

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
FACULDADE DE ENGENHARIA  
CÂMPUS DE ILHA SOLTEIRA**

**LUCAS HENRIQUE DOS SANTOS**

**REDE NEURAL ARTMAP-FUZZY APLICADA A DETECÇÃO DE  
FALHAS ESTRUTURAIS EM ENGRENAGENS**

**Ilha Solteira  
2023**

**LUCAS HENRIQUE DOS SANTOS**

**REDE NEURAL ARTMAP-FUZZY APLICADA A DETECÇÃO DE  
FALHAS ESTRUTURAIS EM ENGRENAGENS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica, Universidade Estadual Paulista “Júlio de Mesquita Filho” – UNESP, Faculdade de Engenharia de Ilha Solteira – SP, como requisito à obtenção do título de Mestre em Engenharia Mecânica. Área de concentração: Mecânica dos Sólidos.

Prof. Dr. Fabio Roberto Chavarette  
**Orientador**

Ilha Solteira  
2023

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

S237r Santos, Lucas Henrique dos.  
Rede neural ARTMAP-fuzzy aplicada a detecção de falhas estruturais em engrenagens / Lucas Henrique dos Santos. -- Ilha Solteira: [s.n.], 2023  
61 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Mecânica dos Sólidos, 2023

Orientador: Fabio Roberto Chavarette  
Inclui bibliografia

1. Redes neurais artificiais. 2. ARTMAP-Fuzzy. 3. Detecção de falhas.

## CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Rede Neural ARTMAP-FUZZY aplicada a Detecção de Falhas Estruturais em Engrenagens

**AUTOR: LUCAS HENRIQUE DOS SANTOS**

**ORIENTADOR: FABIO ROBERTO CHAVARETTE**

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Mecânica, área: Mecânica dos Sólidos pela Comissão Examinadora:

  
Fabio Roberto  
Chavarette:15473115845  
Assinado de forma digital por Fabio Roberto Chavarette:15473115845  
Dados: 2023.01.31 10:44:26 -03'00'  
Prof. Dr. FABIO ROBERTO CHAVARETTE (Participação Virtual)  
Departamento de Engenharia, Física e Matemática / Instituto de Química de Araraquara - UNESP

Prof. Dr. ROBERTO OUTA (Participação Virtual)   
Faculdade de Tecnologia Professor Fernando Amaral de Almeida Prado / Faculdade de Tecnologia de Araçatuba, FATEC

**31 de janeiro de 2023**

Profa. Dra. ERICA REGINA FILLETTI NASCIMENTO (Participação Virtual)  
IQ / UNESP/Araraquara (SP)

Documento assinado digitalmente  
 ERICA REGINA FILLETTI NASCIMENTO  
Data: 31/01/2023 10:48:52-0300  
Verifique em <https://verificador.iti.br>

Ilha Solteira, 31 de janeiro de 2023

## RESUMO

Estudou-se o desenvolvimento de um sistema inteligente utilizando redes neurais artificiais, para o monitoramento de falhas estruturais. Simulou-se em uma bancada experimental o comportamento de um motor com engrenagens em estado normal ou com algum estresse para exemplificar falhas no decorrer do experimento. E para a análise, identificação e caracterização dos dados, foi utilizado uma rede neural do tipo ARTMAP-Fuzzy. A principal aplicação deste sistema é inspecionar a estrutura da bancada objetivando sua melhor conservação e gerando informações para análise de futuras falhas. Os resultados obtidos na aplicação da rede neural ao problema especificado mostraram-se ser significativos.

**Palavras-chaves:** redes neurais artificiais; ARTMAP-*fuzzy*; detecção de falhas.

## **ABSTRACT**

The development of an intelligent system using artificial neural networks was studied to monitor structural failures. The behavior of a motor with gears in normal state or with some stress was simulated in an experimental bench to exemplify failures during the experiment. And for the analysis, identification and characterization of the data, an ARTMAP-Fuzzy neural network was used. The main application of this system is to inspect the structure of the bench aiming at its better conservation and generating information for the analysis of future failures. The results obtained in the application of the neural network to the specified problem proved to be significant.

**Keywords:** artificial neural networks; fuzzy ARTMAP; structural health monitoring.

## LISTA DE FIGURAS

Figura 1 - Desenho esquemático de duas engrenagens com dentes acoplados .....	14
Figura 2 - Interferência entre os dentes pinhão-engrenagem .....	15
Figura 3 - Força de Excitação em relação a Amplitude, Direção e Posição .....	16
Figura 4 - Sistema Dinâmico com massa-mola-amortecedor .....	17
Figura 5 - Movimento Harmônico Simples .....	17
Figura 6 - Diagrama de Corpo Livre .....	18
Figura 7 - Bloco de Diagrama de DSP .....	20
Figura 8 - Processamento de Sinal de um Determinado Sistema com um operador	20
Figura 13 – Neurônio biológico.....	26
Figura 14 – Componentes de um neurônio artificial. ....	27
Figura 15 – Modelo não linear de um neurônio. ....	28
Figura 16 – (a) Função de limiar. (b) Função linear por partes. (c) Função sigmoide para parâmetro de inclinação a variável.....	30
<i>Figura 17 – Disposição de uma rede neural artificial.....</i>	<i>32</i>
Figura 18 – Rede Neural Artificial ARTMAP-Fuzzy. ....	42
Figura 19 – Fluxograma da rede neural ARTMAP-Fuzzy.....	44
Figura 20 - Rede neural ARTMAP Fuzzy .....	47
Figura 17 – Funcionamento do SHM utilizando a rede ARTMAP-Fuzzy.....	49
Figura 18 - Rotor com Engrenagens Acopladas.....	49
Figura 19 - Posicionamento dos Sensores MPU6050.....	50
Figura 20 - Sinal de Vibração de 4Hz.....	51

## LISTA DE TABELAS

Tabela 1 - Sinais presentes na base de dados. ....	51
Tabela 2 - Quantidade de amostras utilizadas no treinamento e diagnóstico. ....	52

## LISTA DE ABREVIATURAS

ART	=	<i>Adaptive Resonance Theory</i>
BAM	=	<i>Bidirectional Associative Memory</i>
CI	=	Computação Inteligente
CNM	=	<i>Combinatorial Neural Model</i>
CPN	=	<i>Counterpropagation Network</i>
IA	=	Inteligência Artificial
NDE	=	<i>Nondestructive Evaluation</i>
RBFN	=	<i>Radial Basis Function Network</i>
RNA	=	Redes Neurais Artificiais
SHM	=	<i>Structural Health Monitoring</i>
SOM	=	<i>Self Organizing Map</i>
SVM	=	<i>Support Vector Machines</i>

## LISTA DE SÍMBOLOS

$X_n$	=	Entradas em um neurônio artificial.
$\varphi(.)$	=	Função não linear de ativação da saída do neurônio artificial.
$w_{kj}$	=	Pesos sinápticos.
$\Sigma$	=	Combinador linear.
$b_k$	=	Bias.
$V_k$	=	Potencial de ativação.
$Y_k$	=	Sinal de saída de um neurônio artificial.
$\alpha$	=	Parâmetro de escolha da categoria.
$\beta$	=	Taxa de treinamento.
$\rho_a$	=	Parâmetro de vigilância do módulo ARTa.
$\rho_b$	=	Parâmetro de vigilância do módulo ARTb.
$\rho_{ab}$	=	Parâmetro de vigilância do módulo Inter-ART.

## SUMÁRIO

1	INTRODUÇÃO .....	11
2	ENGRENAGENS.....	14
3	SISTEMAS DINÂMICOS E VIBRAÇÃO.....	17
3.1	Análise Digital de Sinal .....	19
4	REDES NEURAIS ARTIFICIAIS .....	23
4.1	Resumo Histórico .....	23
4.2	Neurônio Biológico.....	25
4.3	Neurônio Artificial.....	27
4.3.1	Funções de Ativação .....	30
4.4	Arquitetura das Redes Neurais Artificiais .....	31
4.5	Treinamento da Rede Neural .....	33
4.6	Tipos de Redes Neurais Artificiais.....	34
4.7	Benefícios das Redes Neurais Artificiais .....	36
4.8	Aplicações das Redes Neurais Artificiais.....	37
5	TEORIA DA RESSONÂNCIA ADAPTATIVA.....	38
5.1	Rede Neural ART .....	38
5.1.1	Rede Neural ART-1 .....	40
5.1.2	Rede Neural ARTMAP- <i>Fuzzy</i> .....	41
5.1.3	Algoritmo ARTMAP- <i>Fuzzy</i> .....	42
6	LÓGICA NEBULOSA.....	45
6.1	Principais conceitos.....	45
6.2	Breve Histórico .....	45
6.3	Fusão com Redes Neurais .....	46
7	Desenvolvimento e Simulação Computacional .....	48
7.1	Materiais e Métodos.....	48
7.2	Sistema de Monitoramento e Diagnóstico de Falhas Estruturais .....	48

<b>7.3</b>	<b>Experimento .....</b>	<b>49</b>
<b>7.3.1</b>	<b>Aleatoriedade .....</b>	<b>51</b>
<b>7.3.2</b>	<b>Treinamento do sistema.....</b>	<b>52</b>
<b>7.3.3</b>	<b>Classificação do sistema .....</b>	<b>53</b>
<b>8</b>	<b>Aplicações e resultados.....</b>	<b>54</b>
<b>8.1</b>	<b>Parâmetros utilizados.....</b>	<b>54</b>
<b>8.2</b>	<b>RESULTADOS .....</b>	<b>55</b>
<b>9</b>	<b>CONCLUSÃO.....</b>	<b>56</b>
	<b>REFERÊNCIAS .....</b>	<b>57</b>

## 1 INTRODUÇÃO

A prevenção de falhas em componentes mecânicos surgiu desde as primeiras construções das estruturas de engenharia. Inicialmente, esta prevenção era feita de forma empírica e a solução para tais casos era devido à escolha certa do material e da forma do elemento estrutural. Portanto, a necessidade de desenvolver métodos eficazes para a detecção de falhas cresceu no decorrer dos anos (PASTOUKHOV; VOORWALD, 1995).

Os métodos para a detecção de falhas baseiam-se no fato de que os parâmetros modais (frequências, amortecimento e formas modais) representam funções das propriedades físicas da estrutura (massa, amortecimento e rigidez). Portanto, quando estas propriedades físicas sofrem alguma alteração, por exemplo, a redução de rigidez, as propriedades modais apresentarão alterações detectáveis. (SASMAL; RAMANJANEYULU, 2009).

Ao longo dos anos temos observados diversas mudanças nas indústrias e principalmente a evolução de diferentes tecnologias, gerando novas formas de trabalho com maior eficiência. A adoção de novas tecnologias nas indústrias é considerada a indústria 4.0, que utiliza sistemas ciberfísicos, internet das coisas, computação na nuvem, robótica, inteligência artificial, biotecnologia, entre outras (CHEN; LI, 2018).

Sistemas industriais exigem um maior esforço do sistema de gestão para manter máquinas e equipamentos em um bom estado de funcionamento. Geralmente, equipamentos com insuficiência de reparos e manutenção adequada tem maiores probabilidades de falhas e danos. O resultado é baixa produtividade e aumento de custos inerentes ao processo (WOJCIECHOWSKA, 2019). Métodos de identificação de falhas podem determinar o nível de severidade de uma falha, o qual são feitos por softwares específicos que utilizam métodos ligados a inteligência artificial, deep learning, artificial neural network, entre outros (ANAND; RAM, 2019). Diversos pesquisadores têm desenvolvido atividades ligadas a métodos de inteligência artificial, em um desses trabalhos foi desenvolvido a abordagem de rede neural para detecção e identificação das falhas de um sistema de controle de vôo, cuja problemática é resolvida com a introdução de estimadores de redes neurais de aprendizagem on-line (SILVESTRI *et al.*, 1994). Outro pesquisador, utiliza o conceito de redes neurais artificiais e deep learning para detecção e classificação de falhas,

cuja problemática foi resolvida classificando as falhas, posteriormente, através do treinamento da rede, foi possível detectar as falhas considerando também as camadas ocultas (HEO e LEE, 2018). Outro autor estuda o comportamento de uma estrutura a fim de obter informações de danos na estrutura e, para isso, utiliza técnica de computação inteligente ligado a SHM. O resultado encontrado demonstra que a metodologia proposta é robusta e de precisão (OLIVEIRA *et al.*, 2019). Outro autor, utiliza o conceito de sistemas imunológicos artificiais (SIA) aplicados a *structural health monitoring* para detectar falhas em um rotor dinâmico, cuja problemática foi resolvida com conceitos de monitoramento e sensoriamento do SIA classificando e agrupando os sinais em grau de severidade de falhas e na probabilidade de falhas (OUTA *et al.*, 2020).

Desta forma é necessário desenvolver maneiras eficientes de monitorar a estrutura, visando detectar falhas em estados iniciais, intervir na sua propagação e, conseqüentemente, impedir o seu desgaste ou até mesmo o seu tombamento. Esta atual e importante linha de pesquisa é denominada Monitoramento da Integridade de Estruturas (SHM – *Structural Health Monitoring*), que tem a capacidade de fornecer informações sobre a expectativa de vida das estruturas, além de detectar e localizar danos (FARRAR; WORDEN, 2006).

Assim, os principais benefícios que os sistemas de SHM apresentam são: a diminuição dos custos com manutenção e a maior confiabilidade das estruturas projetadas, gerando uma maior segurança de vida. (BALAGEAS; FRITZEN; GÜEMES, 2006).

Logo, conforme destacado por Hall (1999), um SHM deve satisfazer os seguintes requisitos:

- Aquisição e processamento de dados;
- Validação e análise de sinais;
- Identificação e caracterização de falhas;
- Interpretação de mudanças adversas em uma estrutura;
- Auxiliar a tomada de decisões.

Em vista disso, a diminuição dos custos com manutenção e a maior confiabilidade das estruturas projetadas, gerando uma maior segurança de vida são alguns dos principais benefícios deste monitoramento (BALAGEAS; FRITZEN; GÜEMES, 2006). Conseqüentemente, aumenta-se a segurança proporcionada pela

estrutura, uma vez que as falhas sendo precocemente detectadas, não evoluem para níveis perigosos (RAMOS, 2006).

Toda estrutura passa por uma avaliação de testes de integridade estrutural. Neste caso são realizadas avaliações não destrutivas (NDE – *Nondestructive Evaluation*), visando estimar o grau de segurança e confiabilidade da estrutura.

