 2017). Isso ocorre graças ao poder das ferramentas de Inteligência Computacional (IC), integráveis em *Smart Grids*, que possuem a capacidade de detectar os distúrbios elétricos. A detecção deve ser realizada por meio de sistemas de baixa complexidade computacional, permitindo assim o monitoramento em tempo real para aplicações de compensação e proteção (RIBEIRO et al., 2018).

Normalmente, esses sistemas possuem como etapas a extração de parâmetros e a aplicação de um algoritmo que realize a detecção baseada nos parâmetros extraídos. A extração de parâmetros consiste na transformação dos dados (normalmente janelas de dados) para um novo espaço onde as diferenças entre os distúrbios e os sinais nominais tornam-se destacadas. Estas

características, ou parte delas, são então apresentadas em um sistema de detecção. Seguindo essa linha, são encontrados na literatura diversos métodos para a detecção de distúrbios, usando ferramentas como transformadas *Curvelet* (LIU et al., 2018), transformadas *Wavelets* e máquinas de Vetor de Suporte (SVM) (THIRUMALA et al., 2018), programação genética evolutiva e multi-objetiva (UTKARSH; SINGH, 2018), aprendizagem profunda ou *Deep Learning* e redes neurais artificiais (MOHAN; SOMAN; RAVI, 2017), estatísticas de ordem superior, árvores de decisão e os classificadores bayesianos (RIBEIRO et al., 2018) e análise de componentes independentes (NAGATA et al., 2018).

Nos métodos de detecção e classificação encontrados na literatura é comum a análise de uma janela dos dados (um conjunto formado por 256 amostras do sinal contendo o distúrbio), também conhecidos como ciclo da onda. A exemplo, Mendes et al. (2017), por meio da análise multidimensional dos dados e com baixo custo computacional, conseguiram com até ciclo do sinal realizar a detecção de distúrbios elétricos. Semelhantemente, Ribeiro et al. (2018) utilizaram uma janela de detecção de mesmo tamanho e conseguiram realizar a detecção dos distúrbios por meio de estatísticas de ordem superior. Isso demonstra necessidade cada vez maior de rapidez e agilidade para com os métodos de detecção distúrbios elétricos, preservando assim QEE, conforme discutido em (CAI et al., 2019).

1.1 Objetivos

Este trabalho propõe um método de detecção e de classificação de distúrbios que afetam a qualidade de energia baseado no emprego de Redes Neurais do tipo NARX (*Nonlinear Autoregressive with exogenous inputs*), com enfoque no tempo de detecção e classificação. Assim, os seguintes objetivos específicos foram propostos:

- implementar um detector de distúrbios, no caso um detector de novidades, com número reduzido de amostras da rede, de forma a obter uma rápida resposta de detecção;
- desenvolver um sistema de classificação baseado na mistura de especialidades, onde cada classe de distúrbio possua seu detector específico e a classificação final do sistema leve em consideração todos os detectores obtidos;
- analisar o uso de redes NARX com diferentes configurações, por exemplo, número de atrasos das suas entradas e número de neurônios da rede;
- analisar o desempenho do sistema para diferentes níveis de ruído no sinal.

1.2 Estrutura do Trabalho

Na sessão 2, são apresentadas as características dos distúrbios elétricos em qualidade de energia e as ferramentas de identificação de sistemas junto aos modelos NARX, conforme a revisão literária e suas respectivas normas. O método, descrito na sessão 3, contempla tanto a ferramenta de detecção, quantitativa e focada em velocidade de detecção, quanto a ferramenta de classificação, quantitativa e voltada para capacidade de análise e diferenciação. Por fim, na sessão 4, são apresentados os resultados e o desempenho dos métodos propostos, para que, por meio da avaliação dos pontos positivos e negativos dos mesmos, fosse feita a discussão. Em seguida, foram apresentadas as partes conclusivas e as perspectivas de melhorias para as pesquisas futuras.

1.3 Lista de Publicações

Isaque Alcântara; Bruno Henrique Groenner Barbosa; Danton Ferreira. Detecção de Distúrbios em Qualidade de Energia usando modelos NARX Neurais. **In: ANAIS DO 14º SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI)**, 2019, Ouro Preto. Anais eletrônicos. Campinas, Galoá, 2019.

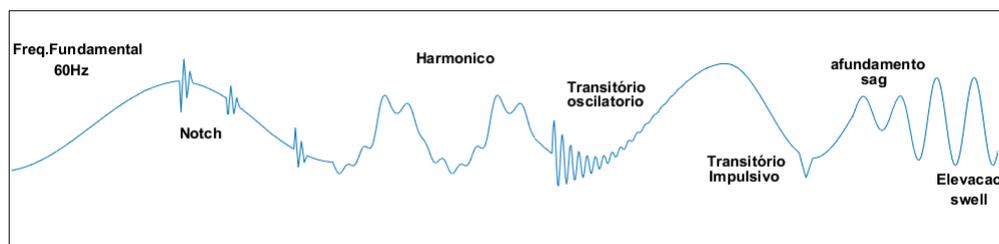
2 REFERENCIAL TEÓRICO

2.1 Distúrbios elétricos e qualidade de energia no SEP

A Qualidade da Energia Elétrica, conforme Ferreira (2010), é uma área que estuda a capacidade operacional da corrente e tensão no Sistema Elétrico de Potência (SEP), nos quais o modelo de referência de um sistema elétrico satisfatório é aquele que possui constância na frequência e na amplitude do sinal, permitindo a operação da rede em suas capacidades nominais, o que caracteriza uma operação eficiente e segura para as cargas ligadas à mesma. Nesta sessão, serão abordados os distúrbios elétricos de curta e longa duração, os harmônicos e inter-harmônicos, as flutuações de tensão, as interrupções, as sobretensões e as subtensões. Para fins didáticos e de padronização, a unidade utilizada na medição da intensidade dos distúrbios é a grandeza “pu”, que significa “sistemas por unidade”, onde se obtém o valor medido sobre a base da unidade, com esta padronização em pu permitindo simplificar e tornar as análises mais objetivas (BOARD, 1995).

A figura 2.1 apresenta as deformações no formato de onda causadas por alguns distúrbios elétricos envolvendo a área de QEE. Entre as distorções estão os afundamentos (*sag*) e elevações de tensão (*swell*), os *notchings*, os harmônicos e os eventos transitórios. Já os dados específicos de todos os distúrbios, de acordo com a natureza de cada evento, o espectro da onda, a duração e amplitude da tensão, foram agrupados na tabela 2.1.

Figura 2.1 – Distúrbios Elétricos



Fonte: Do autor (2020)

2.1.1 Transitórios

Os eventos de natureza transitória são distúrbios eletromagnéticos que advém de mudanças eventuais e inesperadas na rede elétrica. A amplitude do sinal de tensão e corrente desses eventos geralmente é muito alta, porém, com tempos de duração muito baixos, entre milisse-

Tabela 2.1 – Tabela de Distúrbios

Categoria	Espectro	Duração	Grandeza(pu)
1 TRANSITÓRIOS	-	-	-
1.1 Impulsivos	-	-	-
1.1.1 Nanossegundo	-	<50 ns	-
1.1.2 Microssegundo	-	50 ns - 1 ms	-
1.1.3 Milissegundo	-	>1 ms	-
1.2 Oscilatórios	-	-	-
1.2.1 Baixa Frequência	<5 kHz	3 - 50 ms	0 - 4pu
1.2.2 Média Frequência	5 – 500 kHz	20 ms	0 - 8pu
1.2.3 Alta Frequência	0,5 - 5 MHz	5 ms	0 - 9pu
2 VTCD			
2.1 Instantânea	-	-	-
2.1.1 Afundamento de tensão	-	0.5 - 30 ciclos	0,1 – 0,9pu
2.1.2 Elevação de tensão	-	0.5 - 30 ciclos	1,1 – 1,8pu
2.2 Momentânea	-	-	-
2.2.1 Afundamento de tensão	-	30 ciclos - 3 s	0,1 – 0,9pu
2.2.2 Elevação de tensão	-	30 ciclos - 3 s	1,1 – 1,4pu
2.3 Temporária	-	-	-
2.3.1 Afundamento de tensão	-	3 s - 1 minuto	0,1 – 0,9pu
2.3.2 Elevação de tensão	-	3 s - 1 minuto	1,1 – 1,2pu
3 VTLD			
3.2 Subtensão Sustentada	-	>1 minuto	0,8 – 0,9pu
3.3 Sobretensão Sustentada	-	>1 minuto	1,1 – 1,2pu
4 DISTORÇÃO DA FORMA DE ONDA	-	-	-
4.1 Nível CC	-	reg. permanente	0 – 0,1%
4.2 Harmônicos	ordem 0-100	reg. permanente	0 – 20%
4.3 Interharmônicos	0 - 6 kHz	reg. permanente	2%
4.4 Notching	-	reg. permanente	-
5 FLUTUAÇÃO DE TENSÃO	<25 Hz	Intermitente	0,1 - 7%
5 RUÍDO	faixa ampla	reg. permanente	0 – 1%

Fonte: Board (1995, p. 12)

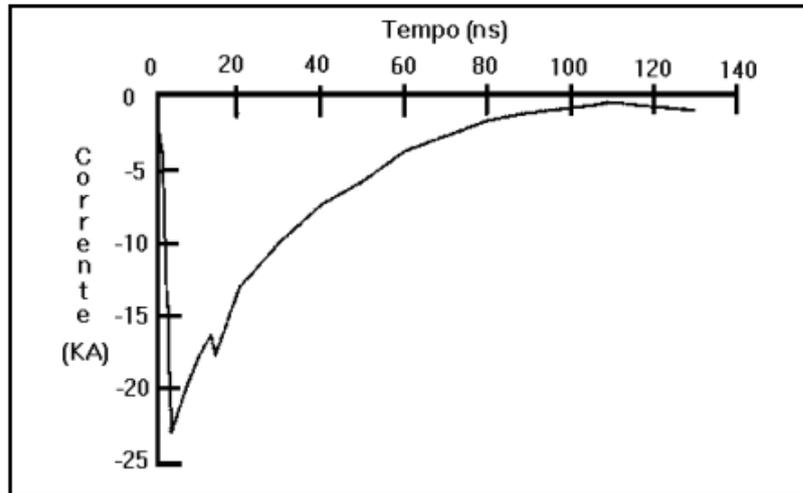
gundos e nanossegundos. Os dois tipos de eventos transitórios são: impulsivos e oscilatórios, sendo diferenciados principalmente pela fonte que os causa (BOARD, 1995).

2.1.1.1 Transitórios Impulsivos (*Spikes*)

Os transitórios impulsivos são distúrbios de natureza elétrica, que são causados, em geral, por grandes descargas vindas da atmosfera. Os impulsos desses eventos são unidirecionais e podem cair tanto no lado positivo ou negativo do sinal de tensão e corrente, variando também de forma aleatória, a frequência da rede elétrica. O tempo de duração do transitório impulsivo pode ocorrer em intervalos menores que 50 nanossegundos, entre 50 nanossegundo a 1 milissegundo ou em intervalos maiores do que 1 milissegundo, conforme a tabela 2.1. A figura

2.2 apresenta o exemplo de um sinal acometido de um transitório impulsivo, advindo de uma descarga atmosférica. (BOARD, 1995)

Figura 2.2 – Transitório Impulsivo



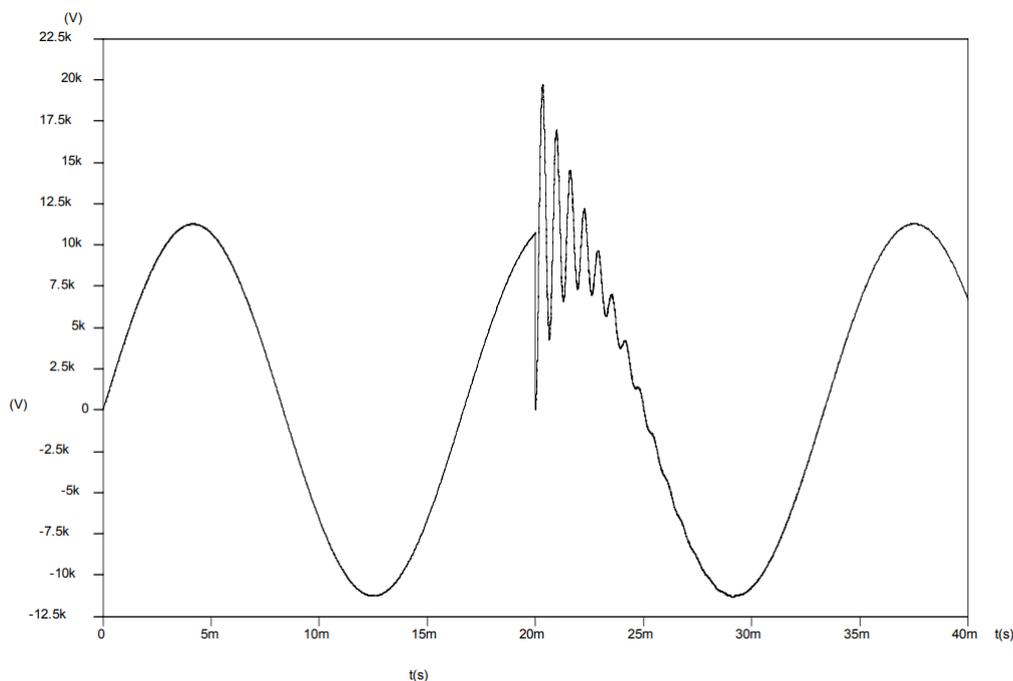
Fonte: Arruda (2003, p. 8)

Os transitórios impulsivos são conhecidos informalmente como *spikes*, devido aos seus rápidos e intensos picos no sinal da tensão.

2.1.1.2 Transitórios Oscilatórios

Transitórios Oscilatórios são eventos comuns de ocorrer em operações de chaveamento de transformadores ou bancos de capacitores, em energização de linhas de transmissão ou mesmo na extinções das correntes de faltas. São divididos em eventos de baixa, média ou alta frequência. A figura 2.3 apresenta o espectro do evento transitório oscilatório, fruto do chaveamento de um banco de capacitores. Os transitórios de baixa frequência possuem o espectro menor que 5 kHz, com a duração entre 3 a 50 milissegundos e uma amplitude de tensão variando entre 0 e 4 pu. Os transitórios de média frequência trabalham com o espectro variando entre 5 kHz a 500 kHz, com a duração média de até 20 microssegundos e uma amplitude do sinal de tensão variando de 0 a 8 pu. Já os transitórios de alta frequência são eventos que ocorrem com uma frequência maior, em torno de 0,5 MHz até os 5 MHz, com o tempo de duração médio em torno dos 5 microssegundos e a variação da amplitude do sinal de tensão variando entre 0 a 4 pu (BOARD, 1995).

Figura 2.3 – Transitório Oscilatório advindo de um chaveamento de banco de capacitores



Fonte: Arruda (2003, p. 11)

2.1.2 Variações de Tensão de Curta Duração

As variações de tensão de curta duração são anomalias geralmente caracterizadas como oscilações momentâneas, temporárias ou instantâneas na rede, tendo como eventos principais as elevações de tensão, conhecidas como *swells* e os afundamentos de tensão, conhecidos como *sags* (FERREIRA, 2010).

2.1.2.1 Variações Instantâneas

Dentre as variações instantâneas, podem ocorrer os afundamentos de tensão, que duram entre os 0,5 e 30 ciclos, com uma tensão em torno de 0,1 até os 0,9 pu e também podem ocorrer as elevações de tensão instantâneas, que possuem duração de 0,5 a 30 ciclos, com a amplitude do sinal de tensão variando 1,1 até 1.8 pu (BOARD, 1995).

2.1.2.2 Variações Momentâneas

Dentro dos grupos das variações momentâneas de curta duração, ocorrem as interrupções, os afundamentos (*sags*) e as elevações (*swells*). Para o grupo das interrupções, a duração ocorre entre 0,5 ciclo até os 3 segundos com a amplitude da tensão inferior a 1 pu. No grupo dos afundamentos, os ciclos oscilam em torno dos 3 ciclos, se mantendo até 3 segundos, e uma

amplitude da tensão entre os 0,1 até 0,9 pu. Por fim, as elevações, podem oscilar entre os 3 ciclos até 3 segundos, com uma faixa de operação na sua tensão variando de 1,1 até os 1,4 pu (BOARD, 1995).

2.1.2.3 Variações Temporárias

As variações temporárias, são diferentes das variações momentâneas e instantâneas quando se leva em conta o tempo de duração de cada uma. No caso das variações temporárias, as interrupções, os *sags* e os *swells* podem durar de 3 segundos até 1 minuto, com as elevações operando na faixa de 1,1 até 1,2 pu, os afundamentos de tensão operando na faixa de 0,1 a 0,9 pu e as interrupções operando em intervalos menores do que 0,1 pu (BOARD, 1995).

2.1.3 Variações de Tensão de Longa Duração

As variações de tensão de longa duração, como o próprio nome já as caracteriza, possuem uma duração maior que os demais distúrbios, geralmente acima dos 60 segundos podendo ser causadas por chaveamentos ou alterações na carga do sistema (MENDES et al., 2017). Conforme a tabela 2.1, as variações de longa duração podem ser interrupções sustentadas, subtensões sustentadas ou mesmo sobretensões sustentadas (BOARD, 1995).

2.1.3.1 Interrupções Sustentadas

As interrupções sustentadas, por serem maiores que 1 minuto, ocorrem na maior parte dos casos quando as concessionárias tem algum problema técnico, que força o desarme ou a queima de componentes, causando a interrupção do fornecimento de energia e consequentemente prejuízos financeiros. Em alguns casos, esse tipo de interrupção pode ser forçada por manutenções programadas da própria concessionária no SEP, diminuindo os prejuízos, em atividades de melhoria da própria infraestrutura, como a troca do cabeamento, as alterações em seccionadores, as mudanças no transformador, entre outras atividades. Dentre as causas comuns nas interrupções sustentadas causadas por incidentes, estão as queimas nos fusíveis, os problemas no circuito de alimentação ou falhas em seccionadores. Para a proteção de equipamentos mais sensíveis nesse tipo de corte abrupto de energia, é comum o uso de *nobreaks*, que são equipamentos eletrônicos dotados de baterias chumbo-ácidas capazes de sustentar uma carga por longos períodos durante a falta de energia (BOARD, 1995).

2.1.3.2 Subtensões Sustentadas

As subtensões sustentadas são afundamentos de tensão por longos períodos, acima dos 60 segundos. Esse evento possui uma amplitude de tensão abaixo dos 0,9 pu. Tecnicamente, as subtensões sustentadas são causadas pela sobrecarga das fontes de alimentação de energia, fazendo com que a corrente na qual é submetida a rede tenha interações com a impedância. Assim, ocorrem as quedas no nível de tensão. Muitas cargas reativas ou a falta dos bancos de capacitores na Rede Elétrica, podem também provocar subtensões sustentadas no fornecimento de energia (BOARD, 1995).

Dentre os problemas mais comuns causados pelas subtensões sustentadas estão (ARRUDA, 2003):

- redução da potência reativa fornecida por bancos de capacitores ao sistema;
- possível interrupção da operação de equipamentos eletrônicos, tais como computadores e controladores;
- redução de índice de iluminação para os circuitos de iluminação incandescente.
- elevação do tempo de partida das máquinas de indução, o que contribui para a elevação de temperatura dos enrolamentos;
- aumento nos valores das correntes do estator de um motor de indução quando alimentado por uma tensão inferior à nominal. Desta forma tem-se um sobre-aquecimento da máquina, o que certamente reduzirá a expectativa de vida útil da mesma.

Existem alternativas que podem ser tomadas para se regular os níveis de tensões em subtensões sustentadas, são elas (ARRUDA, 2003):

- instalar reguladores de tensão;
- instalar capacitores *shunt* para reduzir a corrente do circuito;
- instalar capacitores série para cancelar a queda de tensão indutiva;
- instalar cabos com bitolas maiores para reduzir a impedância da linha;
- mudar o transformador de serviço para um com maior capacidade, reduzindo assim a impedância da linha;

- instalar compensadores estáticos de reativos, os quais tem os mesmos objetivos que os capacitores, para mudanças bruscas de cargas.

2.1.3.3 Sobretensões Sustentadas

As sobretensões sustentadas podem ser também denominados como elevações de tensão sustentada. Entre as propriedades que as caracterizam, está o tempo de duração maior que os 60 segundos e uma amplitude do sinal de tensão na faixa de 1,1 pu até 1,2 pu em média. Dentre as causas mais comuns para esse tipo de evento, está o corte abrupto do consumo de grandes cargas do sistema, provocando a elevação do nível de tensão. As sobretensões sustentadas, por outro lado, também pode ser causada por banco de capacitores, quando em contato com a rede energizada, ou mesmo por falhas na conexão dos bornes de transformadores. As sobretensões sustentadas são distúrbios que estão ligados diretamente com a vida útil de equipamentos da rede, podendo reduzi-la drasticamente ou até mesmo queimar esses equipamentos (MAIA, 2011).

2.1.4 Desequilíbrios de Tensão

Desequilíbrios de tensão são variações que ocorrem principalmente pela má distribuição entre as fases de alimentação do sistema, provocando muitas vezes a concentração monofásica em sistemas que possuem mais de uma fase, sendo comum em cargas residenciais. Geralmente a amplitude do sinal desequilibrado corresponde entre os 0,5% até os 2% do sinal original da frequência fundamental, e quanto a sua duração, é um evento que ocorre em regime permanente. Os desequilíbrios de tensão podem se manifestar através da assimetria entre uma das fases, assimetria em várias fases de forma conjunto ou por assimetrias na amplitude dos sinais de tensão (MAIA, 2011).

2.1.5 Distorções da Forma de Onda

A distorção no formato de onda se enquadra na categoria dos distúrbios que alteram a componente fundamental e o espectro da onda, como ocorrem nos distúrbios harmônicos, nos inter-harmônicos, nas compensações de corrente contínua (CC) e nos eventos *notchings* (MAIA, 2011).

2.1.5.1 Compensações CC

As compensações de corrente contínua são um problema conhecido também como *DC offset*, no qual decorre em consequência da presença de corrente CC em sistemas CA, tendo como causadores, por exemplo, os retificadores de meia-onda quando operados de forma ideal. Em compensações CC, a quantidade de CC em redes CA pode reduzir a vida útil de transformadores, por meio da sua operação saturada, podendo ainda causar nos conectores da rede de alimentação e nos da malha de aterramento, o fenômeno de corrosão eletrolítica (BOARD, 1995).

2.1.5.2 Harmônicos

Os distúrbios harmônicos são derivados de frequências múltiplas inteiras do sinal da frequência fundamental (geralmente considerando a frequência fundamental em 50 ou 60 Hz). Esses distúrbios, também chamadas de distorções harmônicas, modificam tanto o espectro de tensão e corrente, quanto a constância da amplitude e frequência do sinal (que é perdida), tendo como agente causador, as cargas não-lineares que operam na rede. Os afetados por esse distúrbio não são apenas os consumidores ligados diretamente à distorção harmônica, e sim todos os consumidores envolvidos no entorno da rede (indiretos ao problema) podem ser afetados (FERREIRA, 2010).

2.1.5.3 Notching

Os *notches* são eventos, no sinal de tensão, causados pela comutação de corrente elétrica entre fases, ocorrendo um curto-circuito momentâneo entre elas. Geralmente a frequência do sinal na ocorrência de eventos *notches* são altas, impossibilitando assim a sua medição para os trabalhos de análise das componentes harmônicas (ARRUDA, 2003).

2.1.5.4 Ruídos

Os ruídos são espectros indesejados sobrepostos aos sinal de tensão ou corrente elétrica e que varia em uma banda menor que 200 kHz. Em redes de energia elétrica, os ruídos pode ser originados por circuitos controladores, cargas advindas de retificadores, equipamentos de potência eletrônicos e fontes chaveadas. Os ruídos possuem em média de 0 a 1% de amplitude em relação ao sinal da frequência fundamental do sistema (BOARD, 1995).

2.1.5.5 Flutuações de Tensão

Flutuações de tensão são eventos causados pelas oscilações que ocorrem de forma constante no valor da tensão, com a amplitude do sinal operante entre 0,1 a 7% do valor da frequência fundamental, ou em termos de grandeza, em torno de 0,95 e 1,05 pu, quanto a amplitude do distúrbio em relação ao sinal de tensão. Entre as flutuações, existem os tipos aleatórias e as repetitivas.

As flutuações podem oscilar de forma aleatória (sem um padrão definido), de forma cíclica (com padrões de repetições no sinal), ou podem ocorrer de forma esporádica (ocorrem inesperadamente). Em geral possuem um espectro de onda menor que 25 Hz. Um dos exemplos comuns dos efeitos das flutuações são os motores, quando os mesmos possuem oscilação na intensidade do torque. É importante ressaltar que das flutuações de tensão surgem os efeitos *flicker*. Esses, por sua vez, são muito perceptíveis aos olhos humanos e ocorrem em lâmpadas. O *flicker* faz com que o piscar da iluminação ocorra com intensidades diferentes, provocando a sensação de desconforto para a visão humana.

2.1.5.6 Variações da Frequência do Sistema

As variações na frequência da rede elétrica são alterações na frequência fundamental de alimentação da rede, geralmente, do padrão 60 Hz. Esse tipo de distúrbio possui normalmente uma duração menor que 10 segundos e as variações provocadas por ele podem alterar a velocidade de sistemas geradores ou mesmo de motores conectados à rede. É comum um sistema com alimentação em 60 Hz ocorrer variação de até 0,5% devido ao equilíbrio que ocorre entre os geradores e as cargas, conectados na rede elétrica. Caso a variação seja muito grande, a mesma já passa a ser considerada como uma falta no sistema elétrico.

Em sistemas isolados, entretanto, como é o caso da geração própria nas indústrias, na eventualidade de um distúrbio, a magnitude e o tempo de permanência das máquinas operando fora da velocidade resultam em desvios da frequência em proporções mais significativas.

2.1.6 Equações e Modelagem dos distúrbios

Os distúrbios em QEE podem ser identificados no sinal discreto da tensão, conforme o modelo descrito por Ribeiro e Pereira (2007). O sinal de tensão $v(n)$, de n -ésimas amostras de N , o qual representa um sinal contaminado por distúrbios elétricos, onde $n = 0, \dots, N - 1$, contém a componente fundamental $f(n)$, as distorções harmônicas $h(n)$, as distorções inter-

harmônicas $i(n)$, os fenômenos transientes $t(n)$ e um ruído independente, chamado $r(n)$. Este por sua vez é distribuído de forma homogênea ao longo do sinal. A equação do sinal de tensão $v(n)$ é representada por:

$$v(n) = f(n) + h(n) + i(n) + t(n) + r(n). \quad (2.1)$$

A componente fundamental $f(n)$ é dada por,

$$f(n) = A_0(n) \cos \left[2\pi \frac{f_0(n)}{f_s} n + \theta_0(n) \right], \quad (2.2)$$

em que $A_0(n)$ corresponde a amplitude do sinal, $f_0(n)$ é a frequência fundamental e $\theta_0(n)$ representa a fase da componente fundamental.

A soma total dos eventos harmônicos no sinal é descrita como:

$$h(n) = \sum_{m=1}^M h_m(n), \quad (2.3)$$

em que M é o número de componentes harmônicos presentes e

$$h_m(n) = A_m(n) \cos \left[2\pi m \frac{f_0(n)}{f_s} n + \theta_m(n) \right], \quad (2.4)$$

sendo que $A_m(n)$, $f_0(n)$ e $\theta_m(n)$ correspondem a amplitude, frequência fundamental e fase do harmônico, respectivamente.

O total de eventos inter-harmônicos é descrito por:

$$i(n) = \sum_{j=1}^J i_j(n), \quad (2.5)$$

em que J é o número de componentes inter-harmônicos e

$$i_j(n) = A_j(n) \cos \left[2\pi \frac{f_j(n)}{f_s} n + \theta_j(n) \right], \quad (2.6)$$

com $A_j(n)$, $f_j(n)$ e $\theta_j(n)$, nesta sequência, representando a amplitude, frequência e fase do inter-harmônico.

O componente $t(n)$ na Eq. 2.1 refere-se aos distúrbios transientes, representado pela soma dos eventos impulsivos, oscilatórios e *notches*, conforme a equação:

$$t(n) = t_{imp}(n) + t_{not}(n) + t_{osc}(n). \quad (2.7)$$

As equações 2.8, 2.9 e 2.10 representam os modelos matemáticos de cada tipo de evento transitório:

$$t_{imp}(n) = \sum_{i=1}^{N_{imp}} t_{imp,i}(n), \quad (2.8)$$

$$t_{osc}(n) = \sum_{i=1}^{N_{osc}} A_{osc,i}(n) e^{-\alpha_{osc,i}(n-n_{osc,i})}, \quad (2.9)$$

$$t_{not}(n) = \sum_{i=1}^{N_{not}} t_{not,i}(n). \quad (2.10)$$

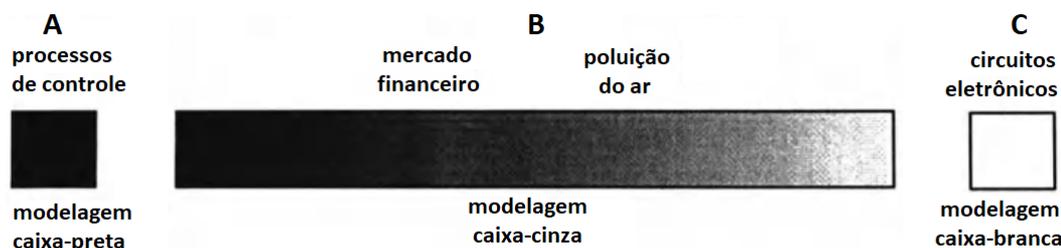
Dentre as classes eventos impulsivos, oscilatórios e *notches*, se encontram os distúrbios *spike* (impulsivo), *notch* (oscilatório), *sag* (afundamento), *swell* (elevação) e os *flickers* (flutuações de tensão que podem conter *sags* e *swells* juntos). Além disso, a classificação desses distúrbios pode ser feita conforme a sua duração, sendo considerados de curta ou longa duração. As terminologias e classificações de cada evento foram organizadas na tabela 2.1, normatizada por Board (1995).

2.2 Identificação de Sistemas

As formas de representar um determinado sistema de acordo com suas características estão ligadas ao método de modelagem escolhido. Cada problema revela um tipo de natureza que é essencial para a seleção da ferramenta de modelagem (GEVERS, 2005).

As três formas de identificação de sistemas são: modelagem caixa-branca (*whitebox*), caixa-preta (*blackbox*) e caixa cinza (*graybox*). Na modelagem caixa-branca utilizam-se dados científicos, ou advindos de conhecimentos *a priori*, para permitir que este identifique determinado sistema. Na modelagem caixa-preta se restringe ao uso de dados dinâmicos. Nos modelos de caixa-cinza são utilizadas tanto as relações diretas de entrada/saída dos dados, comuns nos modelos caixa-preta, como também o conhecimento *a priori*, típico dos modelos caixa branca. A figura 2.4 ilustra o espectro em escala de preto e branco, onde se encontram exemplos de aplicação de abordagens caixa-branca, caixa-cinza e caixa preta.

Figura 2.4 – Conjunto de modelos de identificação



Fonte: Adaptado de Sohlberg (1998)[p.9]

Por meio da figura 2.4, conforme descrito por Sohlberg (1998), processos de controle industriais (A), por exemplo, tendem a empregar técnicas caixa-preta por exigirem, em muitos casos, um conhecimento limitado do processo. Por outro lado, circuitos eletrônicos (C) são normalmente modelados a partir de conhecimento prévio em relação as leis da física, enquadrando-os na modelagem caixa branca. Já sistemas econômicos e indicadores de poluição do ar (B), admitem tanto o método de identificação pelos dados de entrada e saída como por dados científicos de conhecimento *a priori*, se enquadrando como modelagem caixa-cinza.

2.2.1 Etapas da identificação de sistemas

A identificação de sistemas aplicadas a problemas reais, de acordo Aguirre (2007), busca aproximar o modelo com a relação de causa e efeito presente nos dados. Em linhas gerais, as principais etapas de identificação de um sistema são:

1. coleta de dados e testes dinâmicos;
2. escolha das representações matemáticas;
3. determinação da estrutura do modelo;
4. estimação de parâmetros;
5. validação do modelo.