Nos últimos anos, os sistemas de monitoramento de integridade estrutural vêm sofrendo uma evolução natural, devido ao avanço das tecnologias de sensores, materiais inteligentes, técnicas eficientes de processamento de dados e sinais, e principalmente a crescente demanda de se empregar tais ferramentas em tempo real. As técnicas convencionais de SHM, conhecidas também como técnicas de ensaio não destrutivas (NDEs) são: emissão acústica, raios X, correntes de Eddy, métodos de campo magnético, inspeção visual, líquido penetrante, entre outros (CARRILLO, 2007; BITENCOURT; STEFFEN JÚNIOR, 2009).

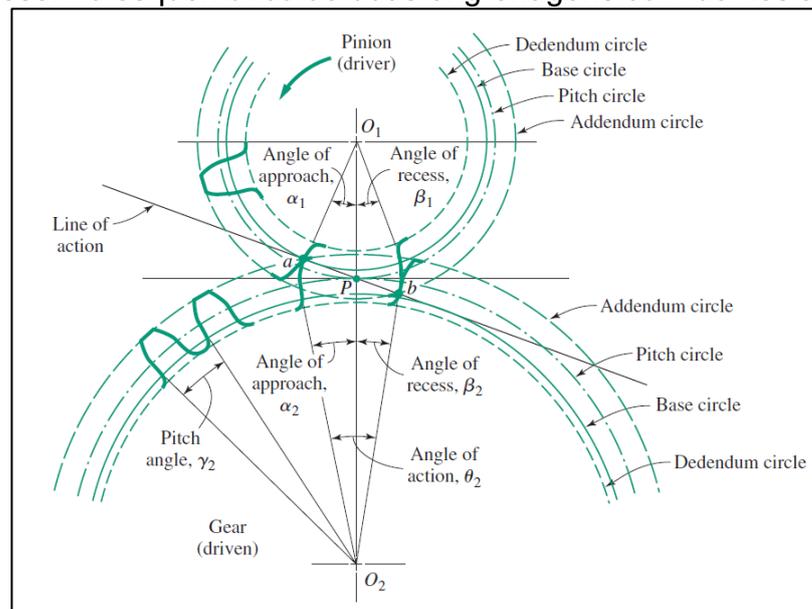
Contudo, existem também técnicas que aproveitam os benefícios dos sistemas inteligentes. Estes são caracterizados por manipularem conhecimentos especializados com benefícios qualitativos e quantitativos através das tecnologias de informação pertencentes à área de inteligência artificial que tem como objetivo o desenvolvimento de sistemas que apresentam as mesmas funcionalidades da natureza ou do cérebro humano (REZENDE, 2005). Neste contexto, uma possível solução, para se desenvolver um SHM moderno e eficiente é a utilização de sensores inteligentes e/ou técnicas de computação inteligentes (sistemas especialistas, redes neurais artificiais, algoritmos genéticos, lógica *fuzzy*, etc.), que viabilizam habilidades como a extração de conhecimentos e informações de processos complexos, facilitam a análise de sinais e proporcionam a automatização da tomada de decisões nos SHMs.

O objetivo deste trabalho é propor um novo método com aplicação na determinação de falhas, utilizando o filtro de Wiener e redes neurais artificiais (RNA). Para que isso seja feito, este trabalho foi dividido a princípio na decomposição de sinais utilizando o filtro de Wiener, resultando em um bando de dados de nome data-Wiener, e em seguida foi introduzido o conceito de separação e classificação de grupamento utilizando *artificial neural network* (ANN).

## 2 ENGRENAGENS

As engrenagens têm a finalidade de transmitir o movimento de um eixo rotativo ao outro, o qual características como sincronização precisa, eficiência no acoplamento entre os dentes das engrenagens, peso das engrenagens, deslizamento livre e movimento uniforme, são relevantes no desempenho do sistema dinâmico. A transmissão da força é feita considerando o contato de dois dentes de engrenagens até a separação deste par de engrenagens, cujo deslocamento angular é feito pela rotação do eixo (COLLINS *et al.*, 2010; VULLO, 2020). A figura 1 mostra o desenho de duas engrenagens considerando o momento de acoplamento entre dois dentes.

Figura 1 - Desenho esquemático de duas engrenagens com dentes acoplados



Fonte: (COLLINS *et al.*, 2010, p. 615)

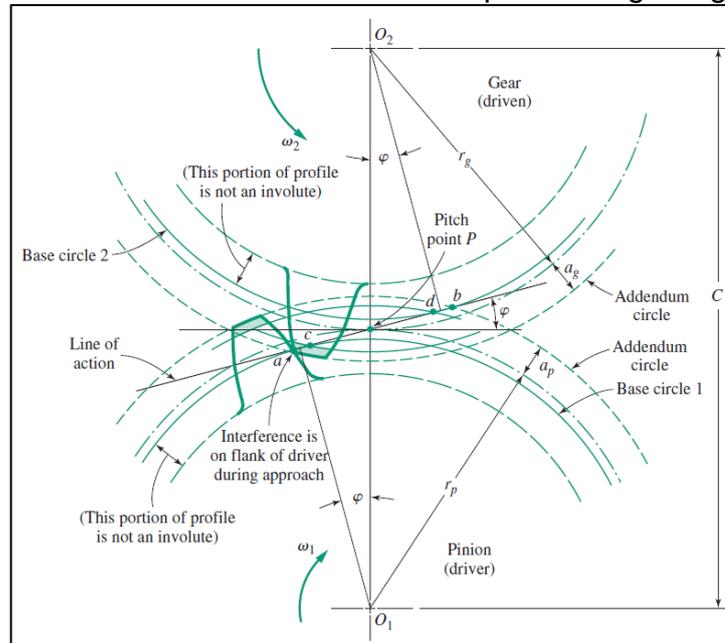
O comprimento de ação ( $Z$ ) é a distância entre o ponto  $a$  e  $b$ , calculada geometricamente pela equação pinhão-engrenagem,

$$Z = \sqrt{(r_p + a_p)^2 - (r_p \cos \varphi)^2} + \sqrt{(r_g + a_g)^2 - (r_g \cos \varphi)^2} - C \sin \varphi \quad (1)$$

sendo,  $r_p$  o raio do pinhão;  $a_p$  é o diâmetro máximo do círculo de cabeça menos o raio do pinhão;  $r_g$  é o raio da engrenagem movida;  $a_g$  é o diâmetro máximo do círculo de cabeça menos o raio do da engrenagem movida (COLLINS *et al.*, 2010;

VULLO, 2020). A figura 2 mostra a relação de interferência (área de contato) entre os dentes retos das engrenagens.

Figura 2 - Interferência entre os dentes pinhão-engrenagem

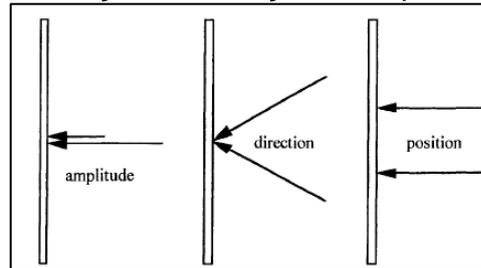


Fonte: (COLLINS *et al.*, 2010, p. 616).

Geralmente os problemas nas engrenagens são percebidos através da observação de um ruído ou vibração do sistema. Os problemas das engrenagens estão ocultos e o tratamento através dos sintomas demonstrados no sistema não surgem efeitos benéficos para uma solução imediata do problema. Portanto, é necessária uma compreensão maior do sistema considerando o problema e as possíveis soluções destes problemas (SMITH, 2003).

Para que um ruído de engrenagem seja gerado é necessário, a princípio, que haja uma variação de força no sistema, e as engrenagens ao se chocarem na área de contato, tem como resultado a reação da força transmitida por toda a estrutura. O movimento contínuo e intermitente do choque dos dentes da engrenagem, promove a vibração que é distribuída por todo o sistema. O ruído gerado varia na amplitude, direção e posição, à medida em que as áreas de contato se movimentam axialmente ao longo da linha de passo da engrenagem (SMITH, 2003). A figura 3 mostra o desenho esquemático da amplitude, direção e posição da força de excitação na engrenagem.

Figura 3 - Força de Excitação em relação a Amplitude, Direção e Posição



Fonte: (SMITH, 2003, p. 2).

Quando a engrenagem é acionada diversas vezes, esta pode se posicionar em locais momentaneamente diferentes em relação à posição de referência e é alterada a velocidade que deveria ser constante (PALMER; FISH, 2012). Este procedimento demonstra o erro de transmissão (TE). Tecnicamente, o erro de transmissão (TE) é considerado como a diferença angular entre a posição ideal e real da engrenagem de saída, resultando na rigidez finita do engrenamento das engrenagens e dos erros do seu movimento (VULLO, 2020; PARK *et al.*, 2018).

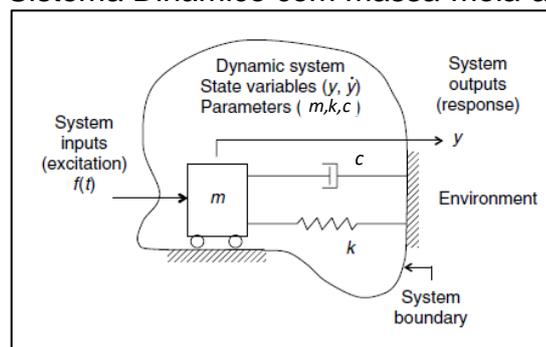
No desenvolvimento dos projetos de engrenagens, a detecção dos modos de falhas do par de engrenagens é de alta complexidade, pois os fatores como a combinação de cargas variáveis, com os deslizamentos de superfícies, entre outras fontes de ação externas, atuam diretamente incidindo no sistema dinâmico (COLLINS *et al.*, 2010).

As falhas podem ser vistas através da tensão de contato na superfície das curvas dos dentes conforme a repetição cíclica do sistema, ocorrendo a propagação de fissuras ao longo da engrenagem. Assim, na região de contato, com ou sem lubrificantes, os desgastes abrasivos e adesivos são analisados para entender o comportamento do sistema. A deformação elástica, induzida pela força na região de contato, também é considerada uma falha e está ligada diretamente a rigidez da superfície dos dentes das engrenagens, o que contribui significativamente na potencialização do ruído ressonante do par de engrenagens (VULLO, 2020; COLLINS *et al.*, 2010; SMITH, 2003).

### 3 SISTEMAS DINÂMICOS E VIBRAÇÃO

Na natureza diferentes fenômenos atuam em um determinado corpo, sendo que, através da função da resposta em frequência (FRF), podem ser entendidos o comportamento de um determinado sistema dinâmico. A representação deste sistema pode corresponder ao conceito de massa-mola-amortecedor, mostrado nos conceitos de vibração (DE SILVA, 2006). A figura 4 mostra um sistema dinâmico composto por massa-mola-amortecedor.

Figura 4 - Sistema Dinâmico com massa-mola-amortecedor

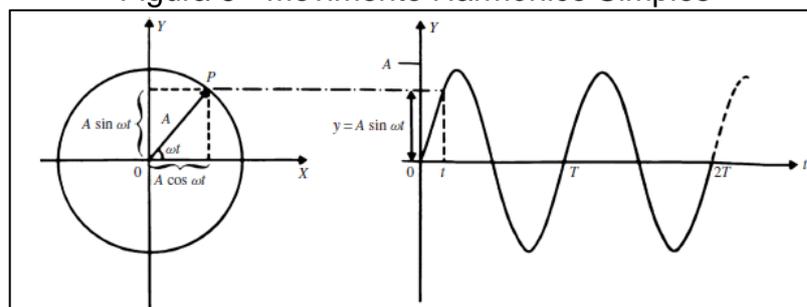


Fonte: (DE SILVA, 2006).

o qual,  $\ddot{y}$  é a aceleração;  $\dot{y}$  é a velocidade; e  $y$  o deslocamento da massa  $m$ ;  $c$  representa o amortecimento viscoso; e  $k$  a constante de rigidez (DE SILVA, 2006; MEIROVITCH, 1997).

A vibração está ligada aos conceitos da dinâmica, e pode ser entendida como a repetição de movimentos de uma determinada massa em relação a uma determinada referência de posição nominal ou ponto de equilíbrio (INMAN, 2014). Um sistema que oscila repetidamente e de forma uniforme pode ser manipulado matematicamente, e é considerado um sistema de movimento harmônico (CROCKER, 2007). A figura 5 mostra a representação gráfica do movimento harmônico simples.

Figura 5 - Movimento Harmônico Simples



Fonte: (CROCKER, 2007, p. 2).

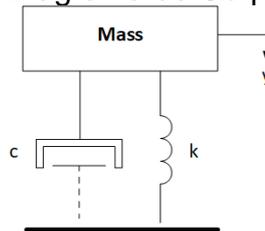
Note que a representação do ponto  $P$  no lado esquerdo da figura, quando em movimento uniforme e constante no sentido anti-horário, pode ser localizado através do conceito geométrico da trigonometria. Quando este ponto  $P$  é projetado em um plano cartesiano bidimensional, pode ser visto a representação gráfica de uma senoide. O sistema do plano cartesiano, contém informações de período, frequência e fase, assim a equação que representa este sistema variando no tempo, pode ser escrita como:

$$y(t) = A \sin(\omega t + \varphi) \quad (2)$$

O argumento  $A$  corresponde a amplitude e pode ser representado na figura como o raio da circunferência; o  $\omega$  é a frequência angular; o  $t$  é o tempo de deslocamento do ponto  $P$ ; o  $\varphi$  corresponde ao ângulo de defasagem do movimento do ponto  $P$  (CROCKER, 2007).

Na mecânica os graus de liberdades representam o número de movimentos independentes que um sistema contém e podem ser caracterizados pelos conceitos de *single degree of freedom* SDOF, e *multi degree of freedom* MDOF. Diversos sistemas mecânicos podem ser representados através do diagrama de corpo livre e pode ser visto na figura 6 (MEIROVITCH, 1997; CROCKER, 2007; INMAN, 2014).

Figura 6 - Diagrama de Corpo Livre



Fonte: Adaptado (MEIROVITCH, 1997).