Durante essas etapas, algumas informações são importantes, a começar na coleta dos dados, deve-se conhecer o processo a ser modelado pois os dados são normalmente extraídos durante a operação normal de um sistema real. A ordem do sistema também é importante para definir a estrutura do modelo, sendo que um modelo com ordem inferior a do problema pode

não acompanhar efetivamente o sistema real, ao mesmo tempo que um modelo com ordem muito acima ficará custoso e inviável.

Um representação matemática bastante flexível são as Redes Neurais Artificiais, mas dependem de uma boa seleção de sua arquitetura (etapa de determinação de estrutura) e de um algoritmo adequado para definição de seus parâmetros (etapa de estimação de parâmetros). Por fim, na etapa de validação, além de testar se o modelo de fato atendeu aos critérios mínimos definidos em relação ao sistema original, é importante a comparação que demonstre os melhores modelos, de acordo com o desempenho, para o objetivo específico em questão (AGUIRRE, 2007).

2.2.2 Modelo NARX polinomial

Os modelos NARX (*Non-linear AutoRegressive with eXogenous inputs*) tem características determinísticas nos quais a saída do sistema, representada por y , é obtida por meio de atrasos do sinal de entrada e do sinal de saída. O uso de valores em diferentes instantes de tempo fazem do modelo NARX um modelo discreto em relação ao tempo (AGUIRRE; CORREA; CASSINI, 2002). A equação a seguir descreve matematicamente o modelo NARX polinomial:

$$y(k) = f^l[y(k-1), \dots, y(k-n_y), u(k-d), \dots, u(k-d-n_u)] + e(k), \quad (2.11)$$

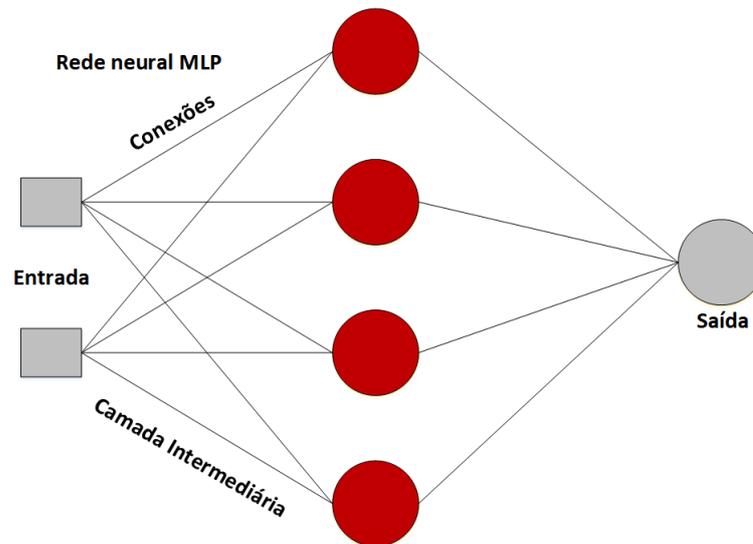
com $u(k)$, $y(k)$, $e(k)$ representando a entrada, a saída e o ruído, respectivamente, n_u e n_y , indicando os n -ésimos atrasos de u e y , o tempo morto do modelo representado pela variável d e f representando a função polinomial não linear. Por fim, l representa o grau de não-linearidade da função f .

2.2.3 Redes Neurais MLP

As Redes Neurais MLP, ou *Multilayer Perceptron*, são caracterizadas pela existência de uma ou mais camadas intermediárias entre a entrada e a saída da rede neural, com a saída dos neurônios de uma camada anterior conectando-se a todos os neurônios da camada posterior (RUMELHART; HINTON; WILLIAMS, 1985). Essa característica confere ao modelo uma boa adaptação com o treinamento pelo algoritmo de *backpropagation* (HAYKIN, 2007).

A figura 2.5 apresenta a arquitetura de uma rede MLP com 2 neurônios na camada de entrada, 4 distribuídos na camada intermediária (escondida) e um neurônio na camada de saída.

Figura 2.5 – Camadas de uma RNA MLP



Fonte: Do autor (2020)

2.2.4 Redes NARX MLP

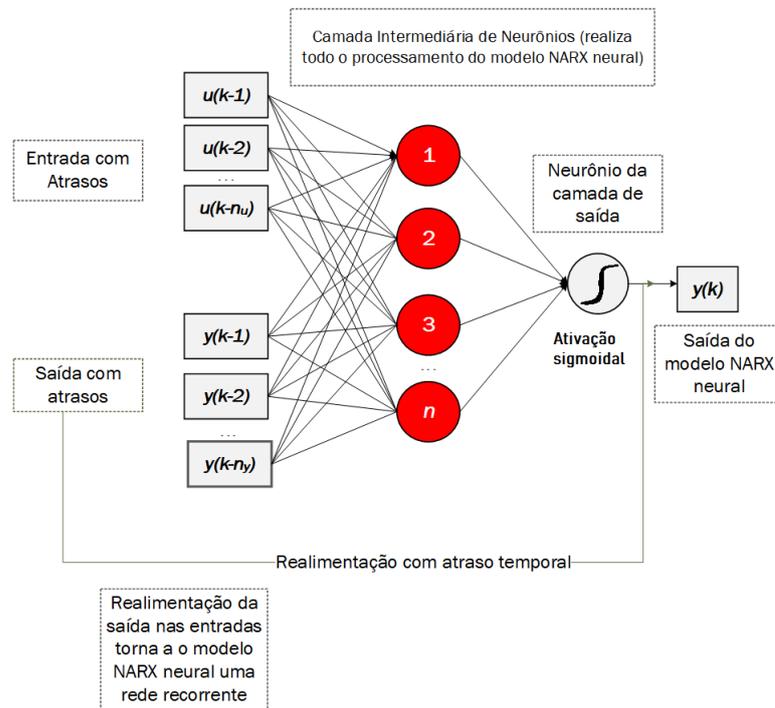
As redes neurais NARX MLP possuem boa capacidade de resolver problemas de natureza não linear, o que as favorece na seleção de regressores que é realizada pela função estática da própria rede, possuindo maior capacidade de não linearidade se comparadas aos modelos NARX polinomiais (AGUIRRE, 2007). A representação das redes NARX MLP, também pode ser descrita pela equação 2.11 (referente ao modelo NARX polinomial). Todavia, deve se ressaltar que nesta equação, o modelo NARX MLP se difere quanto a sua função não linear f , que representa as diversas camadas e funções de ativação dos neurônios da rede neural artificial, enquanto no modelo NARX polinomial, a função f é relacionada a um polinômio de grau l .

A figura 2.6 ilustra a estrutura das redes NARX, sendo que duas abordagens são possíveis, redes recorrentes ou não, ou seja, a própria saída da rede com respectivos atrasos é realimentada na entrada da rede (abordagem série-paralelo) ou atrasos das medições da saída do sistema modelado são diretamente utilizados na entrada da rede (abordagem série).

2.3 Configuração das redes NARX MLP utilizando teste ANOVA

O erro médio quadrático (MSE) permite visualizar os resíduos de uma rede neural artificial, conforme Toro-Vizcarrondo e Wallace (1968), por meio da diferença do quadrado dos erros medidos pelo quadrado dos erros estimados, com o baixo índice de erro (MSE) indicando um bom desempenho da RNA e o contrário ocorrendo com o alto índice de erro, apontando fa-

Figura 2.6 – Estrutura de uma RNA NARX



Fonte: Do autor (2020)

lhas e insuficiências em seu funcionamento. As melhores RNAs de um classificador, podem ser escolhidas com base em seus resíduos (MSE), todavia esta análise se torna difícil para ser realizada manualmente quando se trata de um conjunto muito de milhares de redes, como é o caso deste trabalho. Para isso, ferramentas estatísticas podem realizar o ordenamento dos resultados com maior praticidade, como é o caso do teste de análise de variâncias (ANOVA) (STHLE; WOLD, 1989). Por meio deste, é possível compreender as variâncias internas dos resíduos das RNAs, analisando as performances individuais de cada uma. O resultado pode indicar ou não se no meio do conjunto das redes ocorrem resultados significantes de algumas em relação a todas as demais, ou, contextualizando ao problema, permitiria ordenar as melhores NARX MLP para a classificação de distúrbios, por exemplo, conforme o desempenho em um nível de ruído.

O teste de resíduos da ANOVA indica resultados significantes caso o valor *p value* do teste seja menor que 0,05, possibilitando a rejeição da hipótese de nula (baixa significância) nos resultados. Paes (2008), ressalta que um resultado com o *p value* menor que 0,01 representa indício forte de resultados significantes e um valor menor 0,001, um indício muito forte de significância, com esses valores, em termos práticos, podendo indicar, com maior grau de certeza, da existência de redes com bons desempenhos para tornarem-se classificadoras especialistas de suas respectivas classes de distúrbios.

3 MATERIAIS E MÉTODOS

De forma a detectar ou classificar a presença de distúrbios no sinal de tensão de uma rede de distribuição de energia, duas metodologias são propostas neste trabalho: um sistema de detecção e um sistema de classificação. Em ambos, os sinais de distúrbios considerados foram: *Notch*, Harmônico, Transitório Oscilatório (capacitivo), Transitório Impulsivo (*spike*), elevação (*swell*) e afundamento (*sag*) de tensão.

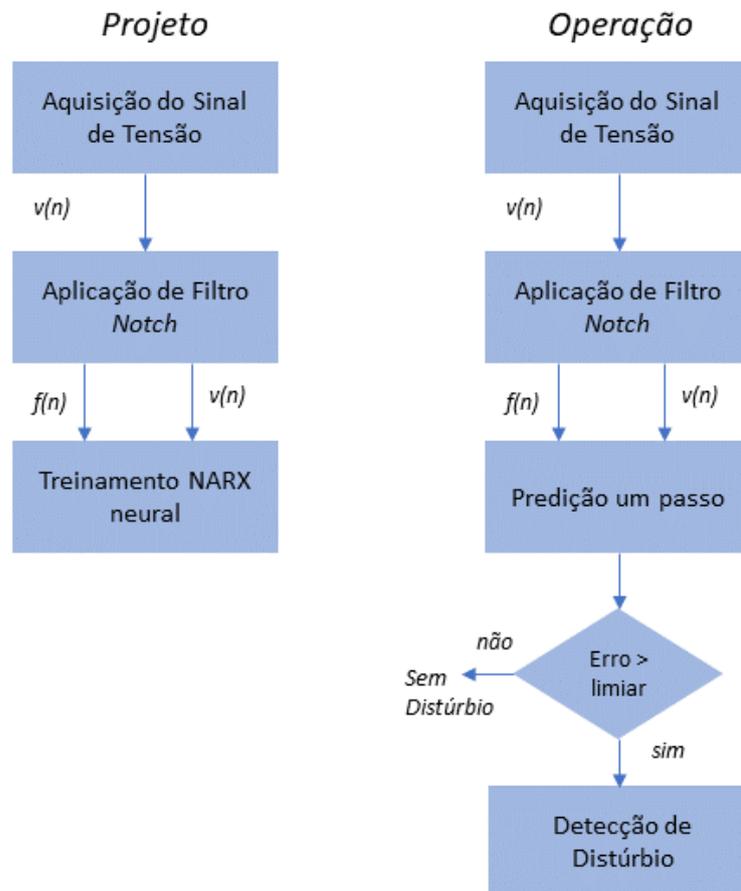
O sistema de detecção de distúrbios tem por finalidade detectar, com o menor número de amostras possível, se há um distúrbio de qualidade de energia no sinal de tensão e corrente adquiridos. Para isso, as seguintes etapas de projeto e operação, apresentadas na figura 3.1, são realizadas:

- aquisição do sinal de tensão, sendo no projeto apenas sinais sem distúrbio e na operação tanto sinais com distúrbios quanto sem distúrbios;
- extração do sinal fundamental(sem distúrbio) com aplicação de um filtro *Notch* (projeto e operação);
- treinamento de uma rede NARX MLP com o sinal extraído (sem distúrbio) e com o sinal original (com distúrbio) de forma a minimizar o erro um passo à frente do sinal de tensão da rede (projeto);
- predição um passo à frente do sinal de tensão pela rede NARX MLP treinada para detecção (operação);
- análise do erro de predição e tomada de decisão sobre a presença ou não de distúrbio (operação).

Para a classificação de distúrbios, diferentemente do detector, foi treinada uma rede neural NARX para cada tipo de distúrbio, além da rede treinada sem distúrbios. As etapas envolvidas no sistema de classificação proposto são apresentadas na figura 3.2 e descritas como:

- aquisição do sinal de tensão com e sem distúrbio (projeto e operação);
- treinamento individual de uma rede neural NARX para cada tipo de sinal de tensão de forma a minimizar o erro um passo à frente do sinal de tensão da rede (projeto);

Figura 3.1 – Método de detecção de distúrbios proposto.

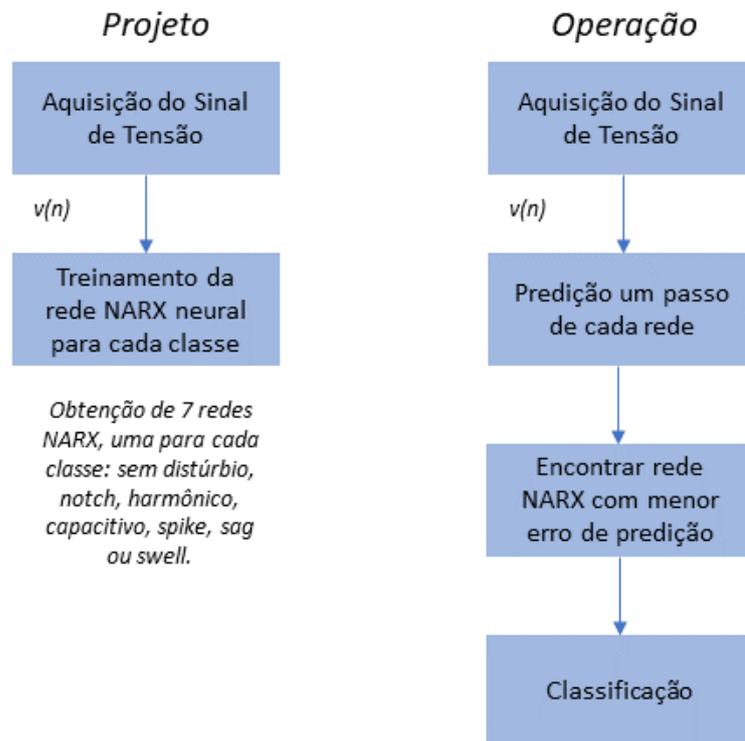


Fonte: Do autor (2020)

- predição um passo à frente do sinal de tensão por cada uma das redes NARX treinadas (operação);
- análise do erro de predição de todas as redes e tomada de decisão sobre a classe do sinal de tensão adquirido (operação).

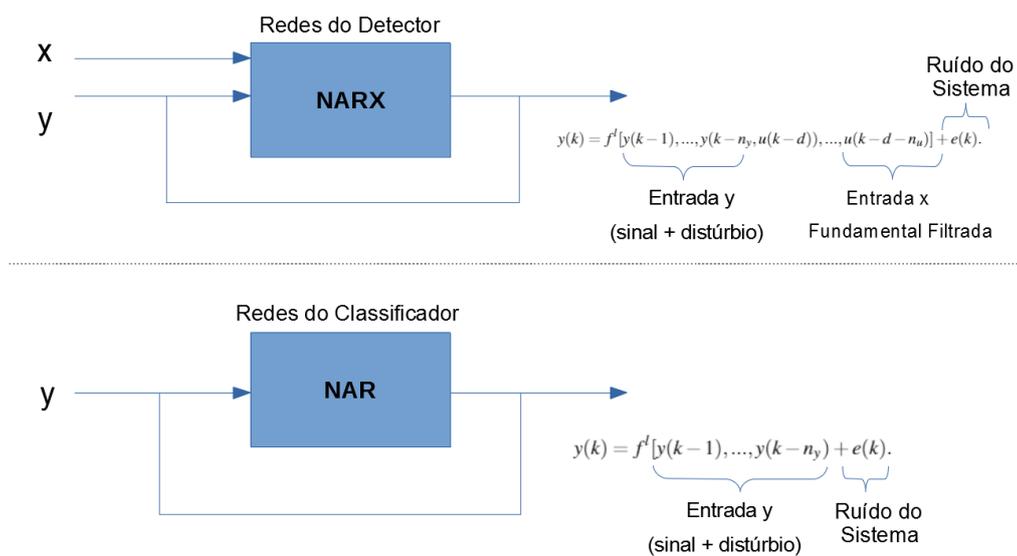
Podem ser observadas nas metodologias uma diferença importante. No método de detecção foi utilizado um filtro *notch* para extração da componente fundamental do sinal de tensão enquanto que o mesmo não foi feito para o sistema de classificação. Por conseguinte, as redes utilizadas para detecção são do tipo NARX enquanto as redes utilizadas para classificação são do tipo NAR, como pode ser observado na figura 3.3. Observou-se que para a classificação, o uso desse filtro apenas acrescentaria um custo computacional ao método sem melhorar seu desempenho. Essas etapas e discussões serão apresentadas posteriormente.