A equação geral que representa um sistema em equilíbrio, pode ser escrita como,

$$m\ddot{y} + c\dot{y} + ky = 0 \quad (3)$$

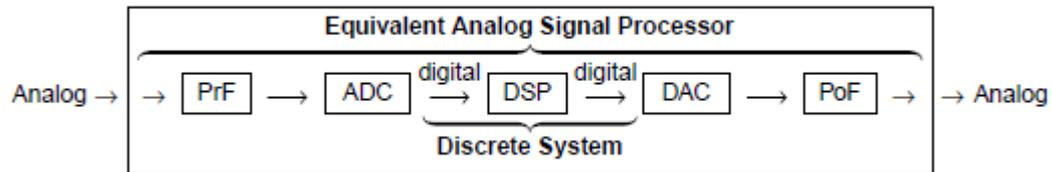
onde,  $\ddot{y} = \frac{d\dot{y}}{dt}$  é a aceleração;  $\dot{y} = \frac{dy}{dt}$  é a velocidade; e  $y$  o deslocamento da massa  $m$ ;  $c$  e  $k$  são respectivamente o amortecimento viscoso e constante de rigidez (MEIROVITCH, 1997; CROCKER, 2007; INMAN, 2014).

### 3.1 Análise Digital de Sinal

O processamento do sinal é uma operação projetada que auxilia na diferença de informações úteis e não úteis de um determinado sinal. Nesta condição é possível considerar que o processamento de sinal determina, a extração, melhoramento, armazenamento e transmissão de operações para uma melhor condição do sinal útil. Esta condição pode ser aplicada em diferentes áreas engenharia, medicina, entre outras (INGLE e PROAKIS, 2012; OPPENHEIM *et al.*, 1999). Os diferentes sinais, podem ser classificados em: Sinal analógico e digital; Sinal real e complexo; Sinal periódico e não periódico; Sinal determinístico e randômico; Sinal de canal único e multicanais; Sinal de força e de energia; Sinal monocomponente e multicomponentes (HUSSAIN *et al.*, 2011).

Os sinais que encontramos no mundo real representam informações do comportamento do estado físico de um determinado sistema em estudo (OPPENHEIM *et al.*, 1999). Na sua concepção são principalmente analógicos que variam continuamente no tempo e, esses sinais, ao sofrerem um processamento de sinal analógico (ASP) tendem a ser considerados de alto custo, justificado pela falta de flexibilidade no processamento e complexidade dos projetos. Já o processamento digital de sinal (DSP) é um tipo de processamento mais robusto e potente, pois podem ser desenvolvidos utilizando softwares em computadores de uso geral. As vantagens são baseadas em: custos de componentes são reduzidos, considerando a tecnologia de desenvolvimento; operações de adições e multiplicações, cujo processamento é executado no limite de sua capacidade, considerado estável (INGLE e PROAKIS, 2012; HUSSAIN *et al.*, 2011). O processamento digital de sinal pode ser mostrado através de um bloco de diagrama, mostrado na figura 7.

Figura 7 - Bloco de Diagrama de DSP

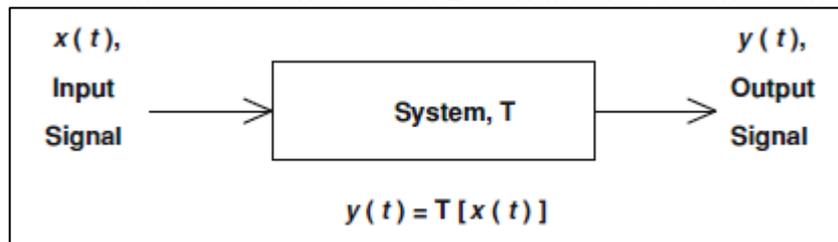


Fonte: (INGLE; PROAKIS, 2012).

O PrF é um filtro antialiasing; o ADC é um conversor analógico digital que produz um fluxo de números binários à partir de sinais analógicos; DPS é um processador de uso especial, considerado um computador de uso geral; o DAC converte o sinal digital para analógico que produz uma onda da sequência de números binários; PoF é um pós filtro que tende a suavizar o sinal em forma de onda em escada no sinal analógico desejado (INGLE e PROAKIS, 2012).

O modelamento de um sistema ( $T$ ), na análise digital de sinal, pode ser definido como um único sinal de entrada ( $x(t)$ ) representa um único sinal de saída ( $y(t)$ ), e matematicamente esta representação é feita no domínio do tempo. A figura 8 mostra o processamento do sinal de um determinado sistema em estudo (HUSSAIN, 2011).

Figura 8 - Processamento de Sinal de um Determinado Sistema com um operador



Fonte: (HUSSAIN, 2011, p. 8).

Os sistemas podem ser classificados em: Sistemas analógicos, discretos no tempo e digitais; Sistemas variantes no tempo e não variantes no tempo; Sistemas causais e não causais; Sistemas estáticos e dinâmicos; Sistemas estáveis e não estáveis; e por fim, Sistemas lineares e não lineares. Assim, para cada tipo de sistema é introduzido um conceito matemático específico para se entender o seu comportamento (HUSSAIN *et al.*, 2011; OPPENHEIM *et al.*, 1999).

Os sistemas de domínio no tempo ou funções temporais utilizam o princípio da transformada de Fourier, o qual decompõe uma função temporal em uma função de valor complexo no domínio da frequência. O resultado é um valor absoluto que

representa a soma das frequências presentes na função original, e o argumento complexo determina a fase de deslocamento daquela frequência (OPPENHEIM *et al.*, 1999).

O método de correlação cruzada também é utilizado na análise de sinais, cuja finalidade de entender o comportamento entre dois sinais  $(\sigma_x; \sigma_y)$ , cujo resultado pode ser obtido considerando o coeficiente de correlação  $r$ , aplicando o teorema dos mínimos quadrados ou ajuste de curva. A equação do coeficiente de correlação  $r$ , pode ser escrita como (LYONS, 2012),

$$r = \left[ 1 - \frac{\sigma_{y,x}^2}{\sigma_y^2} \right]^{1/2} \quad (4)$$

Outro teorema que pode ser aplicado a sistemas de domínio no tempo, é o filtro de Wiener, o qual produz uma estimativa de um processo aleatório desejado por filtragem linear invariante no tempo de um determinado sinal. O filtro de Wiener minimiza o erro quadrático médio entre o processo aleatório estimado e o processo desejado e é aplicado para eliminar os ruídos indesejados de um determinado sinal (HUSSAIN *et al.*, 2011; OUTA *et al.*, 2021). A equação pode ser escrita como,

$$H_0(s) = \frac{S_{yx}(s)}{S_{xx}(s)} e^{\alpha x} \quad (5)$$

onde  $\alpha$  representa o atraso do filtro de Wiener  $H_0(s)$ ;  $S_{xx}(s)$  representa espectro de potência do sinal (PSD) do sinal original; o  $S_{yx}(s)$  representa a densidade espectral cruzada (CSD) entre os sinais originais e observado (HUSSAIN *et al.*, 2011). Considerando a formulação espectral, apresentada na equação 5, a equação que representa o filtro de Wiener ( $W_f$ ) pode ser escrita baseada na minimização do erro quadrático médio entre o sinal observado e um sinal de referência, que é igual ao sinal original,

$$W_f = [R_{yy}^{-1} R_{yd}]^T \quad (6)$$

onde,  $R_y$  é o sinal observado;  $R_{yy}$  é a autocorrelação do sinal observado; e  $R_{yd}$  é a correlação cruzada do sinal (HUSSAIN *et al.*, 2011).

Os sinais de um determinado modelo físico, podem ser reproduzidos em projetos de experimentais, cuja ideia principal é entender o comportamento utilizando métodos experimentais, diferentemente de condições somente analíticas comumente tratadas na engenharia. A finalidade é obter resultados de qualidade precisos, conhecendo as estimativas das medições (HOLMAN, 2012).

## 4 REDES NEURAIS ARTIFICIAIS

Este capítulo irá apresentar uma revisão sobre redes neurais artificiais, onde serão abordados um resumo histórico, as principais características, o neurônio biológico, o neurônio artificial, sua estrutura, componente e funcionamento.

### 4.1 Resumo Histórico

Desde o início do século XX, o homem tem buscado compreender o funcionamento do cérebro. A partir desta busca, muitos pesquisadores têm se dedicado nesta área de estudo. Historicamente, a primeira publicação relacionada à neuro computação é de 1943, e neste artigo os autores McCulloch e Pitts realizaram o primeiro modelamento matemático inspirado em um neurônio biológico, resultando-se na primeira concepção de um neurônio artificial (MCCULLOCH e PITTS, 1943).

McCulloch e Pitts (1943) descrevem um cálculo lógico das redes neurais que unificava os estudos de neurofisiologia e da lógica matemática. Eles definiram que o seu modelo formal de um neurônio seguia o propósito “tudo ou nada”. Com um número suficiente dessas unidades simples e com conexões sinápticas ajustadas e sincronicamente operando, McCulloch e Pitts mostraram que uma rede construída dessa forma realizaria a computação de qualquer função computável.

Com este resultado, muitos pesquisadores aceitam o nascimento das disciplinas de redes neurais e inteligência artificial (IA).

O próximo desenvolvimento significativo das redes neurais, ocorreu no fim da década de 40, com a publicação do livro de Hebb “*The Organization of Behavior*”, o qual apresentou de forma inédita uma formulação explícita de uma regra de aprendizagem filosófica para a modificação sináptica, conhecida como aprendizagem Hebbiana. Resumidamente, Hebb propôs que a conectividade do cérebro é continuamente modificada conforme um organismo que vai aprendendo tarefas funcionais diferentes e essas modificações criam agrupamentos neurais. Publicado em 1949, o livro de Hebb foi imensamente influente entre os psicólogos, mas teve pouco ou nenhum impacto sobre a comunidade de engenharia (HEBB, 1949).

Segundo Silva, Spatti e Flauzino (2010), diversos outros pesquisadores continuaram o trabalho de desenvolvimento de modelos matemáticos com base no neurônio biológico, gerando uma série de estruturas e de algoritmos de aprendizado. Entre os trabalhos publicados, destaca-se o de Frank Rosenblatt que desenvolveu o primeiro neuro computador, denominado *Mark I – Perceptron*, idealizando o modelo básico da rede neural *Perceptron* (ROSENBLATT, 1958).

E na década de 60, especificamente em 1962, Rosenblatt publicou o livro “*Principles of Neurodynamics*” (ROSENBLATT, 1962). Este livro introduziu as redes denominadas *perceptrons*, e segundo Lopes (2005), mais tarde, em 1969, esta obra se tornaria objeto de estudo dos pesquisadores Minsky e Papert, pois estes descobririam que os *perceptrons*, apresentado por Rosenblatt, eram incapazes de aprender o relacionamento entre as entradas e as saídas de funções lógicas bem simples como o XOR (ou-exclusivo). Demonstrando claramente a impossibilidade de as redes realizarem a correta classificação de padrões para classes não linearmente separáveis (SILVA; SPATTI; FLAUZINO, 2010). Devido a este fato, houve uma diminuição do interesse em pesquisas nesta área.

Já no início dos anos 80, Haykin (2001) relata que foram feitos importantes contribuições quanto a teoria e ao projeto de redes neurais, conseqüentemente havendo o ressurgimento do interesse pelas redes neurais. Neste momento autores como: Grossberg, Kohonen e Hopfield, dentre outros, contribuíram significativamente para as principais evoluções nesta nova fase. Grossberg (1980) estabeleceu um novo princípio de auto-organização conhecido como teoria da ressonância adaptativa (ART, *Adaptative Resonance Theory*). De forma simplificada, a teoria envolve uma camada de reconhecimento de baixo para cima, e uma camada generativa de cima para baixo. Ainda na década de 80, Kohonen (1982) publica artigo sobre os mapas auto-organizáveis, e Hopfield (1982) propõe as redes recorrentes baseadas em funções de energia, sendo esta última uma das principais responsáveis pela retomada de destaque da área de redes neurais, o mesmo destaque que possuía antes de 1969.

Em 1986, ocorreu um dos marcos mais importantes, o desenvolvimento do algoritmo *Backpropagation*. Com a publicação do livro intitulado *Parallel distributed processing*, os autores Rumelhart, Hinton e Williams (1986) desenvolveram um algoritmo que permitia ajustar os pesos em uma rede com mais de uma camada, resolvendo até o problema de aprendizado dos padrões da função ou-exclusivo.

Este algoritmo tornou-se o mais popular entre as redes neurais, e reacendeu e motivou o interesse dos pesquisadores nesta área do conhecimento.

Final dos anos 1990 e início dos anos 2000, houve inúmeras aplicações práticas em diferentes ramos do conhecimento na área de redes neurais. Dezenas de novas outras contribuições têm permitido um crescente desenvolvimento teórico. Em especial pode-se destacar a proposição de algoritmos de aprendizado baseados no método de Levenberg-Marquardt, também as redes neurais artificiais baseadas em máquina de vetores de suporte (*SVM - support vector machines*), que podem ser utilizados em classificação de padrões e regressão linear, e outra interessante contribuição é a implementação de circuitos integrados neurais com diversas configurações de tipologia (SILVA; SPATTI; FLAUZINO, 2010).

É possível encontrar maiores detalhes sobre diversos outros fatos históricos sobre redes neurais na obra de Haykin (2001).

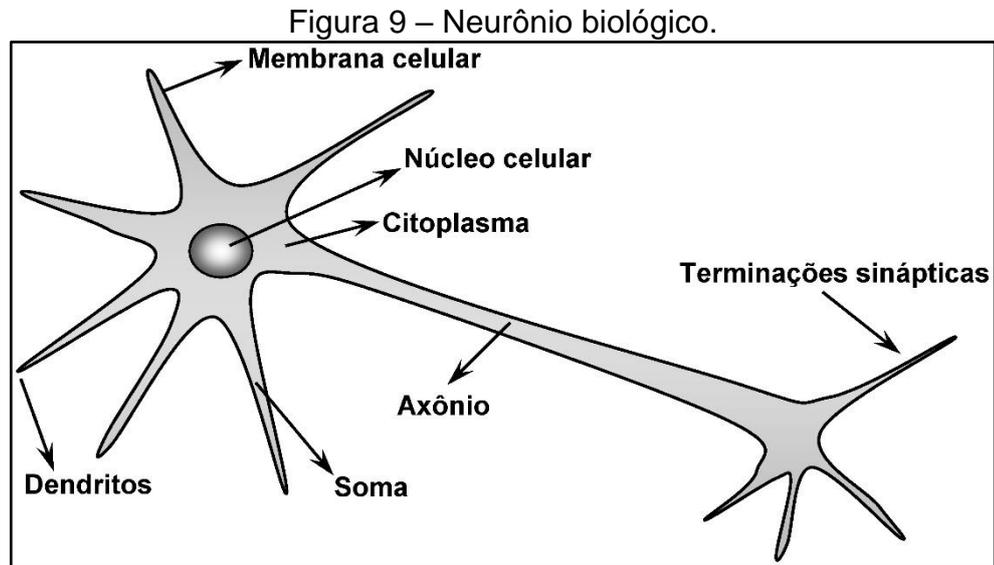
## 4.2 Neurônio Biológico

Algumas das características mais interessantes da rede neural biológica, que a torna superior ao mais sofisticado sistema de computação de IA, no que diz respeito a reconhecimento de padrões, segundo Yegnanarayana (2005), são:

- Robustez e tolerância a falhas: o envelhecimento das células nervosas parece não comprometer significativamente a performance.
- Flexibilidade: a rede automaticamente se ajusta ao novo ambiente sem utilizar instruções pré-programadas.
- Capacidade para lidar com uma enorme variedade de dados: a rede pode lidar com informações com ruído, probabilísticas, distorcidas e inconsistente.
- Computação coletiva: a rede tem capacidade de realizar operações em paralelo e também uma determinada tarefa de forma distribuída.

As características de uma rede neural biológica são atribuídas a sua estrutura e função. A unidade fundamental da rede é chamada de neurônio ou célula nervosa. O cérebro humano apresenta algo em torno de 100 bilhões de neurônios, destes 10 bilhões somente no córtex, e 60 trilhões de sinapses ou conexões (HAYKIN, 2001; LOPES, 2005; SILVA, SPATTI; FLAUZINO, 2010).

Silva, Spatti e Flauzino (2010) afirmam que o principal papel do neurônio é conduzir impulsos, que na realidade são estímulos elétricos advindos de reações físico-químicas, e que conforme exibido na Figura 9, o neurônio pode ser dividido em três partes principais: dendritos, corpo celular e axônio.



Fonte: (SILVA; SPATTI; FLAUZINO, 2010).

O núcleo está localizado no corpo celular (soma). Os dendritos têm como principal função captar, de forma contínua, sinais de outros neurônios. Podemos entendê-los como terminais de entrada (LOPES, 2005). Já o axônio estende-se desde o corpo celular através de um único filamento, cujas terminações são constituídas por ramificações denominadas terminações sinápticas, ou sinapses (SILVA; SPATTI; FLAUZINO, 2010). Podemos entendê-los como terminais de saída.

“As sinapses são unidades estruturais e funcionais elementares que medeiam as interações entre os neurônios”, define Haykin (2001). Lopes (2005) ressalta que as sinapses ocorrem na região em que o axônio de um neurônio se conecta a um dendrito de outro neurônio, lembrando que inexistente contato físico nesta junção. E quando um neurônio é ativado, é transmitido um sinal eletroquímico através do axônio que, por meio das terminações sinápticas é enviado para outros neurônios.

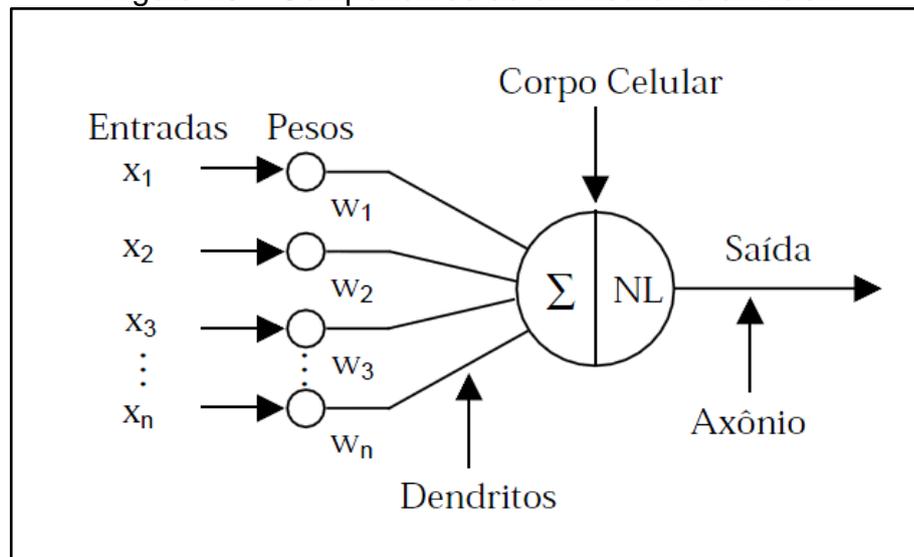
Se este sinal eletroquímico alcança um limiar (*threshold*), uma atividade elétrica na forma de pulsos curtos é gerada. Segundo Yegnanarayana (2005), geralmente esta atividade elétrica permanece no interior do neurônio, enquanto que mecanismos químicos ocorrem nas sinapses. Lopes (2005) conclui que por meio desta conectividade, a sinapse, é atribuído a inteligência.

### 4.3 Neurônio Artificial

A estrutura de uma RNA é baseada a partir de modelos conhecidos de sistemas nervosos biológicos, e do próprio cérebro humano (SILVA; SPATTI; FLAUZINO, 2010). E a partir dos neurônios biológicos houve a inspiração para se criar, de forma mais simplificada, unidades processadoras, ou seja, os neurônios artificiais. Segundo Lopes (2005), estes neurônios artificiais possuem a capacidade de armazenar conhecimento, e a rede neural artificial forma um processador paralelo composto por neurônios ou nodos.

McCulloch e Pitts (1943) propuseram um modelo de neurônio mais simples, porém não descartando as principais características de uma rede neural biológica, ou seja, o paralelismo e a alta conectividade. E este vem sendo o modelo mais utilizado nas diversas arquiteturas de redes neurais artificiais. Este modelo pode ser observado através da Figura 10.

Figura 10 – Componentes de um neurônio artificial.

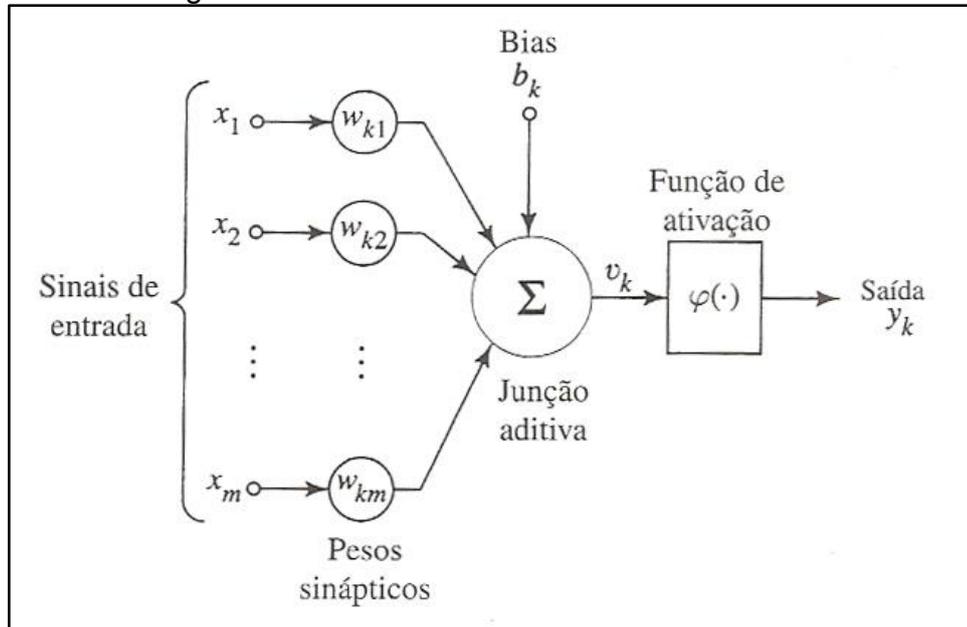


Fonte: (LOPES, 2005).

O modelo básico de neurônio, que forma a base para o projeto de RNA, é apresentado na Figura 15. A saída ( $y_k$ ) gerada por esse neurônio artificial é dada da seguinte forma: multiplica-se cada sinal de entrada ( $x_1 \dots x_m$ ) representando informações advindas do meio externo pelo seu respectivo peso sináptico ( $w_{k1}, \dots, w_{km}$ ) resultando no combinador linear  $\Sigma$ . Em seguida, obtém-se o potencial de ativação ( $v_k$ ) através da subtração do combinador linear pelo limiar de ativação ( $b_k$ ), este último indica qual o patamar adequado para que o combinador linear gere

um valor de disparo para a saída do neurônio. Por fim, aplica-se a função de ativação ( $\varphi(\cdot)$ ) em relação ao seu potencial de ativação.

Figura 11 – Modelo não linear de um neurônio.



Fonte: (HAYKIN, 2001).

Assim, considerando a Figura 11, verifica-se que o processo de treinamento do neurônio artificial se dá da seguinte forma (HAYKIN, 2001; SILVA, SPATTI; FLAUZINO, 2010):

- Sinais de entrada  $X \{x_1, x_2, \dots, x_m\}$ : neste caso tem-se um neurônio de  $m$  entradas, onde um sinal  $x_j$ , vindo do meio externo, conecta-se a sinapse  $j$ . Estes sinais podem ser considerados os valores assumidos pelas variáveis de uma aplicação específica.
- Pesos sinápticos  $W \{w_{k1}, w_{k2}, \dots, w_{km}\}$ : são escritos  $w_{kj}$ , onde  $k$  se refere ao neurônio em questão e  $j$  se refere ao terminal de entrada da sinapse a qual o peso está ligado. É importante salientar que pesos sinápticos podem assumir valores positivos ou negativos, e são utilizados para ponderar cada uma das variáveis de entrada da rede.
- Combinador linear  $\Sigma$ : é um somador dos sinais de entrada, ponderados pelos respectivos pesos sinápticos.
- Bias  $b_k$ : possui o efeito de aumentar ou diminuir a entrada da função de ativação, podendo ser positivo ou negativo, respectivamente.

- e) Potencial de ativação  $V_k$ : é o resultado da diferença entre o combinador linear e o limiar de ativação. Se tal valor é positivo, com  $u_k > b_k$ , então possui potencial excitatório, caso contrário, o potencial será inibitório.
- f) Função de ativação  $\varphi(\cdot)$ : seu objetivo é restringir a amplitude da saída do neurônio para um valor finito. Tipicamente normaliza a saída obtendo valores como  $[0, 1]$  ou  $[-1, 1]$ .
- g) Sinal de saída  $Y_k$ : é o sinal que poderá ser utilizado por outros neurônios, caso haja esta possibilidade. Consiste no valor final produzido pelo neurônio artificial conforme conjunto de sinais de entrada.

Em termos matemáticos, as duas expressões abaixo sintetizam o resultado produzido pelo neurônio artificial proposto por McCulloch e Pitts, ou seja:

$$\mathbf{u}_k = \sum_{j=1}^m \mathbf{w}_{kj} \cdot x_j - b_k \quad (1)$$

e

$$\mathbf{y}_k = \varphi(\mathbf{u}_k) \quad (2)$$

As RNAs possuem a capacidade de aprender através de exemplos (padrões) e, a partir do ajuste das intensidades das conexões entre os neurônios artificiais, é que elas adquirem seu conhecimento. O processo de aprendizado de uma RNA busca a melhoria de seu desempenho de acordo com um critério preestabelecido. Em resumo, o funcionamento de uma RNA segue duas etapas: fase de treinamento e fase de diagnóstico. A fase de treinamento tem um destaque maior, pois, é nesta etapa que a rede neural irá adquirir seu conhecimento através do ajuste dos pesos das conexões entre os neurônios artificiais seguindo um método de aprendizado específico. Portanto, quanto maior for o conhecimento adquirido, melhor será a capacidade de generalização da rede neural na fase de diagnóstico. Na fase de diagnóstico a rede será avaliada, tendo como entrada, novos dados, a fim de verificar se seu comportamento está de acordo com o desejado. De acordo com Haykin (2001), existem duas categorias de aprendizado: o treinamento supervisionado e o não-supervisionado. O autor também destaca alguns aspectos importantes sobre as RNAs:

- a. Não linearidade;

- b. Mapeamento de entrada-saída;
- c. Adaptabilidade;
- d. Tolerância a falhas.

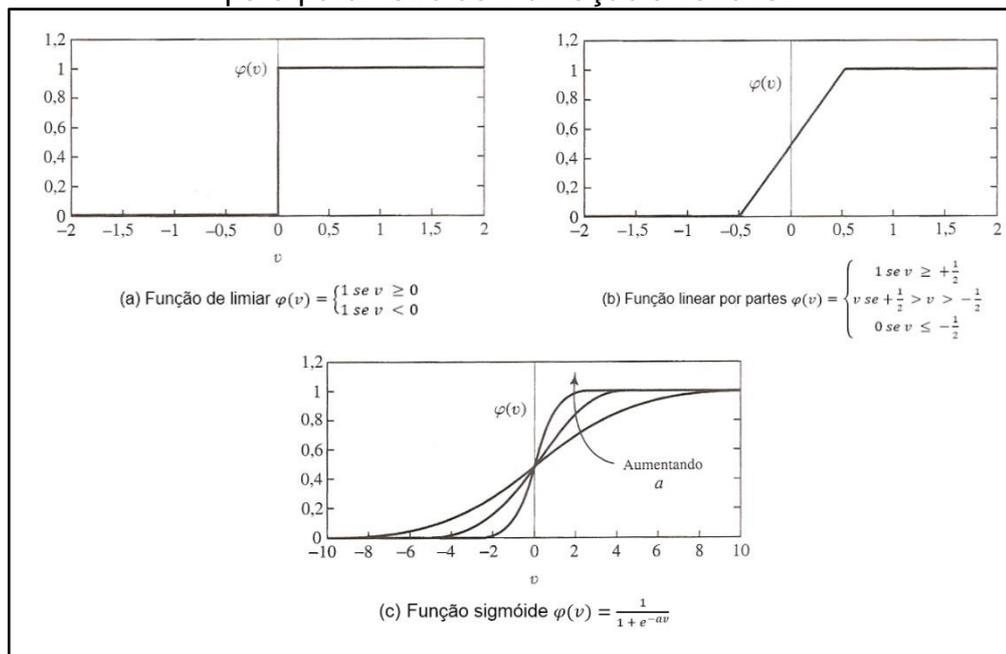
Silva, Spatti e Flauzino (2010) resumem o funcionamento de um neurônio artificial de seguinte forma:

- Recebe-se de um conjunto de valores a serem adotados como as variáveis de entrada;
- Multiplica-se cada valor de entrada por seu respectivo peso sináptico;
- Obtendo-se o potencial de ativação, subtrai-se o limiar de ativação;
- Aplica-se uma função de ativação apropriada;
- Compila-se a saída a partir da função de ativação.