Figura 3.2 – Método de classificação de distúrbios proposto.



Fonte: Do autor (2020)

Figura 3.3 – Comparação entre estrutura das redes utilizadas para treinamento do detector e do classificador.



Fonte: Do autor (2020)

3.1 Banco de dados simulados

Um total de 10.000 eventos foram gerados para o caso da rede elétrica não possuir distúrbios (classe de sinais nominais de tensão), de forma a treinar as redes NARX MLP do detector e classificador. Todos os sinais foram gerados com uma frequência de amostragem igual a 15.360 Hz, ou seja, 256 amostras por ciclo. A frequência da componente fundamental foi definida de forma aleatória para cada evento no intervalo de 58 Hz a 62Hz.

Em relação ao detector, apesar da frequência da fundamental poder variar para cada sinal no banco de dados gerado, o filtro *notch* foi projetado de forma fixa para atenuação da frequência 60 Hz, o que torna a simulação mais realística por considerar uma variação não estimada na frequência da rede.

Foram avaliados seis diferentes tipos de distúrbios em sinais sintéticos de tensão, além do próprio sinal nominal, quais sejam: *notch*, harmônico, transitório oscilatório (capacitivo), transitório impulsivo (*spike*), elevação (*swell*) e afundamento (*sag*) de tensão. As mesmas características de frequência fundamental e de amostragem dos sinais nominais apresentadas anteriormente são aplicadas aqui. Um ruído branco gaussiano aditivo, com relação de sinal-ruído (*Signal-to-noise ratio* SNR) de 40 dB, 50 dB, 60 dB e 70 dB, foi adicionado aos sinais, sendo gerados um total de 1.000 eventos para cada tipo de sinal em cada ruído. De acordo com (TOMIC; KUSLJEVIC; VUJICIC, 2007), sinais reais normalmente possuem ruído na faixa de 50 a 70 dB.

3.2 Detector de Distúrbios

Os sinais utilizados para treino do detector são aqueles com ruído branco Gaussiano aditivo a ruídos de 50 dB. Importante observar que, apesar do detector NARX neural ser treinado com eventos a ruído de 50dB apenas, essa mesma rede será avaliada em diferentes ruídos de forma a testar sua robustez em diferentes condições de operação da rede.

Para treinamento da rede foi utilizado o método de validação cruzada do tipo *k-fold*, com $k = 10$. Assim, 10 redes NARX MLP foram treinadas de forma a estimar o próximo valor do sinal da tensão, baseando em valores anteriores da componente fundamental extraída pelo filtro *Notch* e do próprio sinal de tensão. O número de atrasos tanto dessas entradas quanto da autorregressão da saída utilizados foram 3 ou 7 para fins de comparação da influência dessa escolha nos resultados.

O número de neurônios escondidos das redes variou de 3 a 30. Para treinamento das redes foi utilizado o método de *backpropagation* com algoritmo de otimização de Levenberg-Marquardt com regularização Bayesiana e 2.000 épocas de treino.

A partir do treino das 10 redes NARX foi construído um *ensemble* composto por todas, em que o erro final do detector é obtido a partir da média da saída de todas as redes. Assim, é realizada a análise do resíduo do *ensemble*, sendo que um distúrbio é detectado no instante em que o erro do *ensemble* for maior do que duas vezes e meia o desvio padrão do erro do mesmo em eventos de sinais de tensão para o respectivo ruído, conforme o limiar de erro típico de cada rede.

3.2.1 Filtro *Notch*

Antes do treino da rede NARX MLP para detecção de distúrbios, o sinal de tensão $v(n)$ foi pré-processado por meio de um filtro *Notch* e decomposto de acordo com as componentes presentes no sinal.

A frequência de corte do filtro foi definida como $f_0 = 60$ Hz. Dessa forma, $v(n)$ foi decomposto em dois sinais, o componente fundamental $f(n)$ e os eventuais distúrbios elétricos, acrescidos do ruído da rede. O filtro utilizado foi do tipo IIR (resposta ao impulso infinita) de segunda ordem, do tipo rejeita faixa, nome dado graças a sua capacidade de atenuar faixas específicas de frequência, pois, conforme Mitra e Kuo (2006), graças as suas características, este tipo de filtro possui um baixo custo computacional e também uma boa seletividade, com sua transformada Z representada por:

$$H(z) = \frac{1 + az^{-1} + z^{-2}}{1 + \rho az^{-1} + \rho^2 z^{-2}}, \quad (3.1)$$

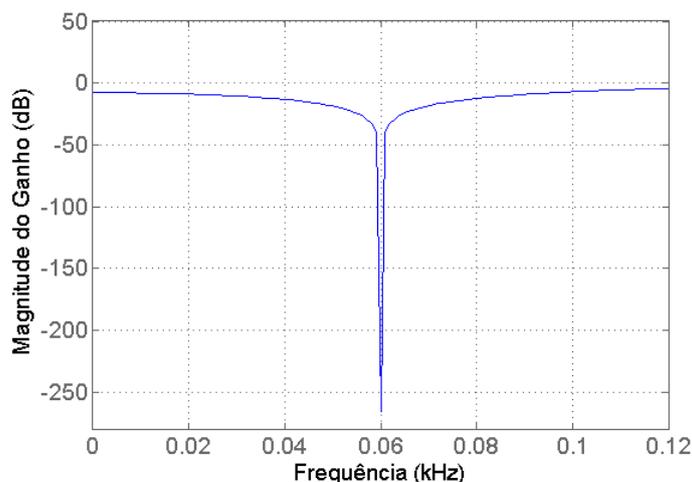
em que $a = -2 \cos \omega_0$ e fator *notch* ρ igual a 0,97.

A figura 3.4, conforme Barbosa e Ferreira (2013), ilustra a curva de resposta em magnitude do filtro *notch* utilizado, cuja frequência de rejeição $\omega_0 = 2\pi f_0$.

3.3 Sistema de Classificação de Distúrbios

Apresenta-se neste tópico uma ferramenta para a classificação de distúrbios. O classificador é composto por sete *ensembles* (conjuntos de 10 redes NAR) que operam simultaneamente com os dados de entrada, cada *ensembles* responsável por detectar um tipo de classe (seis com

Figura 3.4 – Filtro *Notch* e sua respectiva resposta em frequência.



Fonte: Barbosa e Ferreira (2013)

distúrbios e uma nominal). As redes foram treinadas em todo o banco de dados com ruído no sinal elétrico, conforme descrito anteriormente.

As redes obtidas podem ser definidas como um classificador do tipo *One Class*. Ou seja, cada rede é um detector de um tipo de sinal de tensão (sem distúrbio ou com um dos 6 tipos de distúrbios estudados), ou seja, atua como classificador especialista. Este tipo de abordagem é interessante pois caso haja necessidade de adicionar qualquer outra rede, para um novo distúrbio, isso não afetaria a configuração do classificador atual, seria apenas adicionada mais uma rede e seu erro seria comparado com o erro das demais. Isso torna a metodologia proposta bastante flexível e atraente para trabalhos futuros.

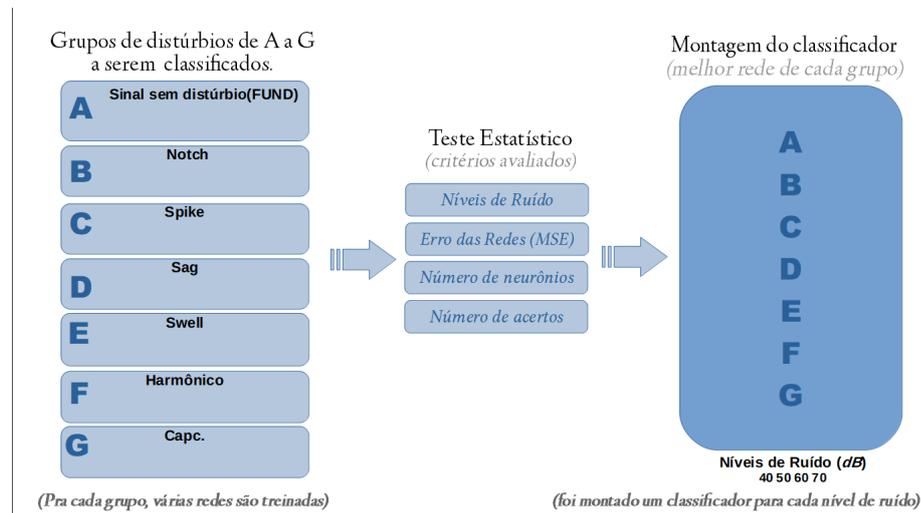
3.3.1 Configurações das Redes NAR

Todas as redes NAR utilizadas para classificação de distúrbios foram treinadas com 3, 7, 16, 32 e 64 atrasos, sendo que este último corresponde a 1/4 do ciclo de 256 amostras. Ao utilizar um número reduzido do número de amostras de ciclo, no máximo 1/4 de ciclo, espera-se obter um classificador que possa ser de fato empregado para tomada de decisão no controle do sistema elétrico.

O número de neurônios escondidos das redes variou de 5 a 30. A figura 3.5 apresenta as configurações empregadas em cada rede, chamadas de A a G. Cada neurônio escondido possui uma função de ativação não-linear do tipo sigmoidal.

Para treinamento das redes, da mesma forma como utilizado para o detector, foi utilizado o método de *backpropagation* com algoritmo de otimização de Levenberg-Marquardt com regularização Bayesiana e 2.000 épocas de treino.

Figura 3.5 – Configuração e seleção da composição do classificador.



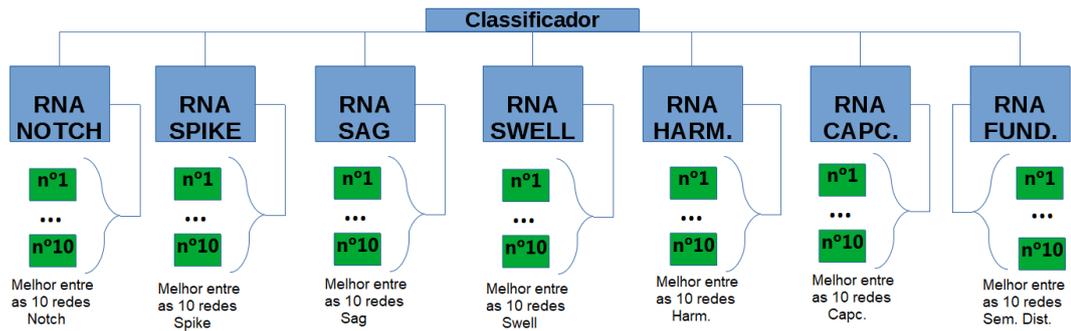
Fonte: Do autor (2020)

3.3.2 Seleção das redes e ANOVA

As melhores configurações de redes NAR MLP de cada classificador (A a G) foram escolhidas por meio de análise estatística (*ANOVA*), que analisou a variância do erro médio quadrático (MSE) das redes neurais, obtidos por validação cruzada do tipo *k-fold*, com $k = 10$ validações por rede, conforme apresentado na figura 3.5. A figura 3.6 apresenta a composição do classificador final, ou seja, ele possui sete *ensembles*, cada um com um conjunto de 10 redes NAR com a melhor configuração de atrasos e neurônios, para cada nível de ruído e classe de distúrbio. O teste *ANOVA* foi utilizado para avaliar a significância dos resultados.

No treinamento das Redes Neurais foi utilizado o *software* MATLAB, licenciado pela Universidade Federal de Lavras e para as análises estatísticas o *software* SAS University Edition, de uso gratuito para o meio acadêmico.

Figura 3.6 – Redes componentes do classificador de distúrbios.



Fonte: Do autor (2020)

4 RESULTADOS E DISCUSSÃO

Os resultados podem ser separados em duas etapas, tanto para os resultados do detector quanto do classificador:

- análise de desempenho das redes neurais onde é verificada a influência do número de atrasos e da escolha do número de neurônios escondidos no erro de predição;
- validação do detector/classificador na presença de sinais com distúrbios em diferentes ruídos.

4.1 Detector Neural

4.1.1 Treinamento

A figura 4.1 apresenta o erro médio quadrático de treino e validação do detector NARX durante o processo de validação cruzada de 10 *folds* . São apresentados valores de erro de acordo com o número de atrasos das entradas da rede (3 ou 7) e com a variação do número de neurônios escondidos (3, 5, 10, 15, 20 e 30).

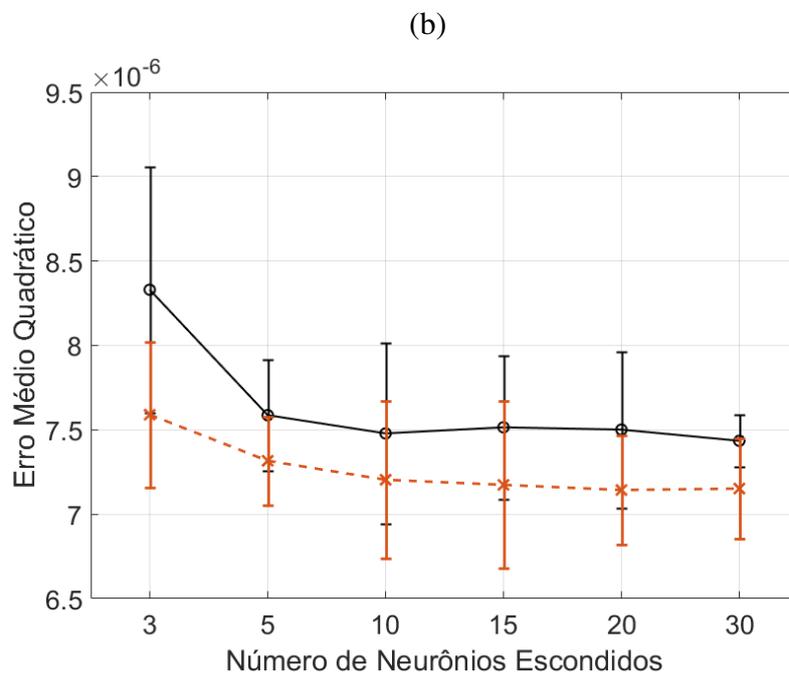
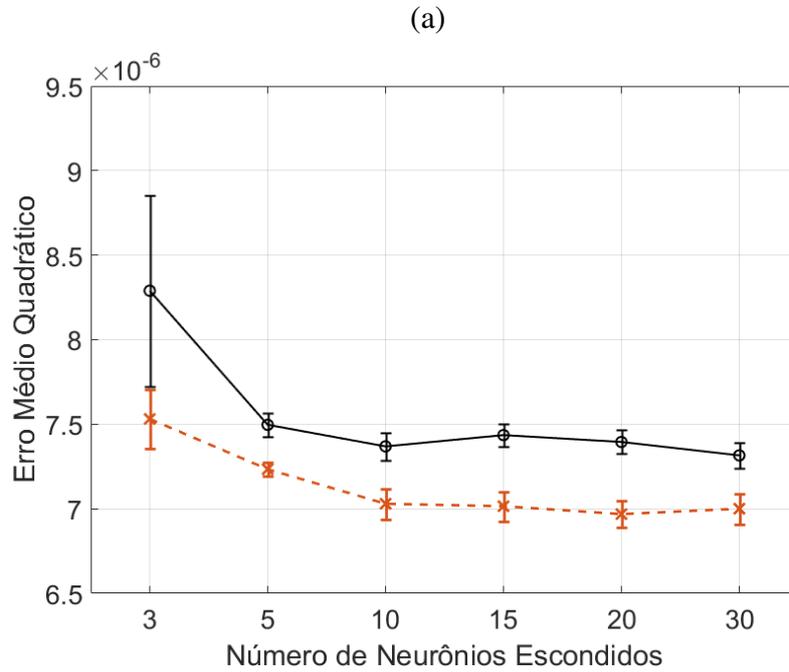
Como pode ser observado, principalmente em dados de treino, o aumento do número de atrasos reduziu o erro médio das redes, justificando assim esse aumento no número de entradas da rede, de seis (três atrasos por tipo de entrada) para catorze (7 atrasos). Com relação ao número de neurônios escondidos, a partir de 10 neurônios não foi constatada melhoria significativa no desempenho das redes que justificasse esse aumento na sua complexidade. Assim, a configuração escolhida para rede foi de 14 entradas (7 atrasos para cada tipo de entrada - fundamental extraída e parte auto-regressiva), com 10 neurônios escondidos. Essas serão as redes que farão parte do *ensemble* validado na próxima seção.