#### 4.3.1 Funções de Ativação

A função de ativação  $\varphi(v)$  define a saída de um neurônio em termos do potencial de ativação  $v$ . A Figura 12 identifica três tipos básicos de funções de ativação.

Figura 12 – (a) Função de limiar. (b) Função linear por partes. (c) Função sigmoide para parâmetro de inclinação a variável.



Fonte: (HAYKIN, 2001).

De acordo com Lopes (2005) e Altran (2010), as funções de limiar, também conhecida como degrau, são apropriadas para sistemas binários, enquanto que as funções sigmoidais podem ser utilizadas tanto em sistemas binários quanto contínuos. Ambos os autores concordam que a função sigmoide é a mais utilizada pelo fato de ser contínua e apresentar derivada simples.

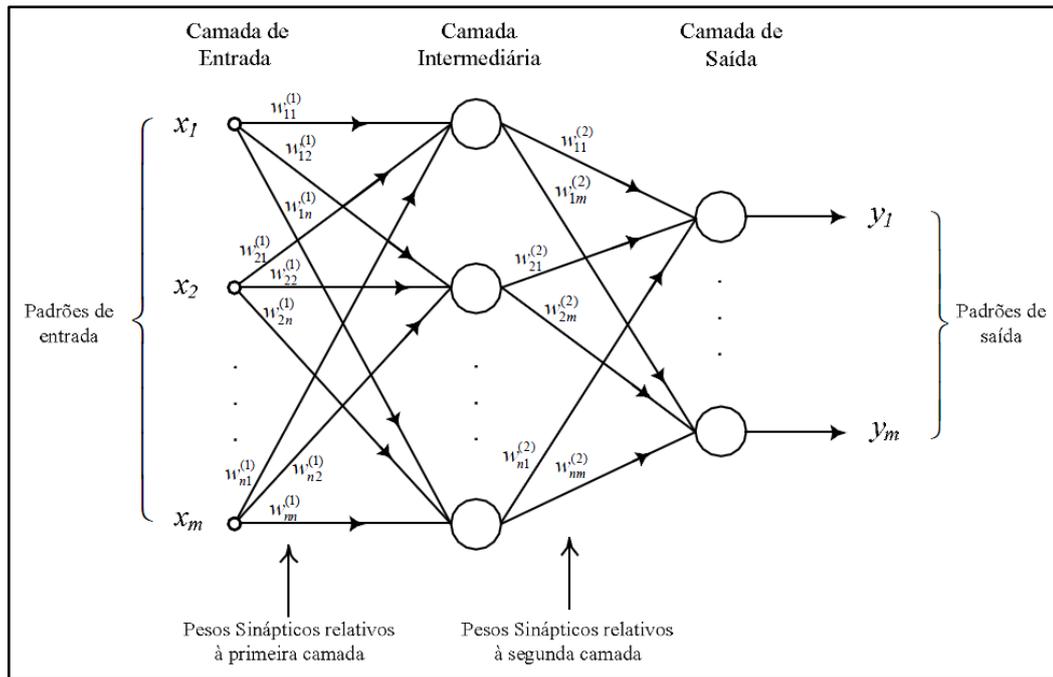
#### **4.4 Arquitetura das Redes Neurais Artificiais**

A arquitetura de uma RNA define como estão arranjos ou dispostos os seus neurônios, uns com relação aos outros. A essência desses arranjos está no direcionamento das conexões sinápticas (SILVA; SPATTI; FLAUZINO, 2010).

Altran (2010) destaca que uma rede neural artificial consiste em neurônios (elementos de processamento) e sinapses (suas conexões), e dentro deste esquema há uma camada de entrada e uma camada de saída. Porém entre estas camadas pode haver um número variável de camadas intermediárias (escondida, oculta ou invisível).

Assim, uma RNA pode ter suas saídas servindo como entradas a outros neurônios, ou ter suas entradas precedentes das saídas de outros neurônios. E neste cenário, há um peso para cada conexão de entrada de um neurônio. Altran (2010) também afirma que o nome de arquitetura da rede neural está diretamente ligado à disposição das camadas e o número de neurônio por camadas, exemplificado pela Figura 13.

Figura 13 – Disposição de uma rede neural artificial.



Fonte: (ALTRAN, 2010).

Pode haver três classificações com relação à propagação dos dados dentro da estrutura de uma RNA, que são:

- Redes *Feedforward* (não recorrentes): o fluxo de informações segue sempre uma única direção (unidirecional), fluem sempre a partir da camada de entrada, em direção à camada de saída. O processamento das informações pode estender-se por uma ou mais camadas, mas sem haver realimentação. (KROSE; SMAGT, 1996).
- Redes *Feedback* (recorrentes): contém laço de realimentação, ou seja, a saída de um neurônio é utilizada para realimentar o mesmo neurônio, ou neurônios das camadas anteriores. No início do processo de realimentação, há um período em que as unidades se submeterão a um processo de adaptação tal, que a rede passará para um estado estável, no qual a realimentação não mais irá variar a saída, desenvolvendo assim uma memória a longo prazo nos neurônios internos (KROSE; SMAGT, 1996; LOPES, 2005).
- Redes reticuladas: possui como principais características a consideração da disposição espacial dos neurônios objetivando propósitos de extração de características. Neste contexto a localização

especial dos neurônios está diretamente relacionada com o processo de ajuste de seus pesos e limiares (SILVA; SPATTI; FLAUZINO, 2010).

#### 4.5 Treinamento da Rede Neural

A propriedade que é de importância primordial presente em uma RNA, é sua habilidade de aprender, pois com esta aprendizagem é possível melhorar seu desempenho. A aprendizagem acerca de seu ambiente se dá através de um processo interativo de ajustes aplicados aos pesos sinápticos. A evolução da aprendizagem acontece a cada iteração (HAYKIN, 2001).

Haykin (2001) faz uma definição de forma precisa de aprendizagem, ele a define como sendo “[...] um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente na qual está inserida [...]”. E o objetivo da aprendizagem, ou treinamento, é permitir que um conjunto de valores de entrada (vetores), produza um conjunto de saídas esperadas ou desejadas (ALTRAN, 2010; LOPES, 2005).

Quanto ao tipo de treinamento, pode-se classificá-lo em quatro tipos, como segue abaixo.

- Treinamento supervisionado ou treinamento associativo: a rede é treinada a partir de padrões de entradas e saídas. Na fase de aprendizado, o treinamento acontece por um agente externo (professor) que informa à rede a resposta desejada para o padrão de entrada especificado. O professor adquire conhecimento da rede, na forma de mapeamento de entrada-saída. Dentre algumas redes que possuem este tipo de treinamento, pode-se citar a rede Madaline, que utiliza o algoritmo de aprendizagem *Backpropagation*, a rede Groosberg, a rede ARTMAP, a rede ARTMAP-Fuzzy, entre outras (Altran, 2010; KROSE e SMAGT, 1996; Lopes, 2005).
- Treinamento não-supervisionado ou *Self-organization*: exclusivamente, o treinamento depende de vetores de entradas. Este treinamento não possui um agente externo (professor) informando à rede a resposta desejada para o padrão de entrada apresentado. A partir desta ideia a rede projetada deverá ser capaz de efetuar seu aprendizado através de um processamento estatístico dos padrões de entrada juntos de seus

respectivos resultados na saída. Pode-se citar como exemplos, as redes: Hopfield, Kohonen e ART (convencional e nebulosa) (KROSE; SMAGT, 1996; LOPES, 2005).

- Treinamento competitivo: este treinamento possui uma saída desejada. Verifica-se que as redes que fazem uso deste tipo de treinamento, possuem vários neurônios na camada de saída, e estes competem entre si para oferecer a saída desejada quando um padrão de entrada é aplicado à rede. Pode-se citar a *Counterpropagation* como exemplo de uma rede neural que utiliza este tipo de treinamento (LOPES, 2005).
- Treinamento híbrido: faz uso alternadamente do treinamento supervisionado e do treinamento não-supervisionado.

Dentre os diversos algoritmos existentes para treinar uma RNA, pode-se destacar (KROSE; SMAGT, 1996): a regra de Hebb; a regra delta de Widrow e Hoff; a regra delta generalizada e o algoritmo de aprendizagem Backpropagation.

#### 4.6 Tipos de Redes Neurais Artificiais

Há diversos modelos de RNA sendo utilizadas nas mais variadas aplicações em inúmeras áreas do conhecimento. Dentre os modelos de RNA mais conhecidos, destacam-se (LOPES, 2005):

- Rede neural de McCulloch-Pitts: Pioneiros nos estudos de RNA, justificando que, por meio do ajuste adequado dos pesos, o neurônio tem capacidade de executar operações lógicas básicas. Foi desenvolvido em 1943 (MCCULLOCH; PITTS, 1943).
- *Perceptron* de camada simples: utilizada para resolução de problemas lógicos envolvendo os operadores AND e OR, e também no reconhecimento e classificação de padrões. Foi proposta por Rosenblatt em 1958 (ROSENBLATT, 1958).
- *Perceptron* de múltiplas camadas: capacidade para realizar operações lógicas complexas (LOPES, 2005).
- *Adaline*: após devidamente treinada, é utilizada para reconhecimento e classificação de padrões (WIDROW e HOFF, 1960).

- *Madaline*: rede neural de multicamada que apresenta alto grau de tolerância a falhas (WIDROW; HOFF, 1960).
- Rede neural *feedforward*: rede neural multicamada utilizada para classificação e controle de robôs. Foi proposta em 1969 (MINSKY; PAPERT, 1969).
- SOM (*Self Organizing Map*) de Kohonen: elaborada em 1972, é uma rede competitiva utilizada para fazer mapeamento entre dados de entrada e saída (KOHONEN, 1972).
- Rede neural *Backpropagation*: Werbos (1974) foi quem apresentou a primeira concepção de algoritmo Backpropagation. Porém, Rumelhart, Hinton e Williams (1986), sabendo sobre o trabalho de Werbos, descobriram como ajustar os pesos de uma RNA das unidades de entrada para a unidade de saída e propagar o erro da saída em direção da camada de entrada. Rede com aplicabilidade em operações lógicas complexas e classificação de padrões.
- Rede ART (*Adaptive Resonance Theory*): elaborada por Grossberg (1976) em 1975, esta rede possui por base característica da ressonância adaptativa. Utilizada para reconhecimento de sinais e processamento de imagens.
- Rede de Hopfield: rede aplicada em reconhecimento de imagens (HOPFIELD, 1982).
- Rede CNM (*Combinatorial Neural Model*): é uma rede neural com característica que permite sua aplicação em processamento de reconhecimento, análise e classificação de dados (MACHADO e ROCHA, 1989).
- Rede CPN (*Counterpropagation Network*): é uma rede neural competitiva elaborada para trabalhar como uma tabela de consulta auto programável com habilidade de interpolar dados de entrada, segundo Hecht-Nielsen (1987).
- Rede BAM (*Bidirectional Associative Memory*): possui memória associativa bidirecional. Quando os dados fornecidos possuem um padrão corrompido, ela permite uma certa tolerância a erros (KOSKO, 1988).

- Rede *Neocognitron*: rede neural multicamada desenvolvida para reconhecer caracteres alfabéticos escritos à mão. Possui interligações parciais entre as unidades das várias camadas. Possui uma boa tolerância a erros, pois identifica os caracteres mesmo com certa inclinação na escrita ou pequena distorção na imagem (FUKUSHIMA, 1980).
- Rede RBFN (*Radial Basis Function Network*): possui arquitetura *feedforward* de camadas múltiplas. Uma das particularidades desta rede é a utilização de uma função de ativação de base radial, como as gaussianas, nos neurônios de camada intermediária (SILVA; SPATTI; FLAUZINO, 2010).

#### 4.7 Benefícios das Redes Neurais Artificiais

De acordo com Lopes (2005), a RNA possui como base uma arquitetura de implementação paralelamente distribuída com capacidade de generalização, ou seja, a RNA responde adequadamente a novas situações (diagnóstico) com base no aprendizado adquirido em experiências passadas (treinamento). Estas duas características são primordiais, porquanto possibilita a resolução de problemas que na vida real possuem resolução complexa.

As redes neurais apresentam particularidades únicas que somente são encontradas em suas estruturas. Seu uso oferece as seguintes propriedades úteis e capacidades (Haykin, 2001; Lopes, 2005):

- **Não linearidade:** a não linearidade é de um tipo próprio na razão dela ser distribuída por toda a rede, porém um neurônio artificial pode ou não ser linear. Essa possibilidade de obter um sinal de entrada gerado a partir de um mecanismo físico inerentemente não linear, faz da não linearidade algo muito importante.
- **Aprendizado e generalização:** possui a capacidade de adquirir resultados significativos por meio da aprendizagem e do acúmulo de conhecimento.
- **Processamento paralelo:** maior rapidez na execução de tarefas mais difíceis.

- **Robustez:** a rede possui capacidade de processar dados mesmo com ruídos ou incompletos.
- **Flexibilidade:** é possível aplicar as redes neurais em diversas áreas do conhecimento.

#### 4.8 Aplicações das Redes Neurais Artificiais

A capacidade de aprendizado e generalização das RNAs proporciona um alto grau de aplicabilidade em inúmeras questões da vida real.

Na atualidade, pesquisadores tem inovado a área de arquitetura de redes neurais e técnicas de treinamento, adequando-as a aplicações específicas. Dessa forma, o interesse de utilização das RNAs vem aumentando de forma significativa. Dentre as principais aplicações destacam-se basicamente (LOPES, 2005; SILVA, SPATTI; FLAUZINO, 2010):

- Diagnóstico;
- Processamento de imagens diversas;
- Reconhecimento de padrões;
- Classificação de padrões;
- Controle;
- Regressão e previsão;
- Otimização;
- Filtragem de dados.

## 5 TEORIA DA RESSONÂNCIA ADAPTATIVA

### 5.1 Rede Neural ART

As redes neurais artificiais são algoritmos computacionais baseadas no funcionamento do cérebro humano. E uma das principais funcionalidades que o nosso cérebro é capaz de realizar, é aprender novas coisas sem necessariamente esquecer, a princípio, do conhecimento previamente adquirido.

A Teoria da Ressonância Adaptativa (ART - *Adaptive Resonance Theory*) é uma estrutura de rede neural estabelecida, desenvolvida no Centro de Sistemas Adaptativos da Universidade de Boston. (SERRANO-GOTARREDONA; LINARES-BARRANCO; ANDREOU, 1998). É baseada em muitos anos de sólidos estudos de modelos matemáticos o que tornou possível a criação de uma série de arquiteturas de ART (GROSSBERG, 1976; GROSSBERG, 1980; CARPENTER e GROSSBERG, 1991).

Em 1976, Grossberg introduziu a rede ART, um sistema utiliza a aprendizagem não supervisionada, como uma teoria do processo de informação cognitiva humana (GROSSBERG, 1976). Este tipo de rede possui uma topologia em que a dinâmica possui como base a teoria da ressonância adaptativa. Permitindo assim, que este tipo de rede seja de suma importância, pois baseia-se na resolução do dilema da plasticidade e da estabilidade, produzido por meio do teste de vigilância, dando origem a uma rede mais rápida e precisa (LOPES, 2005).

O “Dilema Estabilidade-Plasticidade”, em resumo, apresenta uma rede que seja flexível o suficiente para absorver mudanças nos padrões de entradas da rede, ou seja, mudanças no comportamento na classe de entrada, e seja capaz de se adaptar a este novo tipo de padrão e ao mesmo tempo seja estável o suficiente para garantir o agrupamento de todos os elementos sem perder o que já foi aprendido, ou seja, toda a aprendizagem já absorvida nos processos anteriores (MARTINS, 2010). Ou seja, a rede neural ART deveria ser flexível para incorporar novas classes de entrada (novos conhecimentos) referentes às mudanças ocorridas no ambiente externo e ao mesmo tempo estável a fim de que, ao realizar um novo treinamento da rede neural, ela não perdesse o conhecimento já adquirido em processos de treinamento anteriores. Portanto, as redes neurais ART são redes que se auto-organizam com o propósito de realizar o reconhecimento de categorias para as

sequências arbitrárias dos padrões de entrada que são apresentadas a rede (LOPES; MINUSSI; LOTUFO, 2005).

Martins (2010) salienta que redes do tipo ART foram criadas para serem utilizadas em ambientes que seja necessário trabalhar durante longos períodos, em cenários que há possibilidades de aparecimento de novos padrões, e que atualize seus pesos de forma contínua e incremental. Lopes (2005) define as redes ART como desenvolvidas para codificar reconhecimentos estáveis, em tempo real, através da auto-organização, em detrimento a sequências arbitrárias de padrões de entrada.

Quando uma nova entrada é apresentada a rede, ela verificará se esta se encaixa em alguma categoria já existente. Se não houver, uma nova categoria é criada. Este processo não é possível em outras redes neurais, pois ao realizar um novo treinamento, elas perdem o conhecimento já adquirido. Isto só é possível nas redes ART por conta do mecanismo de vigilância que elas possuem, o qual é responsável por administrar a entrada de novos padrões em cada categoria existente ou não (FERREIRA, 2003).

Segundo Silva, Spatti e Flauzino (2010), as topologias baseadas na arquitetura ART podem ser divididas nos grupos citados a seguir que são classificados de acordo com o tipo de suas entradas e seus processos de treinamento, conforme segue:

- **ART-1:** Padrões com entradas binárias e treinamento não supervisionado (CARPENTER e GROSSBERG, 1987a).
- **ART-2:** Padrões com entradas binárias ou analógicas (contínuas) e treinamento não supervisionado (CARPENTER e GROSSBERG, 1987b).
- **ART-3:** Treinamento não supervisionado e entradas binárias ou analógicas. Usa-se aqui topologia multinível e transmissores para controle do processo de busca pela melhor solução (CARPENTER e GROSSBERG, 1990).
- **ARTMAP:** Treinamento supervisionado em tempo real e padrões de entradas binárias ou analógicas. Utiliza em sua estrutura duas redes ART (CARPENTER; GROSSBERG; REYNOLDS, 1991a).

- **Fuzzy ART:** Treinamento não supervisionado e engloba em sua arquitetura cálculos baseados em lógica nebulosa (CARPENTER, GROSSBERG e ROSEN, 1991b).
- **Fuzzy ARTMAP:** Treinamento supervisionado com todos os cálculos fundamentados na lógica nebulosa (CARPENTER; GROSSBERG *et al.*, 1992).

Quando o objetivo é reconhecer e classificar padrões, a Teoria da Ressonância Adaptativa é de grande utilidade. Suas particularidades e capacidade de auto-organizar padrões de entrada em categorias de reconhecimento, a faz alcançar equilíbrio na questão plasticidade e estabilidade (MARTINS, 2010).

### 5.1.1 Rede Neural ART-1

O primeiro modelo ART, chamado de ART 1, foi uma rede neural que utilizou-se de um tipo de aprendizado não supervisionado, chamado de treinamento competitivo, para categorizar padrões de entrada binários.

No aprendizado não-supervisionado, a própria rede se auto-organiza para relacionar as características entre os elementos do conjunto de entrada identificando possíveis subconjuntos que contenham semelhanças. A regularidade e a redundância nas entradas da rede são fundamentais para que haja este tipo de aprendizado, pois, durante o processo, os padrões de entrada são mostrados de forma contínua à rede e a regularidade nesses dados torna o aprendizado possível.

Haykin (2001) afirma que no treinamento competitivo ou aprendizagem competitiva, por pertencer à categoria de aprendizado não-supervisionado, os neurônios da camada de saída competem entre si para serem ativados. Portanto, diferentemente de outras formas de aprendizagem, onde vários neurônios da camada de saída podem estar ativos simultaneamente, na aprendizagem competitiva, apenas um único neurônio é ativado em um determinado instante.

Para Haykin (2001) existem três elementos fundamentais sobre este tipo de treinamento:

a. Um conjunto de neurônios onde todos são iguais entre si, exceto por alguns pesos sinápticos que estão distribuídos aleatoriamente, e que por isso respondem diferentemente a um dado conjunto de padrões de entrada;

b. Há um limite imposto sobre a “força” de cada neurônio;

c. Um mecanismo que permite cada neurônio competir pelo direito de responder a certo conjunto de padrões de entrada, de forma que apenas um neurônio de saída ou um neurônio do grupo esteja ativo em um determinado instante. O neurônio que vence esta “competição” é denominado *winnertake-all* (o vencedor leva tudo).

### 5.1.2 Rede Neural ARTMAP-Fuzzy

A rede neural ART Fuzzy abordou as características da rede ART1 juntamente com os conceitos da teoria dos conjuntos nebulosos (ver Apêndice A – Lógica Fuzzy) permitindo a inserção de padrões de entrada do tipo analógico e binário, utilizando-se também de um aprendizado não-supervisionado.

Ela possui uma arquitetura estável e plástica, que garante uma vantagem com relação a outros tipos de redes neurais artificiais. A rede ARTMAP-Fuzzy permite a inclusão de um módulo de treinamento continuado, o qual habilita a extração de conhecimento sem a necessidade de reiniciar o processo de treinamento quando novos padrões são apresentados, ao contrário do que acontece com a maioria das redes neurais. Esta característica torna possível um uso reduzido de padrões de entrada na fase de treinamento, durante a análise da aplicação, a extração do conhecimento é contínua, sendo um exemplo de um sistema que busca melhoramento a todo tempo (CARPENTER, GROSSBERG, *et al.*, 1992).

A RNA ARTMAP-Fuzzy trata-se de um sistema de aprendizagem supervisionado composta de um par de módulos ART (CARPENTER; GROSSBERG, 1987a), ARTa-Fuzzy e ARTb-Fuzzy, interconectados por um módulo de memória associativa inter-ART. Esta arquitetura de rede neural incorpora a teoria *fuzzy*, o operador lógico AND *fuzzy* ( $\wedge$ ) habilitando o sistema neural de aprendizagem, em resposta aos padrões de entradas binários e analógicos, durante os intervalos [0 1] (CARPENTER; GROSSBERG *et al.*, 1992).

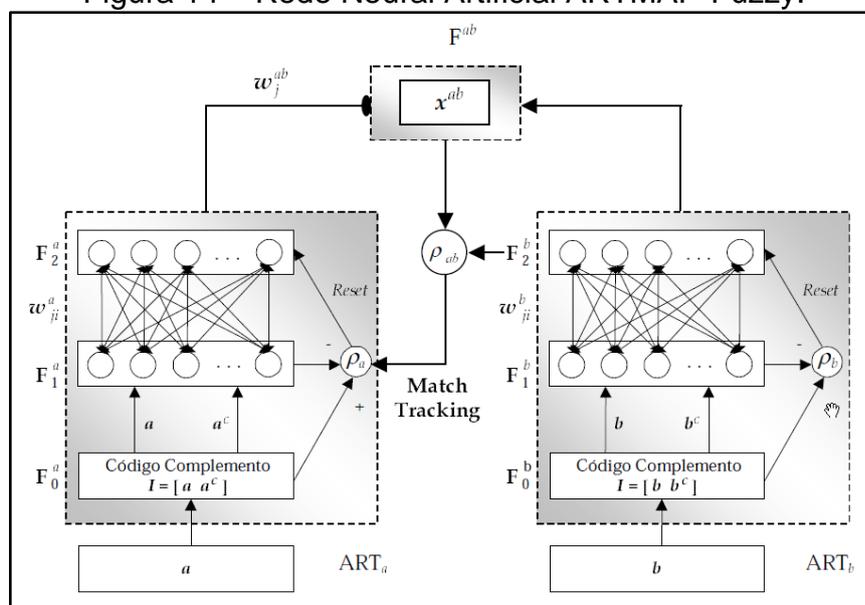
Martins (2010) afirma que um mecanismo interno chamado *match-tracking* é responsável pelo processo autorregulatório da rede neural, no qual maximiza a generalização e minimiza o erro. Quando a rede neural faz uma predição errada, através de uma conexão associativa instruída, o parâmetro de monitoramento do módulo ARTa-Fuzzy é incrementado no mínimo necessário para corrigir o erro no

módulo ARTb-Fuzzy. A Figura 14 ilustra a arquitetura da rede neural ARTMAP-Fuzzy.

Segundo Carpenter *et al.* (1992), a arquitetura ARTMAP-Fuzzy possui três parâmetros principais para o desenvolvimento, chamados:

- **Parâmetro de escolha  $\alpha$  ( $\alpha > 0$ ):** opera na categoria de seleção;
- **Taxa de treinamento  $\beta$  ( $\beta \in [0 1]$ ):** Controla a velocidade de adaptação da rede;
- **Parâmetro de monitoramento ( $\rho_a$ ,  $\rho_b$  e  $\rho_{ab} \in [0 1]$ ):** controla a ressonância da rede, nomeado os parâmetros responsáveis pelo número de categorias criadas.

Figura 14 – Rede Neural Artificial ARTMAP-Fuzzy.



Fonte: (LOPES, 2005).

Se  $\rho$  possui um valor alto, a rede neural torna-se mais seletiva reduzindo sua capacidade de generalização. Se  $\rho$  possui um valor pequeno, é reduzido o número de categorias criadas, maximizando a capacidade de generalização da rede ARTMAP-Fuzzy.

### 5.1.3 Algoritmo ARTMAP-Fuzzy

De acordo com Lopes (2005), a rede neural ARTMAP-Fuzzy consiste em dois módulos ART Fuzzy, o ART<sub>a</sub> e o ART<sub>b</sub>.

Carpenter *et al.* (1992) afirmam que o aprendizado de uma rede neural ART Fuzzy sempre converge, pois todos os seus pesos adaptativos não são incrementados. No entanto, por não ter um processamento adicional a esses pesos, surge um problema de proliferação de categorias. Para resolver tal questão, um pré-processamento no vetor de entrada, chamado decodificação de complemento, é aplicado. Esta codificação de complemento irá normalizar o vetor de entrada, permitindo que o vetor seja inserido na rede neural.