4.1.2 Validação

A partir dos eventos gerados com ou sem distúrbio em diferentes valores de ruído, o detector (*ensemble*) definido na seção anterior foi validado. As tabelas 4.1, 4.2, 4.3 e 4.4 apresentam os acertos de classificação obtidos para cada tipo de evento.

Como o objetivo é implementar um sistema que detecte o distúrbio de forma mais rápida possível, foi realizada uma análise da porcentagem de acerto à medida que as amostras do evento são processadas pelo detector. Por exemplo, na tabela 4.1, quando ocorre um distúrbio do tipo

Figura 4.1 – Erro médio quadrático obtido na execução do *k-fold*, em que as barras representam o desvio padrão, das 10 redes estimadas em (a) dados de treinamento e (b) dados de validação. Linhas contínuas em preto representam redes com 3 atrasos e linhas tracejadas em vermelho representam redes com 7 atrasos.



Fonte: Do autor (2020)

notch, na primeira amostra de ocorrência desse distúrbio são detectados 94,9% desses eventos. Aplicando o detector proposto na segunda amostra desses eventos, dos 5,1% que não foram detectados, 2,6% passaram a ser detectados, somando 97,5% de acerto até a segunda amostra do evento e assim por diante, até a sexta amostra.

Ao analisar essas tabelas é possível inferir que o sistema proposto detecta satisfatoriamente a maioria dos distúrbios (ou não produz falsos alarmes) nos eventos estudados, com exceção da elevação e afundamento de tensão. Boa parte dos eventos são detectados já na primeira amostra e, a partir da sexta amostra, praticamente todos os eventos foram detectados corretamente, o que comprova a eficiência do método em detectar rapidamente a ocorrência de um distúrbio. Ademais, no caso de ruído igual a 50 dB, 60 dB e 70 dB melhores resultados foram obtidos, sendo essas as relações sinal-ruído mais comum de se encontrar em redes. Para ruído igual a 40 dB, harmônico, *sag* e *swell* são mais difíceis de detectar, apesar de que já na sexta amostra 92,5% dos eventos com harmônicos foram detectados.

Tabela 4.1 – Percentual de acertos do comitê de 10 detectores nas 6 primeiras amostras de distúrbios com ruído 40dB.

Distúrbio	n°amostras					
	1	2	3	4	5	6
Nenhum	98,8	–	–	–	–	–
<i>Notch</i>	94,9	97,5	97,5	97,6	97,6	99,9
<i>Harm.</i>	70	75	77,5	80	85	92,5
<i>Capc.</i>	98,6	100	100	100	100	100
<i>Spike</i>	97,9	99,7	100	100	100	100
<i>Sag</i>	25	35	40	42,5	45	52,5
<i>Swell</i>	2,5	2,5	2,5	5	7,5	10

Fonte: Do autor (2020)

Tabela 4.2 – Percentual de acertos do comitê de 10 detectores nas 6 primeiras amostras de distúrbios com ruído 50dB.

Distúrbio	n°amostras					
	1	2	3	4	5	6
Nenhum	98,7	–	–	–	–	–
<i>Notch</i>	98,6	99,4	99,4	99,4	99,4	100
<i>Harm.</i>	95	97,5	97,5	97,5	100	100
<i>Capc.</i>	99,3	100	100	100	100	100
<i>Spike</i>	100	100	100	100	100	100
<i>Sag</i>	67,5	77,5	80	80	80	80
<i>Swell</i>	17,5	30	37,5	45	45	45

Fonte: Do autor (2020)

Pelo pior desempenho do detector em eventos com *sag* e *swell*, foi realizada uma análise do acerto do mesmo à medida que o número de amostras processadas aumentasse. Esse resultado é apresentado na figura 4.2. Como pode ser observado, o índice de acerto é realmente baixo em ambos distúrbios na primeira amostra, mas, a partir da vigésima amostra, todos os

Tabela 4.3 – Percentual de acertos do comitê de 10 detectores nas 6 primeiras amostras de distúrbios com ruído 60dB.

Distúrbio	1	2	3	4	5	6
Nenhum	98,5	–	–	–	–	–
<i>Notch</i>	98,9	99,4	99,4	99,4	99,4	100
<i>Harm.</i>	97,5	100	100	100	100	100
<i>Capc.</i>	100	100	100	100	100	100
<i>Spike</i>	100	100	100	100	100	100
<i>Sag</i>	90	95	95	95	95	95
<i>Swell</i>	35	45	50	55	57,5	57,5

Fonte: Do autor (2020)

Tabela 4.4 – Percentual de acertos do comitê de 10 detectores nas 6 primeiras amostras de distúrbios com ruído 70dB.

Distúrbio	1	2	3	4	5	6
Nenhum	98,1	–	–	–	–	–
<i>Notch</i>	99,2	99,5	99,5	99,5	99,5	100
<i>Harm.</i>	95	100	100	100	100	100
<i>Capc.</i>	100	100	100	100	100	100
<i>Spike</i>	100	100	100	100	100	100
<i>Sag</i>	87,5	87,5	87,5	87,5	90	92,5
<i>Swell</i>	55,0	57,5	57,5	60	60	62,5

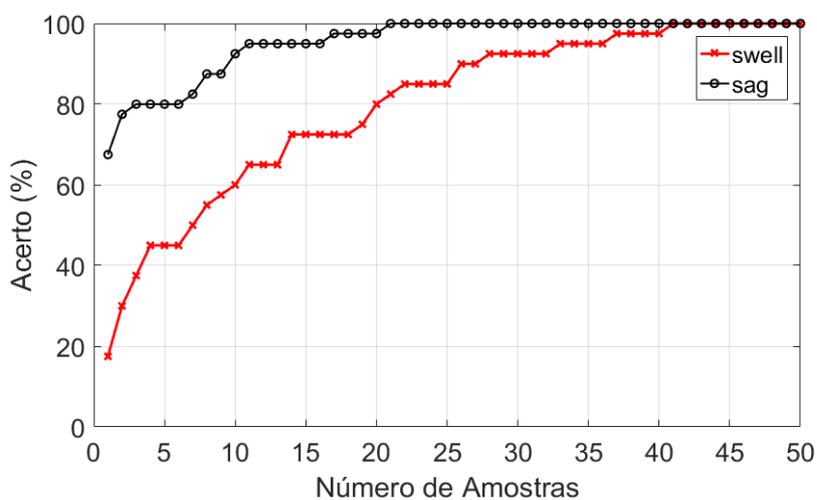
Fonte: Do autor (2020)

eventos com *sag* foram detectados, o mesmo ocorreu com eventos *swell* a partir da quadragésima amostra. Considerando que um ciclo do sinal possui 256 amostras, a detecção em menos de um quarto do ciclo é ainda bastante interessante.

4.1.3 Discussão

O detector, proposto nesta pesquisa alcançou resultados rápidos para os sinais amostrados. Considerando o nível de ruído no sinal de 70 dB, o sistema apresentou um percentual de acertos maior, com 100% de acerto para as classes de transientes oscilatórios (capcitivos) e transientes impulsivos (*spikes*), isso ocorreu também na faixa de 60 dB. Todavia, as classes *sag* e *swell* foram as que apresentaram o menor desempenho em relação às demais, com o *sag* no pior dos casos, chegando a 52,5% de acerto até as 6 primeiras amostras em 40 dB e o *swell* conseguindo apenas 10%. Para resolução deste problema se utilizou uma janela maior de dados, com 64 atrasos (1/4 de ciclo), com ambos conseguindo acertar 100% nessa faixa, demonstrando que, conforme a classe do distúrbio, houve uma necessidade de um intervalo de dados maior.

Figura 4.2 – Acerto do detector em padrões com *sag* e *swell* em função do número de amostras desde o início da ocorrência do distúrbio (ruído igual a 50dB).



Fonte: Do autor (2020)

As relações de sinal-ruído utilizadas foram de 40 dB, 50 dB, 60 dB e 70 db. Com exceção da elevação e afundamento de tensão, em todos os outros distúrbios e sinal nominal, a abordagem apresentada obteve resultados satisfatórios ao analisar até a sexta amostra de ocorrência do distúrbio. No caso de afundamento e elevação de tensão foi observado que depois de 20 e 40 amostras, respectivamente, a detecção atingiu seu valor máximo, sendo ainda considerada uma detecção rápida por ser necessário menos que um quarto do ciclo para detecção.

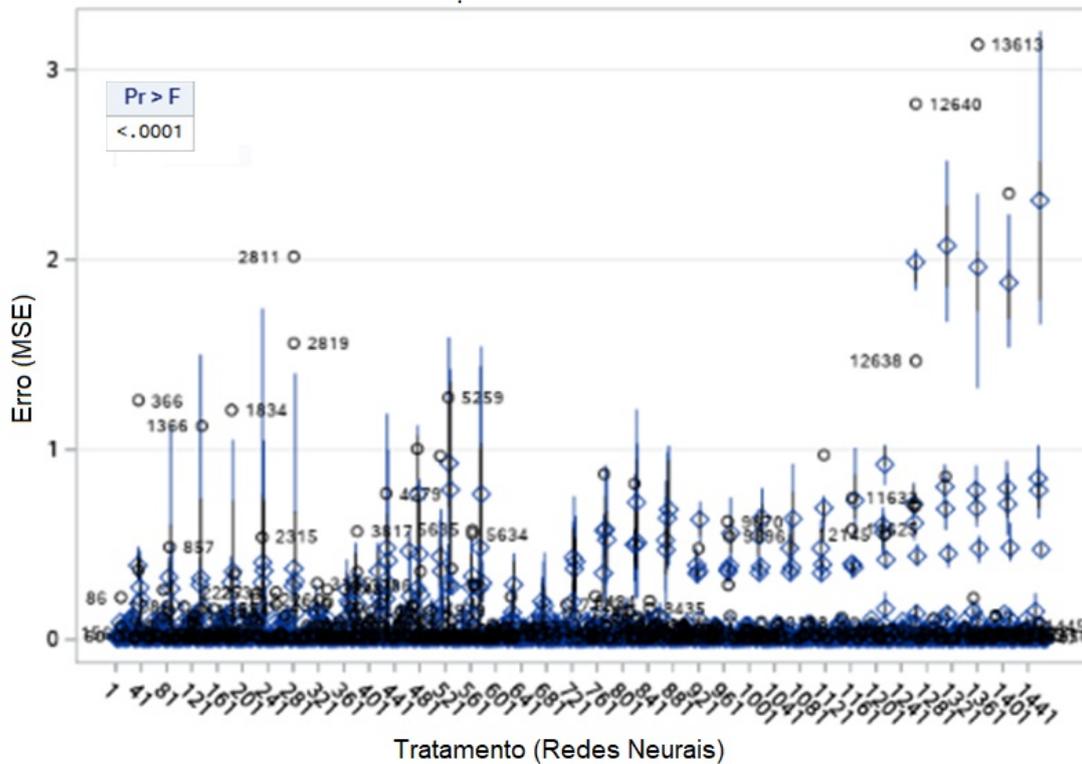
4.2 Classificador Neural

4.2.1 Análise da estrutura dos classificadores através de testes estatísticos

O teste de análise de variâncias ordenou, conforme a figura 4.3, as melhores configurações das redes NARX para os classificadores. O eixo y representou o índice de erros médios quadráticos medidos em cada uma das redes e o eixo x uma numeração atribuída para cada rede, conforme seus atributos de ruído em que operou (70 dB, 60 dB, 50 dB e 40 dB), o número de neurônios (5, 10, 15, 20, 25 e 30) e o número de atrasos (3, 7, 16, 32 e 64). Conforme a figura, os resultados demonstraram um *p-value* menor que 0,0001 permitindo descartar a hipótese nula e de resultados com significância entre as redes do classificador. Devido ao grande número de testes, o gráfico gerou uma sobreposição de amostras, o que impossibilitou a visualização manual das melhores RNAs. Para isso, foi geradas novas figuras 4.4, contendo de forma limpa e clara os resultados das melhores redes para cada nível de ruído (70 dB a 40 dB), com o números

de neurônios e atrasos dessas redes descritos nas matrizes de confusão das tabelas 4.5, 4.7 e 4.7 e 4.8, do tópico a seguir.

Figura 4.3 – ANOVA e melhores desempenhos de redes NARX MLP



Fonte: Do autor (2020)

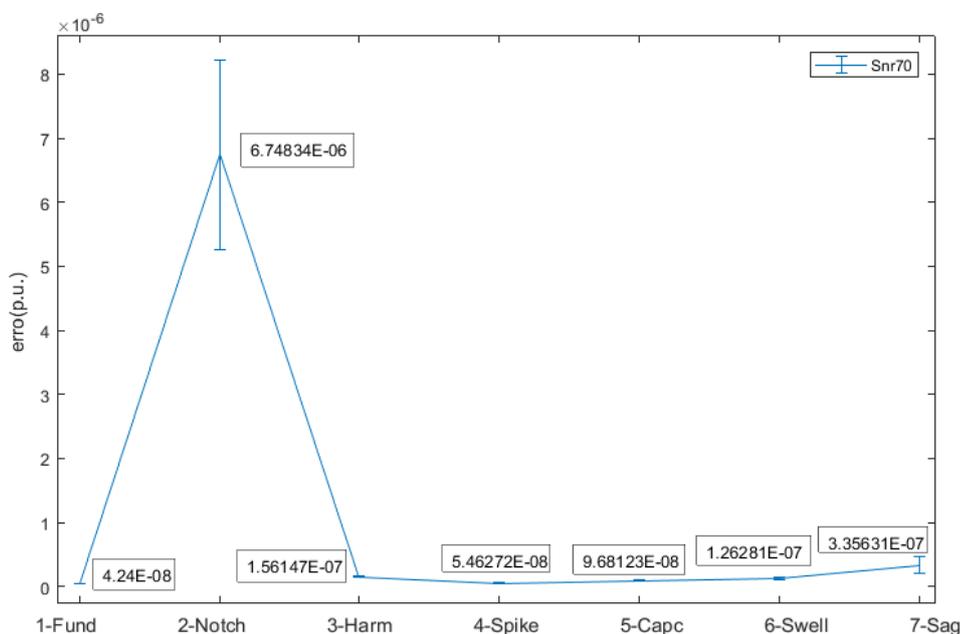
As melhores redes para os distúrbios em ruído 60 dB, 50 dB e 40 dB foram inseridas nas figuras, 7, 6 e 5, presentes no apêndice A.

Para cada classe de distúrbio, um *ensemble* de 10 redes devidamente treinado foi utilizado no classificador. De forma geral, os melhores resultados foram aqueles com a presença de ruído baixo, próximo a 70 dB, apresentando boa significância em relação aos demais, conforme apontou o teste estatístico. Para analisar todas as melhores configuração em cada tipo de ruído (40, 50, 60 e 70 dB) foi realizado o teste de análise de variâncias (*ANOVA*), com resultados sendo ordenados conforme o seu desempenho estatístico. Para validação das redes neurais variou-se também o número de neurônios ocultos com testes em 5, 10, 15, 20, 25 e 30 neurônios e também o número de atrasos, com 3, 7, 16, 32 e por fim 64 atrasos, que corresponde a 1/4 de ciclo do componente fundamental.

A figura 4.4 apresenta o ordenamento das melhores configurações de classificador, conforme os resultados do teste para os distúrbios *notch*, *spike*, *sag*, *swell*, *harmônico*, capacitivo e

também para sinais sem distúrbio. O ordenamento com mais detalhes está contido no apêndice A.

Figura 4.4 – Média e desvio padrão de cada classificador para seu respectivo distúrbio em 70dB.



Fonte: Do autor (2020)

4.2.2 Desempenho do Classificador Neural NAR

A seguir, são apresentados os resultados de desempenho dos melhores classificadores para as faixas de ruído de 70db até 40dB, nas matrizes de confusão 4.5, 4.6, 4.7 e 4.8, conforme o teste ANOVA. Quanto ao número de neurônios, as melhores configurações variaram para cada caso, conforme o ruído dos dados de entrada do classificador. Para cada sinal com distúrbio, foram utilizadas 10.000 amostras de treino e 10.000 amostras para validação com novos dados.

Apesar do classificador apresentar melhor desempenho em ruído 70 dB, em problemas reais é comum que se ocorra variações nas etapas de transmissão e distribuição de energia, conforme a norma IEEE-Std-1159 (2019). Assim, para tornar a simulação mais realística, justifica-se a validação do classificador em diferentes faixas de ruído (40dB, 50dB, 60dB e 70dB).

Como apresentado nas matrizes de confusão, o número de neurônios variou para algumas configurações, bem como o número de atrasos, definidos pelo teste ANOVA, por meio do softwares *SAS Studio* na sua versão universitária, conforme descrito no apêndice B.

Tabela 4.5 – Melhor configuração do classificador operando em ruído 70 dB (acertos em %),

Rede x Distúrbio	Fund	Notch	Har	Spike	Capc	Swell	Sag	Amostras,
RNA Fund.10Neur.	60,17	0,22	19,29	0,72	16,89	0	2,71	64
RNA Notch30Neur.	1,46	94,95	0,91	0,91	1,03	0,10	0,64	64
RNA Har 30Neur.	0,09	0,06	98,63	0,11	0,09	0,02	1,00	64
RNA Spike30Neur.	0,52	0,010	0	97,62	0	0	1,85	64
RNA Capc30Neur.	1,36	0,02	0,57	1,16	94,88	0,01	2,00	64
RNA Swell30Neur.	0,29	0,43	18,90	0,11	1,28	74,06	4,93	7
RNA Sag30Neur.	0,40	0,06	30,04	0,20	0,24	0	69,03	64

Fonte: Do autor (2020)

Tabela 4.6 – Melhor configuração do classificador operando em ruído 60 dB (acertos em %),

Rede x Distúrbio	Fund	Notch	Har	Spike	Capc	Swell	Sag	Amostras,
RNA Fund.20Neur.	46,37	0,77	15,93	0,60	16,88	9,84	9,61	64
RNA Notch 30Neur.	1,45	94,24	0,86	1,01	0,87	0,67	0,90	64
RNA Har 30Neur.	0,38	0,13	92,70	0,19	0,25	4,93	1,42	64
RNA Spike 25Neur.	1,30	0,10	1,79	85,44	0,40	6,45	4,52	64
RNA Capc 10Neur.	3,22	0,20	3,64	1,87	86,30	1,60	3,17	7
RNA Swell 15Neur.	0,49	0,63	17,71	0,36	1,86	72,48	6,47	64
RNA Sag 30Neur.	0,34	1,25	21,62	0,18	0,23	23,57	52,78	64

Fonte: Do autor (2020)

Tabela 4.7 – Melhor configuração do classificador operando em ruído 50 dB (acertos em %),

Rede x Distúrbio	Fund	Notch	Har	Spike	Capc	Swell	Sag	Amostras,
RNA Fund.30Neur.	40,22	0,32	11,32	1,32	16,55	16,24	14,03	64
RNA Notch 30Neur.	1,83	90,49	1,40	1,95	1,89	1,26	1,18	64
RNA Har 25Neur.	1,08	0,48	89,91	0,88	0,53	6,19	0,93	64
RNA Spike 25Neur.	4,48	1,04	3,12	79,73	0,91	9,40	1,32	64
RNA Capc 25Neur.	0,20	4,10	3,68	2,10	84,81	2,55	2,56	32
RNA Swell 25Neur.	1,15	0,89	18,47	2,02	2,51	63,50	11,46	7
RNA Sag 25Neur.	0,78	1,68	23,57	0,72	1,42	24,55	47,25	64

Fonte: Do autor (2020)

O melhor desempenho de classificação quanto ao número de atrasos e neurônios, conforme matriz 4.5, foi de 64 atrasos (1/4 do ciclo do sinal) e de 30 neurônios, respectivamente, que ocorreu na operação do classificador em ruído 70 dB.

Tabela 4.8 – Melhor configuração do classificador operando em ruído 40 dB (acertos em %),

Rede x Distúrbio	Fund	Notch	Har	Spike	Capc	Swell	Sag	Amostras,
RNA Fund.5Neur.	38,23	1,33	11,64	4,47	14,60	15,05	14,68	64
RNA Notch 25Neur.	2,91	82,14	2,19	3,40	3,07	3,04	3,25	64
RNA Har 5Neur.	2,00	0,38	85,39	2,24	2,17	5,94	1,88	64
RNA Spike 20Neur.	4,34	0,20	13,88	55,94	2,72	21,99	0,93	64
RNA Capc 20Neur.	12,32	2,66	10,16	8,75	49,49	8,82	7,80	64
RNA Swell 30Neur.	0,74	0,73	23,24	1,74	1,58	65,25	6,72	16
Sag 10Neur.	1,08	5,77	24,57	2,05	1,39	23,68	41,44	64

Fonte: Do autor (2020)

4.2.3 Discussão

Dentre os resultados do classificador, percebe-se que a RNA detectora de sinais sem distúrbio, que contém apenas a frequência fundamental, apresentou um menor número de acertos em todos os casos. Por outro lado, este problema poderia ser solucionado com o uso do detector NARX apresentado na seção anterior, o que faria com que o número de falsos positivos caísse sobremaneira. Da mesma forma, pelas matrizes de confusão apresentadas, é interessante observar que o número de falsos negativos é pequeno. Normalmente, quando um distúrbio não é classificado corretamente, ele é classificado como outro distúrbio. De forma geral, os distúrbios *sag* e *swell* foram os mais difíceis de serem classificados corretamente, sendo muitas vezes confundidos entre si ou com os distúrbios do tipo harmônicos.

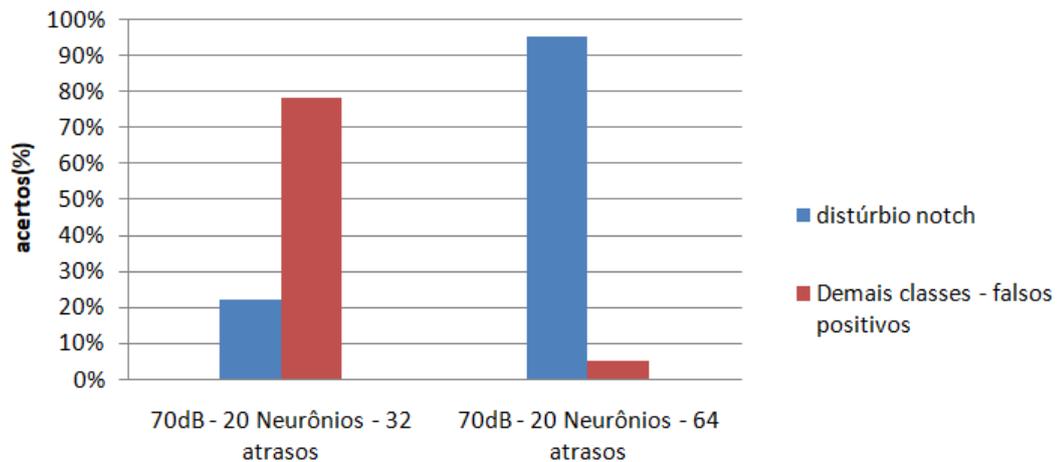
As redes que classificam sinais com distúrbios apresentaram certo grau de assertividade em sinais com ruído baixo, de 70dB, alcançando um número expressivamente maior de classificações em termos percentuais. Para nível de ruído em 70dB, o índice de acerto de classificação geral foi de 84,2% que, para a quantidade de amostras utilizadas, é um resultado promissor para a metodologia proposta neste trabalho.

Em sinais com ruídos maiores, como 50dB e 40dB, o sistema obteve índices de acertos menores. A classificação de distúrbios como afundamento de tensão (*sag*), por exemplo, foi a mais prejudicada considerando todos os classificadores, atingindo acurácia abaixo dos 50%, mostrando que o sistema proposto é mais viável quando o nível de ruído da rede é baixo (60dB ou 70dB).

Outro ponto importante encontrado nos resultados foi em relação ao distúrbio *notch*, em suas configurações de 32 atrasos com 20 neurônios ocultos e com 64 atrasos e 30 neurônios ocultos, ambos em ruído 70db. Conforme apresentado na figura 4.5, mesmo com ambos apre-

sentando erro quadrático médio similar e inferior a 1×10^{-6} em dados de treino, na validação foi possível observar uma piora grande de desempenho na rede de 32 atrasos, com apenas 22% de acertos na validação. Enquanto a rede *notch* em 64 atrasos demonstrou melhor capacidade de generalização com novos dados, com aproximadamente 95% de acerto e 5% de erro nas amostras. Isso mostra que a escolha da configuração da rede influencia bastante nos resultados e essa escolha deve ser realizada de forma criteriosa.

Figura 4.5 – Comparação do desempenho do classificador de distúrbio *notch* com diferentes configurações, em dados de validação.



Fonte: Do autor (2020)

Quanto ao distúrbio as redes do transitório oscilatório (capacitivo), notoriamente, apresentaram um falso positivo em relação ao sinal sem distúrbio, com o fato de se tornando evidente, com falsos acertos em ruído 70 dB, 60 dB, e 50 dB de 16,89%, 16,88% e 16,55% de acertos, respectivamente. O fato também ocorreu em relação às redes dos distúrbios harmônicos, que apresentaram falsos positivos para os distúrbios *sag* e *swell*, de 30,04% e 18,9%, respectivamente, em ruído 70 dB e reduzindo levemente os falsos acertos nos demais níveis de ruído.

5 CONCLUSÃO

Neste trabalho foram propostos um detector e um classificador de distúrbios de qualidade de energia, inspirados em modelos NARX neurais. A partir da análise dos resíduos destes modelos, foi possível detectar e classificar variados tipos de distúrbios de forma rápida e com boa assertividade na classificação, utilizando poucas amostras do sinal de tensão.

Os sistemas propostos nesta pesquisa (detecção e classificação) foram testado em situações cuja frequência da componente fundamental do sinal oscilava em intervalos de 58Hz - 62Hz, com diferentes relações sinal-ruído (40dB até os 70db). No detector, exceto a elevação e o afundamento de tensão, em todos os outros distúrbios e sinal nominal, a abordagem apresentada obteve resultados satisfatórios levando em conta a análise de até 6 amostras do sinal contendo o distúrbio. Para os afundamentos e elevações de tensão a detecção ocorreu a partir de 20 e 40 amostras, nas quais atingiram sua melhor acurácia, sendo ainda avaliadas como detecções rápidas visto ter sido necessário menos de 1/4 de ciclo para a detecção.

O classificador conseguiu resultados satisfatórios operando com um baixo nível de ruído. O intervalo limite de operação foi de 64 amostras (1/4 do ciclo). A assertividade média foi de 84,2% para os distúrbios em ruído 70dB (nível mais baixo de ruído), 75,8% em 60dB, 70,8% em 50dB e 59,7% em 40dB (nível mais alto de ruído).

Um grande avanço neste trabalho foi em relação ao tempo de detecção, que foi de até 6 amostras em grande na maioria dos distúrbios, com alguns chegando a 100% de detecção com apenas uma amostra de sinal. Tendo em vista pesquisas recentes como Ribeiro et al. (2018) e Mendes et al. (2017) por exemplo, que conseguiram realizar a detecção rápida dos distúrbios utilizando 256 amostras de sinal, o método inédito proposto nesta pesquisa, que utiliza entre 1 e 6 amostras é muito interessante para aplicações e estudos em pesquisas relacionadas a detecção de faltas, área em que o tempo de detecção faz muita diferença.

5.1 Perspectivas

A discrepância de velocidade entre o detector (acertos em 6 amostras) e o classificador (acertos em 64 amostras), justificaria em um teste futuro, o detector realizando uma pré-seleção de amostras, graças à sua rapidez, descartando falsos positivos no classificador, como os que ocorreram entre as redes dos distúrbios capacitivos para sinais sem distúrbio ou das redes dos harmônicos para sinais contendo *sags* e *swells*. O classificador, por sua vez, operaria conjuntamente, após o detector, em até 1/4 de ciclo do sinal, definindo qual a classe de distúrbio estaria

presente no sinal de tensão da rede. Esse trabalho conjunto poderia aumentar bastante a acurácia dos sistemas de classificação e detecção, como uma ferramenta para sua otimização.

Além disso, busca-se aprimorar, entre outros, o método de filtragem da fundamental do detector, para isso, em testes futuros, se prevê a utilização do *phase locked loop* (PLL) no lugar do filtro *notch* para a atenuação de frequências variando próximo aos 60Hz. Poderiam também, no detector serem feitos testes para medir o seu desempenho na localização de possíveis faltas na rede, tendo em vista sua velocidade de detecção em poucas amostras de sinal.

Os dados são outro ponto das abordagens futuras desta pesquisa. Tendo em vista a necessidade de validar este método com problemas práticos, busca-se nos próximos testes utilizar banco de dados reais para mensurar o desempenho dos sistemas tanto de classificação quanto de detecção.

Quanto aos classificadores, foram observados magnitudes de erros típicas de cada um, conforme o distúrbio. Nos próximos testes, esses erros poderiam ser utilizados como limiar de decisão para determinar se a janela dos dados possui tais distúrbios. Os resultados com um todo, superaram as expectativas dos autores para distúrbios invariantes no tempo, todavia, para trabalhos futuros, busca-se um aprofundamento também no desempenho nos distúrbios variantes no tempo, para testar a eficácia do método proposto.

Por fim, nos próximos testes do classificador, pretende-se utilizar múltiplas classes de distúrbios, diferindo do modelo atual, onde se trabalha com apenas um tipo de distorção a cada operação. Essa melhoria poderia aumentar a abrangência do sistema de classificador e reduzir o custo computacional, com a possível redução do número de operações do classificador.