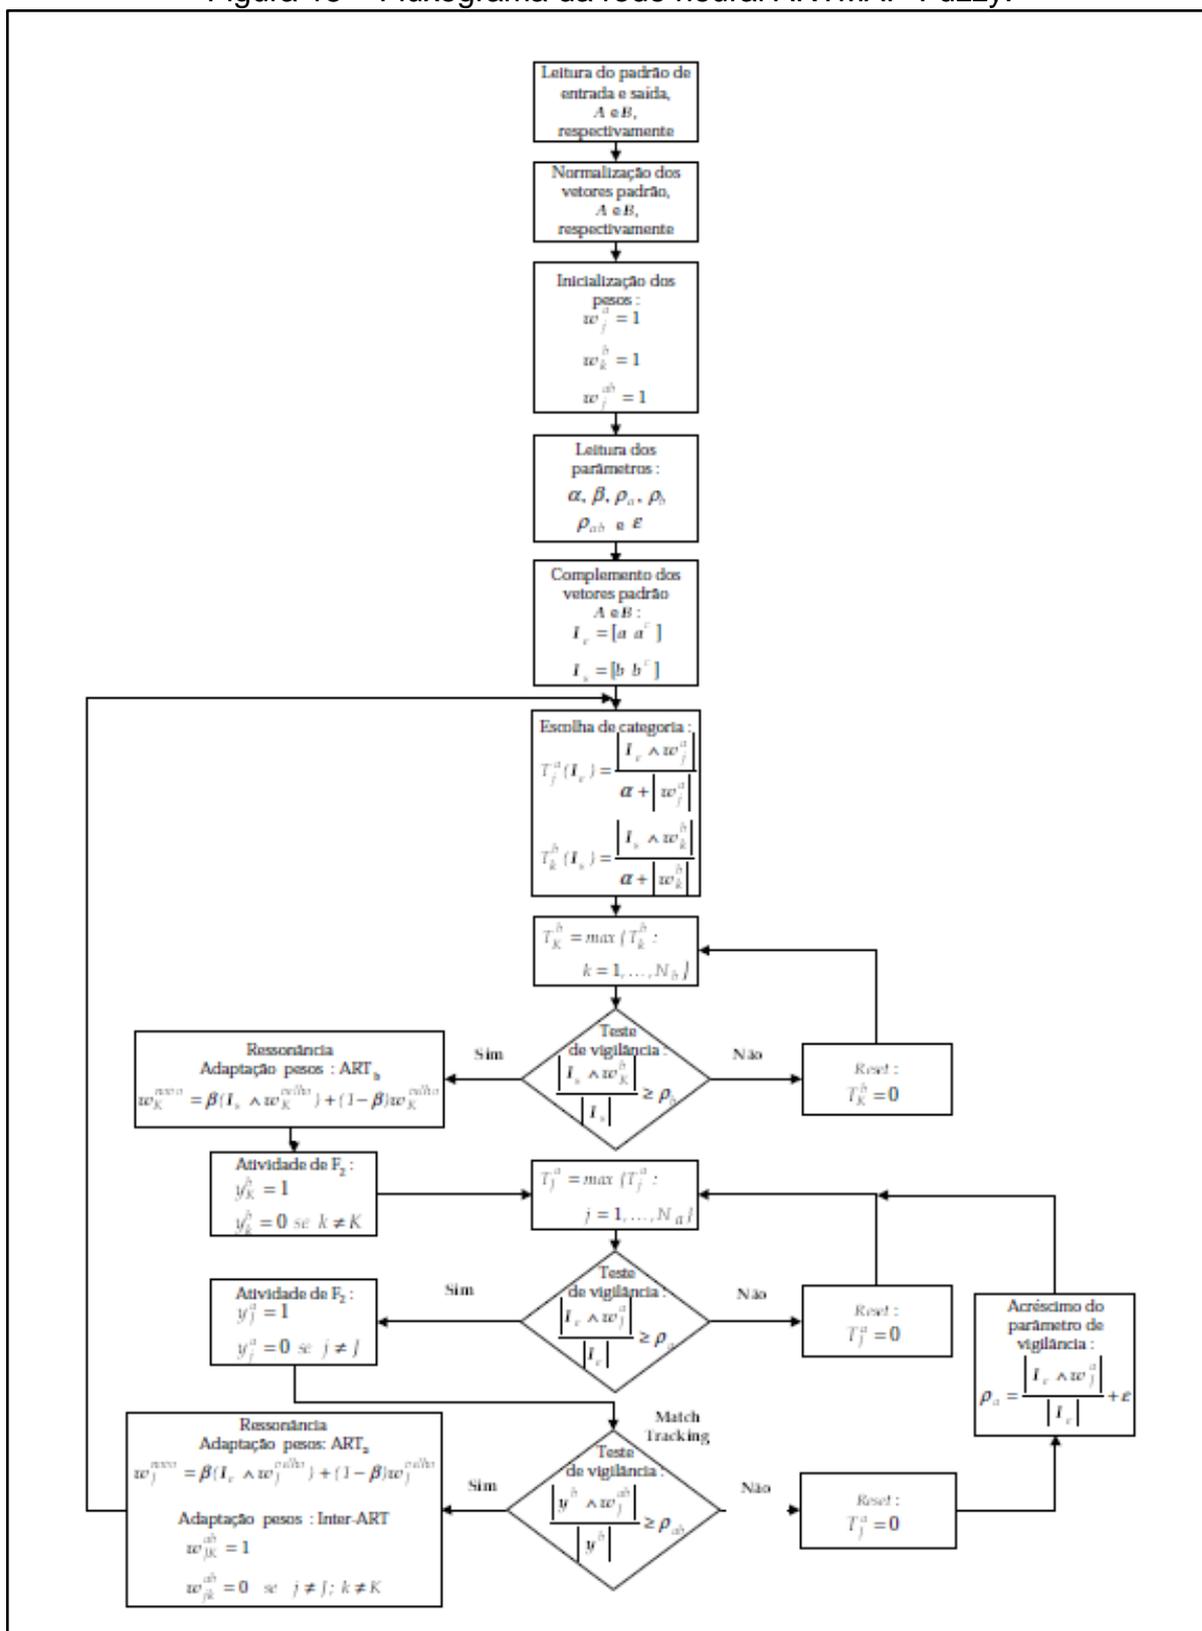
Portanto, antes de começar o treinamento da rede ART Fuzzy os dados de entrada passam por um pré-processamento a fim de normalizá-los, evitando a proliferação de categorias.

Lopes, Minussi e Lotufo (2005) destacam três parâmetros fundamentais para o processamento e treinamento da rede ART Fuzzy:

- Parâmetro de escolha: utilizado na seleção de categorias ( $\alpha > 0$ ).
- Taxa de Treinamento: que controla a velocidade da adaptação da rede ( $\beta \in [0,1]$ ). Quando  $\beta = 1$ , o treinamento é rápido, pois os pesos das conexões são valores ótimos e há poucos ciclos de aprendizagem. Normalmente, é utilizado quando não há muitas entradas novas na rede, mas que exige uma resposta imediata da mesma. Se  $\beta < 1$ , o treinamento é considerado lento e os pesos das conexões são forçados a se adaptarem lentamente.
- Parâmetro de vigilância ( $\rho \in [0,1]$ ): responsável por controlar a ressonância da rede. Se houver a ressonância da rede, o vetor de pesos é atualizado conforme a equação (10)

Com o objetivo de facilitar a compreensão do funcionamento da rede neural ARTMAP-Fuzzy, Lopes (2005) desenvolveu um fluxograma explicando cada etapa da realização do treinamento, o mesmo pode ser visualizado através da Figura 15.

Figura 15 – Fluxograma da rede neural ARTMAP-Fuzzy.



Fonte: (LOPES, 2005).

## 6 LÓGICA NEBULOSA

### 6.1 Principais conceitos

Zadeh (1965), da Universidade da Califórnia em Berkeley, ainda na década de 60, estruturou a lógica nebulosa para tratar e representar incertezas. A importância condicionada a ela é pelo motivo do mundo não ser constituído apenas de fatos absolutamente verdadeiros ou falsos, pois permite representar valores intermediários, que estão entre os valores verdadeiros e falsos da conhecida lógica clássica. A lógica clássica atribui o valor 1 (um) para aquilo que se considera completamente verdadeiro, e 0 (zero) para aquilo que se considera completamente falso. Porém a lógica nebulosa, também conhecida como difusa ou *fuzzy*, possui a vantagem de poder ser atribuída às informações que não são completamente verdadeiras ou falsas, podendo ter seu valor variando entre 0 e 1. A lógica nebulosa permite que se possa atribuir valores intermediários entre avaliações convencionais um sim/não, verdadeiro/falso, são as chamadas variáveis linguísticas, objetos ou palavras, que possui um entendimento mais adequado que os números. As variáveis nebulosas permitem que noções como copo meio cheio ou copo meio vazio sejam formulados matematicamente e processados pelo computador (LOPES, 2005).

A lógica *Fuzzy* tem como propósito central fazer com que as decisões tomadas a partir de sistemas computadorizados cheguem cada vez mais próximas das decisões humanas. Antes da chegada da lógica *Fuzzy*, não havia como processar computacionalmente informações vagas, imprecisas ou incertas (BIONDI; COELHO *et al.*, 2006).

### 6.2 Breve Histórico

Em 1965, Lotfi Askar-Zadeh, professor de Departamento de Engenharia Elétrica e Ciências da Computação da Universidade da Califórnia, apresentou a teoria de conjuntos *Fuzzy*, exatamente quando trabalhava classificação de conjuntos os quais não apresentavam limites bem definidos, devido ser suave e não abrupto a transição entre eles. Em diversos momentos, devido a relação de pertinência não ser bem definida, torna complicado a afirmação de que um elemento pertence ou não a um determinado conjunto. A ideia de Zadeh foi flexibilizar essa relação, e

então elaborar um grau de pertinência. Dessa forma um determinado elemento poderia pertencer parcialmente a um determinado conjunto (RIBEIRO e MELO, 2013). Este artigo é um marco da teoria dos conjuntos *Fuzzy*, e foi publicado em 1965 (ZADEH, 1965).

Segundo Ribeiro e Melo (2013), logo que publicada, a teoria da lógica *Fuzzy* recebeu fortes críticas da comunidade científica, principalmente por parte dos estatísticos norte-americanos. Apesar disso, outros pesquisadores compreendiam a potencialidade desta teoria, e trabalhos foram surgindo em diversos países, principalmente o Japão. Um caso prático é do professor Toshiro Terano da Universidade de Hosei, que em 1972, introduziu a ideia na comunidade de pesquisas japonesas, e logo começaram a aplicar a teoria em larga escala no processo de eletromecânica, nos elevadores e metrô.

Ribeiro e Melo (2013) ainda pontuam os seguintes tópicos ao longo da história:

- 1974 – Aplicação *Fuzzy* de locomotiva a vapor;
- 1976 – Controlador *Fuzzy* aplicado aos fornos das fábricas;
- 1985 – Produção do primeiro chip *Fuzzy* no laboratório Bell;
- 1987 – Fabricação de um helicóptero não-tripulado controlado por um controlador *Fuzzy*.
- 1988 – Primeiro sistema *Fuzzy* de comércio financeiro;
- 1989 – Pesquisas japonesas aplicando *Fuzzy* em sistemas de suporte a decisões e inteligência de robôs;
- 1990 – Primeira máquina de lavar roupas *Fuzzy*;

Com este breve histórico é possível perceber quão rápido foi sua evolução e que há uma área enorme para suas aplicações.

### **6.3 Fusão com Redes Neurais**

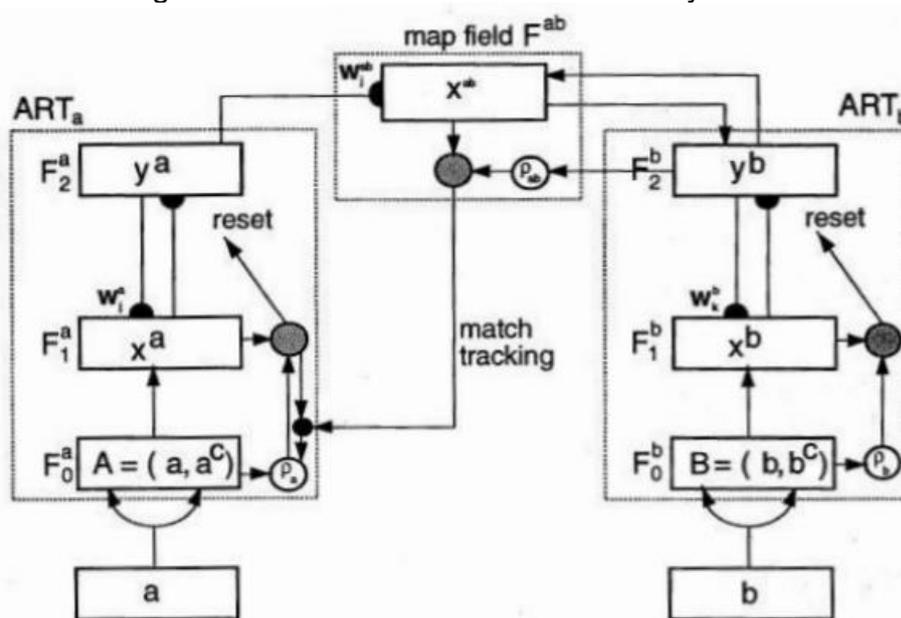
A rede neural ARTMAP *Fuzzy* é uma rede de fácil manuseio, já que possui poucos parâmetros e não requer qualquer elaboração específica do problema a ser solucionado além de não precisar de valores de peso inicial.

Para Lee (2005) as redes neurais artificiais e a lógica *Fuzzy* são duas tecnologias que se completam. Redes podem aprender a partir de dados, porém o

conhecimento representado pela RNA é de difícil compreensão. Ao contrário, sistemas *Fuzzy* são fáceis de compreender pois eles utilizam termos linguísticos, mas não é necessário aprender algoritmos.

A estrutura do treinamento da rede neural ARTMAP Fuzzy é mostrada na Figura 16.

Figura 16 - Rede neural ARTMAP Fuzzy



Fonte: (CARPENTER *et al.*, 1992).

Após a conclusão do treinamento da rede neural, ela estará apta para realizar o reconhecimento de novos padrões. Assim, é feito o diagnóstico da rede, onde novos padrões de entrada serão apresentados e ela deverá reconhecê-los, através do conhecimento já adquirido pela atualização do vetor de pesos. Portanto, para isto, executa-se apenas o código referente ao módulo  $ART_a$  que representa a entrada da rede e em seguida, a ressonância é verificada pelo módulo INTER-ART.

Existem as seguintes classificações dentro desse sistema:

- Sistemas *Fuzzy* modificados com treinamento supervisionado de RNA;
- Criação de redes neurais usando sistemas *Fuzzy*;
- Desenvolvendo funções de pertinência com redes neurais;
- Concatenação de redes neurais e sistemas *Fuzzy*.

## 7 DESENVOLVIMENTO E SIMULAÇÃO COMPUTACIONAL

### 7.1 Materiais e Métodos

O sistema de monitoramento e diagnóstico de falhas proposto neste trabalho foi composto por três módulos principais: a aquisição de dados, o treinamento e o diagnóstico da rede neural ARTMAP-Fuzzy.

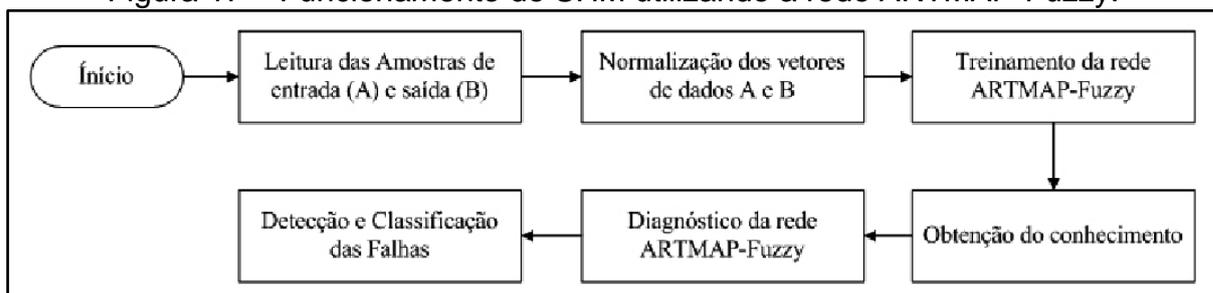
Inicialmente, a aquisição dos dados será obtida através da bancada experimental da engrenagem, sendo os sinais coletados para a realização do treinamento e o diagnóstico da rede neural. O conjunto de entrada da rede ARTMAP-Fuzzy é composto por sinais de resposta com o filtro de Wiener.

### 7.2 Sistema de Monitoramento e Diagnóstico de Falhas Estruturais

A fase de treinamento da rede neural ARTMAP-Fuzzy é realizada de forma *off-line* e é importante para ajustar os pesos e criar as categorias que serão utilizadas no diagnóstico dos dados. Nesta fase a rede é treinada com um conjunto de dados gerando uma quantidade de categorias igual ao número de sinais de entrada.