REFERÊNCIAS

- AGUIRRE, L. A. **Introdução à identificação de sistemas: Técnicas lineares e não-lineares aplicadas a sistemas reais**. [S.l.]: Editora UFMG, 2007. 730 p. ISBN 9788570415844.
- AGUIRRE, L. A.; CORREA, M. V.; CASSINI, C. C. da S. Nonlinearities in NARX polynomial models: representation and estimation. **IEE Proceedings - Control Theory and Applications**, v. 149, n. 4, p. 343–348, July 2002.
- AMARIPADATH, D. et al. Power quality disturbances on smart grids: Overview and grid measurement configurations. In: **2017 52nd International Universities Power Engineering Conference (UPEC)**. [S.l.: s.n.], 2017. p. 1–6.
- ARRUDA, E. F. d. **Análise de distúrbios relacionados com a qualidade da energia elétrica utilizando a transformada Wavelet**. 121 p. Tese (Doutorado) — Universidade de São Paulo, 2003.
- BARBOSA, B. H. G.; FERREIRA, D. D. Classification of multiple and single power quality disturbances using a decision tree-based approach. **Journal of Control, Automation and Electrical Systems**, v. 24, n. 5, p. 638–648, Oct 2013.
- BOARD, I. S. Ieee recommended practice for monitoring electric power quality. **IEEE Standards Board**, p. 1, 1995.
- BOLLEN, M. H.; GU, I. Y. **Signal processing of power quality disturbances**. [S.l.]: John Wiley and Sons, 2006. v. 30.
- CAI, D. et al. A highly accurate and fast power quality disturbances classification based on dictionary learning sparse decomposition. **Transactions of the Institute of Measurement and Control**, v. 41, n. 1, p. 145–155, 2019.
- COMMUNICATION, I. E. technical. **Electromagnetic environment for low-frequency conducted disturbances and signalling in public power supply systems**. Genebra, Suica, 1990. v. 1.
- FERREIRA, D. D. **Análise de Distúrbios Elétricos em Sistemas de Potência**. 121 p. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2010.
- GEVERS, M. Identification for control: From the early achievements to the revival of experiment design. **European journal of control**, Elsevier, v. 11, p. 335–352, 2005.
- GHOSH, A.; LEDWICH, G. **Power quality enhancement using custom power devices**. [S.l.]: Springer Science and Business Media, 2012.
- HAYKIN, S. **Redes Neurais: Princípios e Prática**. [S.l.]: Artmed, 2007. ISBN 9788577800865.
- HOPFIELD, J. J.; TANK, D. W. Neural computation of decisions in optimization problems. **Biological Cybernetics**, v. 52, p. 11, Jul 1985.
- IEEE-STD-1159. Ieee recommended practice for monitoring electric power quality. **IEEE**, p. 1–98, 2019.
- LIU, H. et al. Complex power quality disturbances classification via curvelet transform and deep learning. **Electric Power Systems Research**, v. 163, p. 1 – 9, 2018. ISSN 0378-7796.

MAIA, R. M. **Caracterizacao das Variacoes de Tensao de Curta Duracao e seus Impactos em uma Planta da Industria Alimenticia**. 85 p. Tese (Doutorado) — Universidade Federal de Minas Gerais, 2011.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115–133, Dec 1943.

MENDES, T. M. et al. Detection of power quality disturbance using a multidimensional approach in an embedded system. **IEEE Latin America Transactions**, v. 17, n. 07, p. 1102–1108, 2019.

MENDES, T. M. et al. **Monitoramento multidimensional de qualidade de energia elétrica para Smart Grids**. 66 p. Dissertação (Mestrado) — Universidade Federal de Lavras, 2017.

MITRA, S. K.; KUO, Y. **Digital signal processing: a computer-based approach**. [S.l.]: McGraw-Hill New York, 2006. v. 2.

MOHAN, N.; SOMAN, K.; RAVI, V. Deep power: Deep learning architectures for power quality disturbances classification. In: **2017 International Conference on Technological Advancements in Power and Energy (TAP Energy)**. [S.l.: s.n.], 2017. p. 1–6.

NAGATA, E. A. et al. Voltage sag and swell detection and segmentation based on independent component analysis. **Electric Power Systems Research**, v. 155, p. 274–280, 2018.

OLIVEIRA, A. d. Redes neurais artificiais aplicadas na detecção, classificação e localização de defeitos em linhas de transmissão. **UFJF. Juiz de Fora**, 2005.

PAES, Â. T. Por dentro da estatística. **Einstein: Educ. Contin. Saúde**, v. 6, p. 107–108, 2008.

RAFIQ, M.; BUGMANN, G.; EASTERBROOK, D. Neural network design for engineering applications. **Computers & Structures**, v. 79, n. 17, p. 1541 – 1552, 2001. ISSN 0045-7949.

RIBEIRO, E. G. et al. Real-time system for automatic detection and classification of single and multiple power quality disturbances. **Measurement**, v. 128, p. 276–283, 2018.

RIBEIRO, M. V.; PEREIRA, J. L. R. Classification of single and multiple disturbances in electric signals. **EURASIP Journal on Advances in Signal Processing**, n. 2, p. 1, Jul 2007.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386—408, November 1958. ISSN 0033-295X.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning internal representations by error propagation**. [S.l.], 1985.

SOHLBERG, B. Grey box modelling. In: _____. **Supervision and Control for Industrial Processes: Using Grey Box Models, Predictive Control and Fault Detection Methods**. London: Springer London, 1998. p. 7–43. ISBN 978-1-4471-1558-8.

STHLE, L.; WOLD, S. Analysis of variance (anova). **Chemometrics and Intelligent Laboratory Systems**, v. 6, n. 4, p. 259 – 272, 1989. ISSN 0169-7439.

THIRUMALA, K. et al. Tunable q wavelet transform and dual multiclass svm for online automatic detection of power quality disturbances. **IEEE Transactions on Smart Grid**, v. 9, n. 4, p. 3018–3028, 2018.

TOMIC, J.; KUSLJEVIC, M.; VUJICIC, V. A new power system digital harmonic analyzer. **IEEE Transactions on Power Delivery**, v. 22, p. 772–780, May 2007.

TORO-VIZCARRONDO, C.; WALLACE, T. D. A test of the mean square error criterion for restrictions in linear regression. **Journal of the American Statistical Association**, [American Statistical Association, Taylor & Francis, Ltd.], v. 63, n. 322, p. 558–572, 1968. ISSN 01621459.

UTKARSH, S.; SINGH, S. N. Optimal feature selection via nsga-ii for power quality disturbances classification. **IEEE Transactions on Industrial Informatics**, v. 14, n. 7, p. 2994–3002, 2018.

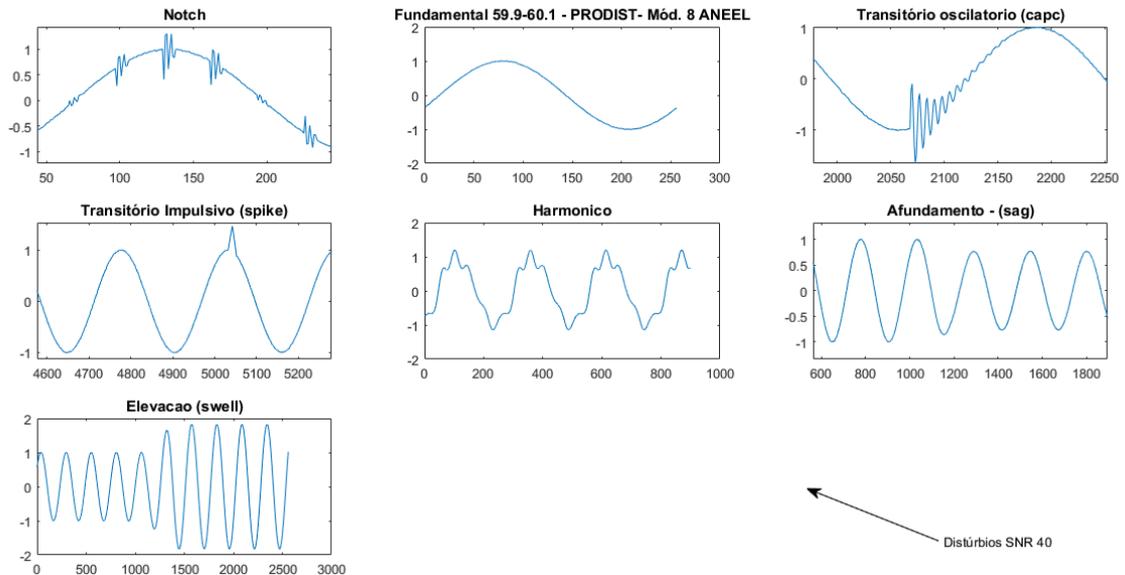
WARD, D. J. et al. Power quality-two different perspectives. **IEEE Transactions on Power Delivery**, v. 5, n. 3, p. 1501–1513, July 1990. ISSN 0885-8977.

YILMAZ, I.; KAYNAR, O. Multiple regression, ann rbf, mlp and anfis models for prediction of swell potential of clayey soils. **Expert Systems with Applications**, v. 38, n. 5, p. 5958 – 5966, 2011.

APÊNDICE A – Banco de dados Sintéticos e gráficos de erros

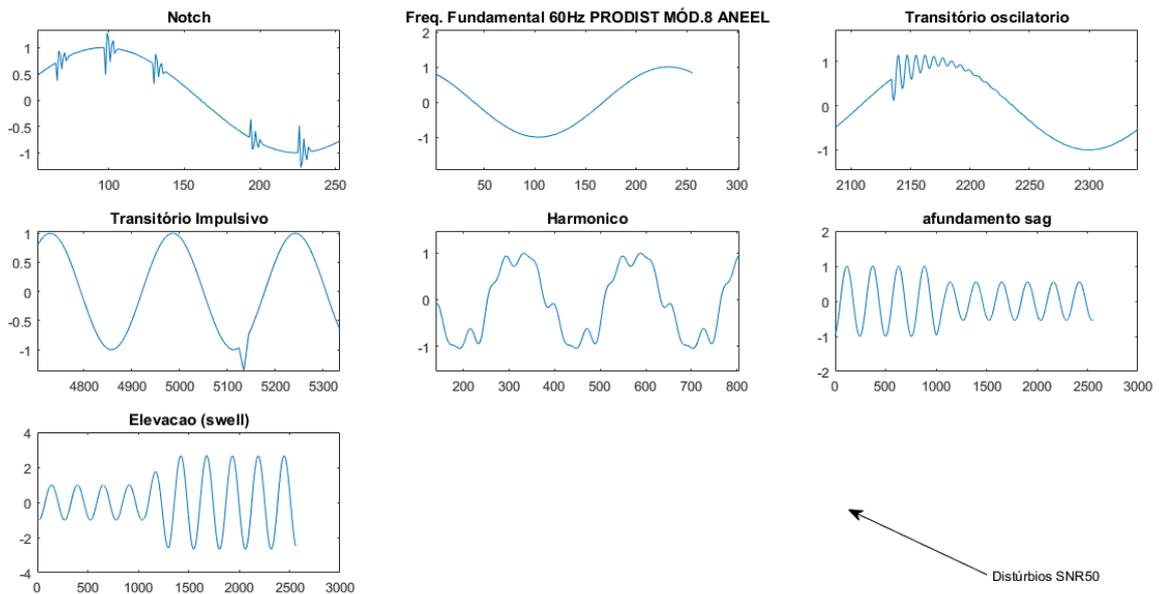
As figuras a seguir representam o banco de dados sintético dos distúrbios em cada um dos níveis de ruído trabalhados (40, 50, 60 e 70dB).

Figura 1 – Banco de dados sintéticos em ruído gaussiano branco de 40db.



Fonte: Autor (2020)

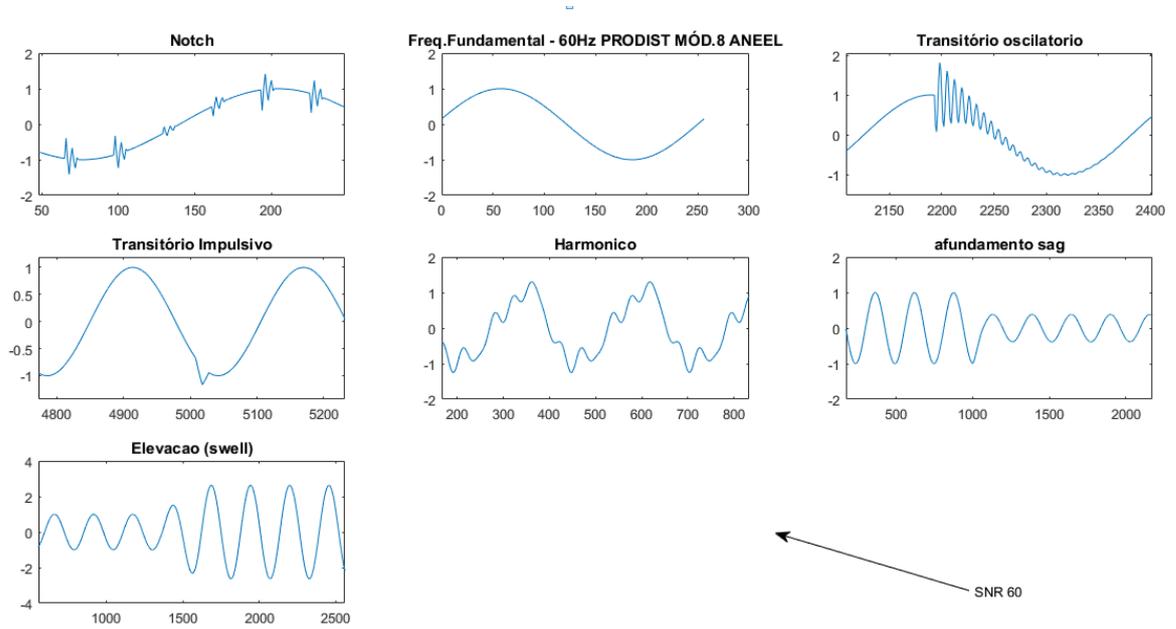
Figura 2 – Banco de dados sintéticos em ruído gaussiano branco de 50db.



Fonte: Autor (2020)

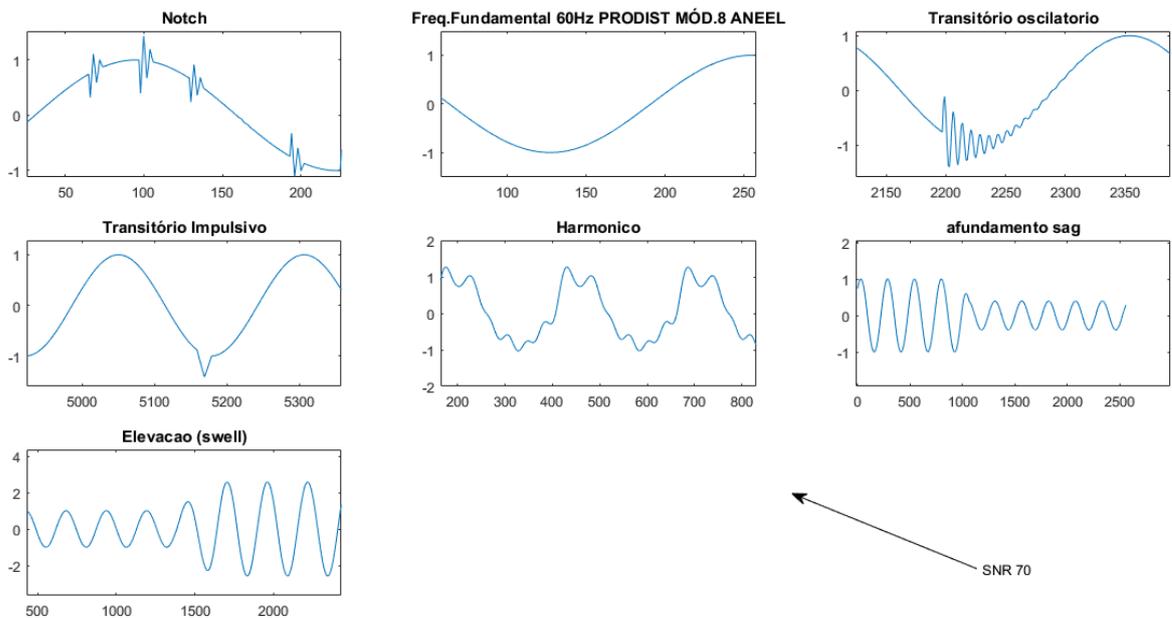
As médias de erro e desvio padrão para o classificador são descritas nas figuras 5 a 7.

Figura 3 – Banco de dados sintéticos em ruído gaussiano branco de 60db.



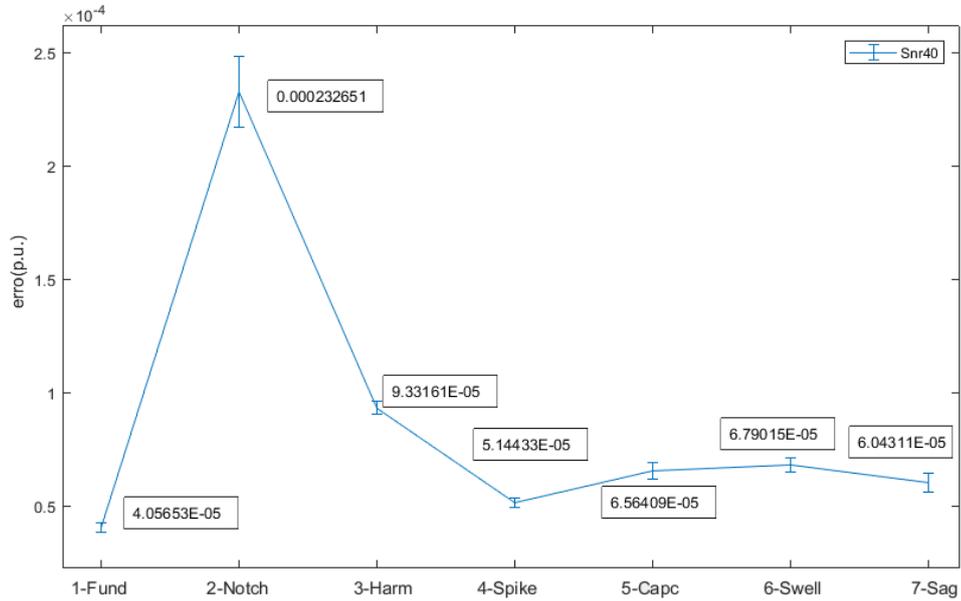
Fonte: Autor (2020)

Figura 4 – Banco de dados sintéticos em ruído gaussiano branco de 70db.



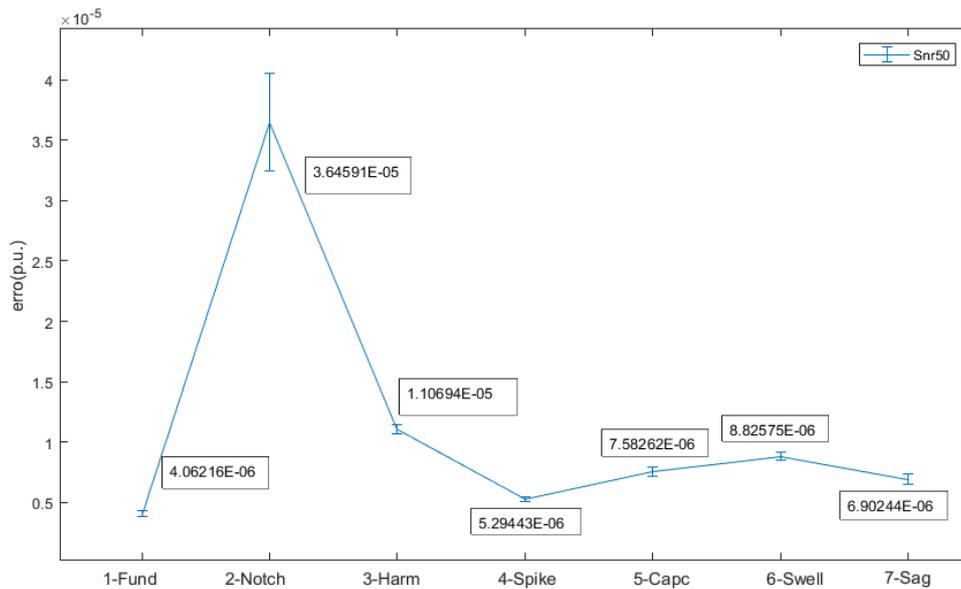
Fonte: Autor (2020)

Figura 5 – Média e desvio padrão de cada classificador para seu respectivo distúrbio em 40dB.



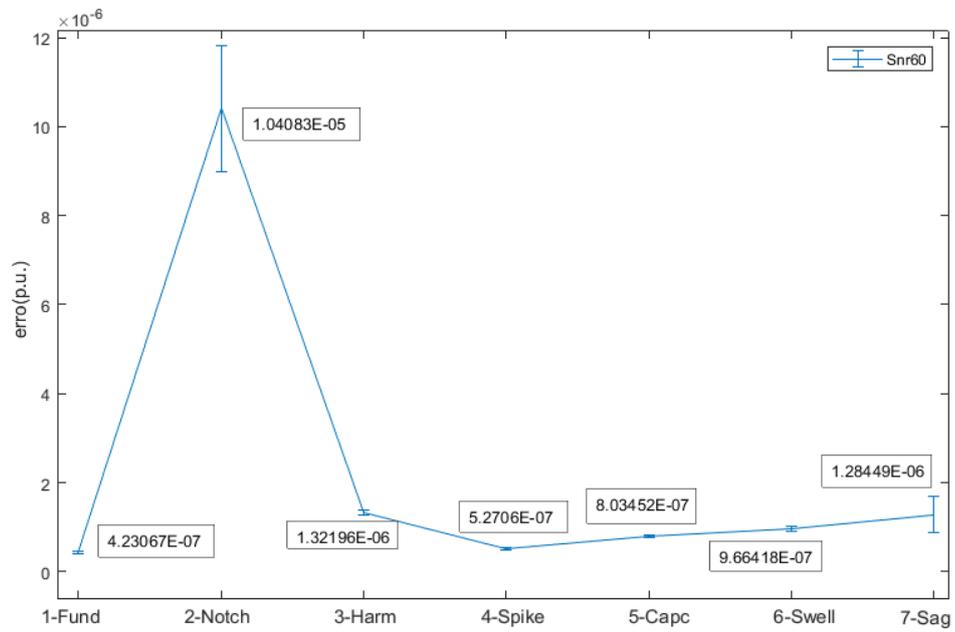
Fonte: Autor (2020)

Figura 6 – Média e desvio padrão de cada classificador para seu respectivo distúrbio em 50dB



Fonte: Autor (2020)

Figura 7 – Média e desvio padrão de cada classificador para seu respectivo distúrbio em 60dB.



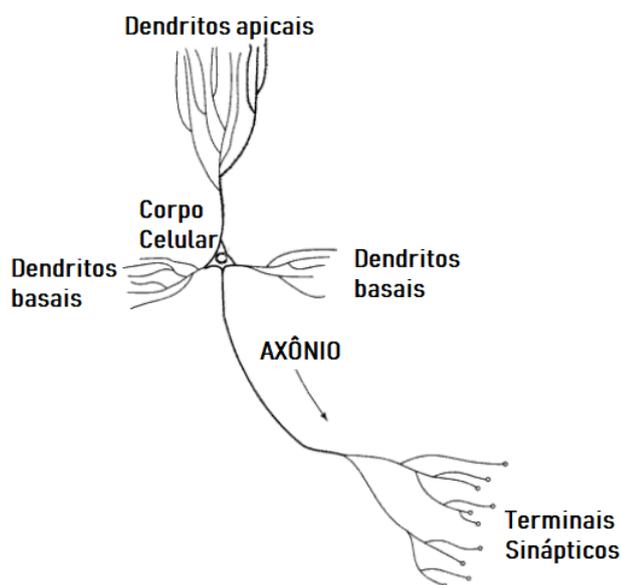
Fonte: Autor (2020)

APÊNDICE B – Redes Neurais Artificiais (RNAs)

Conceitos básicos das RNAs

As redes neurais artificiais são ferramentas de inteligência computacional bioinspiradas no funcionamento dos neurônios e redes neurais biológicas (MCCULLOCH; PITTS, 1943). No modelo biológico, os sinais são recebidos nos dendritos por meio de impulsos elétricos ligados a fenômenos químicos, são processados pelo núcleo da célula no corpo celular e, para transmissão, são enviados para os axônios que utilizam os terminais sinápticos para repassar as informações a outros neurônios, conforme a figura 8 (HAYKIN, 2007).

Figura 8 – Modelo de Neurônio Biológico



Fonte: Adaptado de (HAYKIN, 2007)[p.34]

Já os modelos computacionais das redes neurais artificiais (RNAs) são compostos por neurônios artificiais e, trabalhando com treinamento em conjunto, formam as redes neurais que possuem boa capacidade para resolução de problemas (HOPFIELD; TANK, 1985). Entre os tipos de atividades comuns designadas para RNAs estão a classificações de dados, as previsões baseadas em séries temporais e regressões, tanto lineares quanto principalmente não-lineares (YILMAZ; KAYNAR, 2011; HAYKIN, 2007).

Estrutura de uma Rede Neural Simples

A primeira arquitetura conhecida de uma rede neural artificial, o *perceptron* simples, foi descrita por (ROSENBLATT, 1958) como uma rede de n -ésimas entradas em x , multiplicadas pelos seus respectivos pesos sinápticos ω , que são variáveis que definem a importância de cada entrada x . Para que o neurônio possa entrar em operação, tanto o modelo biológico como em

um neurônio artificial, existe o limiar de ativação b que, ao receber as entradas, ativa o neurônio, com esse valor sendo denominado na literatura como *bias* (HAYKIN, 2007). Assim, o modelo matemático de uma rede neural tipo *perceptron* de Rosenblatt é descrito por:

$$y = \phi(u + b), \quad (1)$$

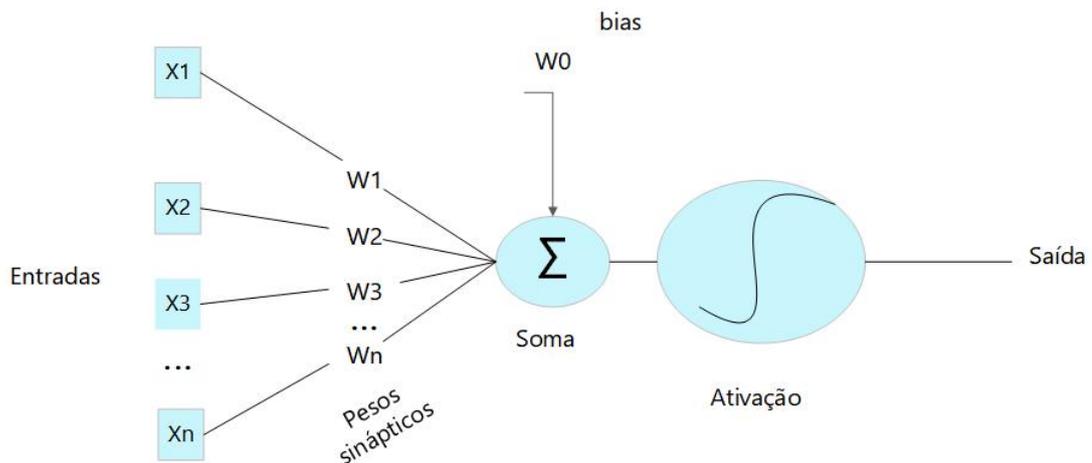
com

$$u = \sum_{j=1}^n \omega_j x_j, \quad (2)$$

sendo n o número de entradas da rede

A figura 9 ilustra o modelo de RNA simples, do tipo perceptron.

Figura 9 – Rede Neural Simples: *Perceptron* de Rosemblat



Fonte: Adaptado de ROSENBLATT (1958)

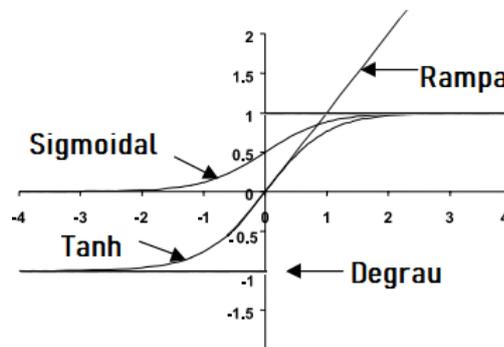
Ativação dos neurônios artificiais

A ativação é a atividade do neurônio artificial que permite a operação e entrega dos resultados em valores que o neurônio pode trabalhar, ou seja, entre 0 a 1 ou de -1 a 1. Dados convertidos nessa escala podem ser inseridos no neurônio e são chamados *normalizados*. Em cada neurônio, há um operador de soma, que é matematicamente definido pela média ponderada entre entradas de dados - figura9) somada a um valor empírico chamado *bias*, que basicamente é processo que reúne todos os dados do problema para ativar o neurônio. Os dados somados atingem o limiar de ativação do neurônio o mesmo entra em operação, processando e entregando os resultados em sua saída. Assim, como a saída do neurônio depende dos dados de entrada, cabe ressaltar a importância de se atribuir pesos numéricos a cada entrada conforme sua rele-

vância, para melhorar o resultado final de acordo com as necessidade do problema. (RAFIQ; BUGMANN; EASTERBROOK, 2001; OLIVEIRA, 2005).

Conforme (RAFIQ; BUGMANN; EASTERBROOK, 2001), em problemas lineares e inteiros, geralmente com saídas binárias, se utiliza a função degrau que pode ser de -1 a 1, já para saídas lineares que variam entre -1 e 1, pode ser utilizada a saída em rampa. Para os problemas não lineares, se admite usar a função sigmoideal se o intervalo for de 0 a 1, ou a função tangente hiperbólica (*tanh*), com saídas variando entre -1 e 1, conforme a figura 10.

Figura 10 – Tipos de funções de ativação utilizadas na camada de saída das redes neurais



Fonte: Adaptado de(RAFIQ; BUGMANN; EASTERBROOK, 2001)[p.1544]

As equações 3, 4, 5 e 6 representam os modelos de função de ativação degrau, rampa, sigmoideal e tangente hiperbólica, respectivamente, com a saída normalizada y em função da entrada normalizada x :

$$\begin{cases} y < 0, & y = -1 \\ x \geq 0, & y = 1 \end{cases} \quad (3)$$

$$\begin{cases} x < 0 & y = 0 \\ 0 \leq x \leq 1 & y = x \\ x > 1 & y = 1 \end{cases} \quad (4)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

Treinamento Supervisionado

O treinamento de uma rede neural artificial na maioria dos casos é realizado de forma supervisionada, ou seja, com um agente realizando a modificação de suas variáveis de forma a ajustar os pesos sinápticos das entradas e o valor do *bias* para minimizar o erro de predição ou classificação da rede (HAYKIN, 2007). Todavia, a rede também pode ser treinada de forma não supervisionada, onde não há um supervisor para definir os pesos de acordo com a função erro da rede.

Arquitetura da Rede

Em geral a maior parte das redes neurais são treinadas de forma supervisionada. Normalmente, o sentido do fluxo de processamento de dados desse tipo de rede é sempre da camada de entrada em direção à camada de saída, com os neurônios interconectados, fazendo da rede, um modelo *feedforward* (HAYKIN, 2007).

Algoritmo de treino *backpropagation*

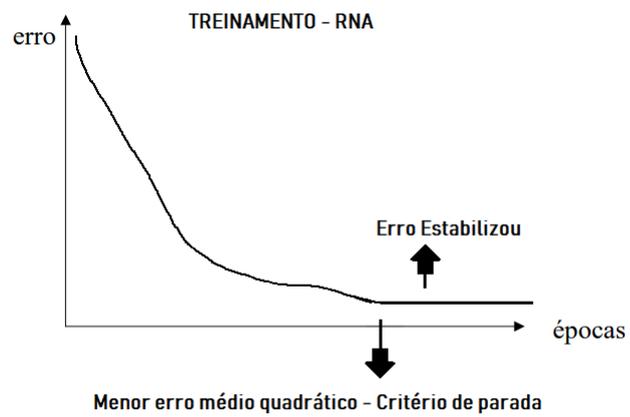
Para ajuste dos pesos da rede neural, o algoritmo *backpropagation* é bastante utilizado. Este algoritmo é capaz de realizar a retropropagação dos erros em cada camada para então ajustar os pesos da rede de forma a reduzir alguma métrica de erro, como o caso do erro médio quadrático (EMQ). Por meio do erro médio quadrático, é possível, por exemplo, definir o critério de parada da rede. Conforme o erro da rede diminui em dados de treino, chega um momento que ele começa a subir considerando dados de validação (dados não conhecidos ou utilizados pela rede durante seu treinamento), tal momento indica possivelmente um início de sobreparametrização da rede, sendo importante a finalização da etapa de ajuste de seus parâmetros (HAYKIN, 2007). Graficamente, é possível observar outro critério de parada para uma rede neural, por exemplo, utilizando a estagnação do erro médio quadrático durante o treino da rede, conforme detalhado na figura 11

O erro médio quadrático de uma rede neural artificial é expresso por:

$$EMQ = \frac{1}{N} \sum_{i=1}^N (y(i) - \hat{y}(i))^2 \quad (7)$$

em que o erro quadrático representa a subtração entre o valor de saída y real e o valor obtido pelo estimador \hat{y} , com N igual ao número de amostras.

Figura 11 – Erro médio quadrático EMQ e critério de parada



Fonte: Adaptado de (HAYKIN, 2007)