A fase de diagnóstico é realizada de forma *online*. Nesta fase um novo conjunto de sinais diferentes do conjunto de sinais utilizados na fase de treinamento deve ser apresentado a rede, e cada sinal será analisado individualmente. Todos os sinais são comparados com o conhecimento (categorias criadas na fase de treinamento) obtido pela rede neural ARTMAP-Fuzzy e assim, quando houver um casamento entre os padrões classifica-se em categoria o sinal apresentado a rede. Obtida a categoria correspondente a um determinado padrão é, portanto, identificado a intensidade (porcentagem de falha) e a localização da falha na estrutura. Lima *et al.* (2014) apresenta um fluxograma do funcionamento do sistema de monitoramento e diagnóstico de falhas, este pode ser observado através da Figura 17.

Figura 17 – Funcionamento do SHM utilizando a rede ARTMAP-Fuzzy.

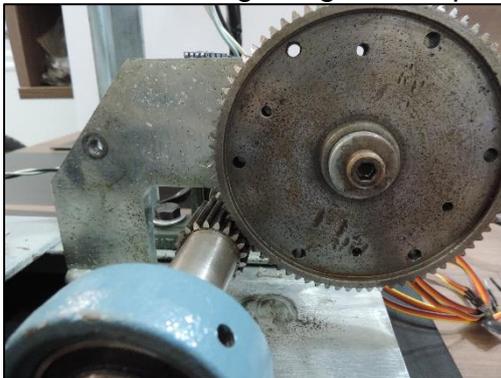


Fonte: (LIMA *et al.*, 2014).

### 7.3 Experimento

O experimento que representa o sistema dinâmico com engrenagens se baseia em um sistema simples de um rotor acoplado por polias a fonte de emissão de energia principal, um motor elétrico. Acoplado a este rotor, no eixo principal, se encontra a engrenagem principal, que está acoplado a outra engrenagem apoiada em um suporte. A figura 22 mostra o conjunto do rotor de engrenagens acopladas.

Figura 18 - Rotor com Engrenagens Acopladas



Fonte: Próprio autor.

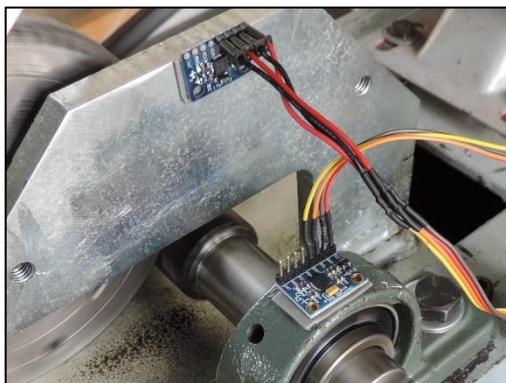
A figura 18 mostra o eixo principal acoplado a uma engrenagem, porém este suporta tem capacidade de fixação para duas engrenagens, sendo uma do lado esquerdo e a outra do lado direito. Neste experimento, será utilizada apenas uma única engrenagem para a detecção de falhas, que é a do lado direito.

Basicamente, o movimento do eixo principal é feito por um motor elétrico de 0,5cv – 60Hz que tem a velocidade do eixo do motor alterada por um inversor de frequência CFW 10 – WEG que atua de 0,1Hz a 60Hz. O eixo principal é de aço 1045 com diâmetro de 25,0 mm, a engrenagem do eixo principal tem altura máxima dos dentes próximos de 23,0mm, e as engrenagens de acoplamento tem a altura

máxima dos dentes próximos a 123,0 mm. Os mancais de rolamento, de apoio ao eixo principal, ambos são P205 UC205.

O experimento se inicia no setup de 4Hz do inversor de frequência, e dado a transmissão de energia do motor ao eixo principal das engrenagens, o movimento do eixo principal é transmitido a engrenagem. A variação da rotação do eixo principal ocorre a cada 2Hz, cuja valor de frequência máxima é 14Hz. Para a coleta do sinal de vibração foi utilizado o sensor MPU6050 que foram posicionados um no mancal e o outro no suporte da estrutura de fixação da engrenagem. A figura 23 mostra o posicionamento dos sensores MPU6050.

Figura 19 - Posicionamento dos Sensores MPU6050



Fonte: Próprio autor.

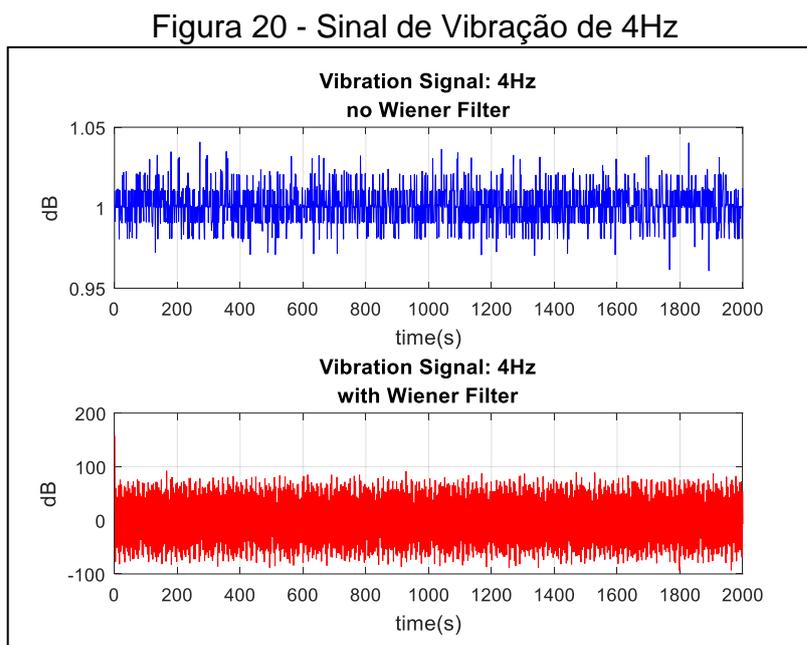
A figura 19 mostra a posição dos sensores, cuja finalidade é captar o sinal da estrutura e do mancal para uma análise posterior.

A amostra do sinal é de 4000 amostras, para a validação amostral, foi utilizado o teorema amostral finito. Através do teorema a quantidade mínima de amostras seria 1111, considerando um erro amostral de 2% e nível de confiança de 95%. Portanto, considera-se que as 4000 amostras podem ser utilizadas.

A formação do banco de dados segue a seguinte característica: o primeiro é o sinal de vibração de referência; o segundo é o sinal com falhas do sistema dinâmico. A composição do sinal com falhas do sistema dinâmico é dividida pela coleta da vibração no suporte de fixação da engrenagem, e no mancal de rolamento, conforme mostrado na figura 13. Cada sinal contém um tamanho de 1x 4000, e a coleta dos dados inicia com 4Hz a 14Hz, variando a cada 2Hz, controlado pelo inversor de frequência. Foram coletados 5 sinais de cada frequência. A condição de falha é determinada pela característica do acoplamento de engrenagem ao suporte, pois no

suporte, o furo de fixação da engrenagem, contém uma folga proposital, permitindo assim, o desbalanceamento da centragem da engrenagem de acoplamento.

O resultado do banco de dados deste experimento tem a matriz do sinal de referência de tamanho 30 x 4000, e a matriz do sinal com falhas tem o tamanho de 60 x 4000. A figura 20 mostra um exemplo do sinal de vibração de 4Hz.



Fonte: Próprio autor.

Note que o filtro de Wiener demonstrou a sua aplicabilidade quando atua na minimização do erro quadrático médio, e que pode ser visto na amplitude do sinal (dB). Deste modo, considere que todos os sinais coletados de vibração do mancal e do suporte da engrenagem, foram submetidos a aplicação do filtro de Wiener.

Dessa forma, constituiu-se uma base de dados de 90 amostras distintas, das quais 30 em condições normais e 60 nas demais condições. Estas quantidades são representadas na tabela 1.

**Tabela 1** - Sinais presentes na base de dados.

<b>Tipo de Amostra</b>	<b>Quantidade</b>
Condições normais	30
Engrenagem em falha	60
<b>Total</b>	<b>90</b>

Fonte: Próprio autor.

### 7.3.1 Aleatoriedade

Os dois vetores multidimensionais são submetidos à função *randperm* (permutação aleatória) do Matlab que aleatoriamente os divide na proporção de 70% das amostras para o módulo de treinamento, 15% de testes e os 15% restantes para o módulo de monitoramento. A aleatoriedade na separação dos dados que são quais dados serão utilizados no treinamento e na classificação elimina qualquer tentativa empreendida na manipulação dos resultados.

A tabela 2 contém o detalhamento do quantitativo dos dados utilizados por cada módulo.

**Tabela 2** - Quantidade de amostras utilizadas no treinamento e diagnóstico.

Tipo de Amostra	Qtde. Treinamento	Qtde. Diagnóstico
Condições normais	22	8
Engrenagem em falha	45	15
<b>Total</b>	<b>67</b>	<b>23</b>

Fonte: Próprio autor.

### 7.3.2 Treinamento do sistema

A fase de treinamento da rede neural ARTMAP-*Fuzzy* é responsável por adquirir o conhecimento que será aplicado no módulo de classificação. Pode ser realizada de forma *offline* (sem que o sistema esteja efetivamente em produção) e é importante para ajustar os pesos e criar as categorias que são utilizadas no módulo de diagnóstico dos dados. Nesta fase a rede é treinada com um conjunto de amostras, gerando uma quantidade de categorias igual ao número de sinais de entrada.

Conforme especificado anteriormente, o treinamento da rede ARTMAP-*Fuzzy* é do tipo supervisionado, ou seja, para cada amostra de entrada também é fornecido a saída desejada, dessa forma cria-se um conhecimento sobre as amostras do sistema.

Para ocorrer a ressonância entre as informações de entrada e saída codificadas no módulo ART<sub>a</sub> e ART<sub>b</sub>, é realizado o mapeamento  $b = f(a)$ ,  $a$  (entrada)  $\in \mathbb{R}^n$  e  $b$  (saída)  $\in \mathbb{R}^m$ , sendo  $f$  uma função desconhecida (linear ou não-linear)

multidimensional. Assim, o mecanismo inter-ART exerce a função de realizar o treinamento supervisionado.

Após a normalização dos vetores multidimensionais de entrada, os valores são compostos por números entre 0 e 1. Quanto à saída, foi adotada uma representação binária de dois dígitos. Cada combinação entre os dígitos de saída indica uma classificação quanto ao tipo da amostra analisada. Esta combinação se dá conforme segue:

- 00 – engrenagem em condições normais;
- 01 – engrenagem em condições de falha;

### **7.3.3 Classificação do sistema**

A fase de diagnóstico da rede neural ARTMAP-*Fuzzy* é realizada de forma *online* (com o sistema em produção) e tem como objetivo validar a utilização da estratégia proposta. Nesta fase um novo conjunto de amostras, diferente do conjunto de amostras utilizadas na fase de treinamento, deve ser apresentado à rede e cada amostra analisada individualmente. Todas as amostras são comparadas com o conhecimento (categorias criadas na fase de treinamento) obtido pela rede neural ARTMAP-*Fuzzy* e, assim, quando há ressonância entre os padrões, classifica-se em categoria a amostra apresentada à rede. Obtida a categoria correspondente a um determinado padrão é, finalmente, identificado a intensidade (porcentagem de falha) e a classificação do evento.

## 8 APLICAÇÕES E RESULTADOS

Neste capítulo são apresentados os resultados obtidos com a aplicação do método proposto na base de amostras simuladas.

### 8.1 PARÂMETROS UTILIZADOS

O algoritmo foi desenvolvido em ambiente MATLAB®, utilizando-se a versão 2022, e os testes realizados em um computador desktop padrão. Para avaliar a metodologia proposta foram adotados como indicadores de eficiência a precisão e o custo computacional, assumido proporcional ao tempo de processamento.

Na tabela 3 apresentam-se os valores dos parâmetros utilizados no processo de treinamento e diagnóstico do sistema de SHM. Deve-se destacar que os parâmetros foram escolhidos depois de exaustivos testes para se obter uma configuração ótima. Salienta-se que os testes foram realizados de forma qualitativa, mediante alteração dos valores dos parâmetros e observação dos resultados obtidos na fase de classificação.

**Tabela 3** – Valores dos parâmetros utilizados pela rede ARTMAP-*Fuzzy*.

Parâmetros	Valores
$\alpha$	0,1
$\beta$	1
$\rho_a$	0,9
$\rho_b$	1
$\rho_{ab}$	0,95
$\xi$	0,0001

Fonte: Próprio autor.

Observa-se que o valor do parâmetro de vigilância ( $\rho_a$ ) é de 0,9. Este valor alto é utilizado devido os sinais apresentarem uma distinção significativa, permitindo assim se obter um sistema mais “exigente” quanto a ressonância. Neste trabalho,  $\rho_a$  com valores menores que 0,5 reduz significativamente o índice de acerto do sistema.

## 8.2 RESULTADOS

Na tabela 4 apresenta-se os resultados obtidos pelo sistema de SHM ao processar as amostras geradas a partir do modelo numérico do trator. Observa-se que o sistema foi executado 100 vezes (*ite = 100*) e, em cada execução, foi gerado um registro das informações obtidas para a partir dela calcular a média simples dos valores.

**Tabela 4** – Resultados obtidos aplicando rede ARTMAP-*Fuzzy*.

Execuções 100	Treinamento	Classificação			Porcentagem (%)	
	Qtde. de Amostras	Qtde. de Amostras	Errada	Correta	Erro	Acerto
Média Simples	67	23	1	22	4,35	95,65

Fonte: Próprio autor.

De acordo com a tabela 4, as cem execuções do programa tiveram em média um índice de 95,65% de classificação correta das amostras analisadas. Os resultados obtidos pelos testes com o sistema de SHM utilizando RNA do tipo ARTMAP-*Fuzzy*, demonstraram um índice de acerto acima de 95%, cumprindo satisfatoriamente o objetivo proposto neste trabalho, comprovando sua eficiência quando aplicado ao monitoramento da integridade de estruturas mecânicas.

## 9 CONCLUSÃO

O sistema de diagnóstico de falhas em estruturas proposto neste estudo apresentou ótimos resultados, alcançando um índice de acerto de 95,65% quando executado com a sua melhor configuração. A rede neural ARTMAP-Fuzzy mostrou-se apta para ser utilizada como um sistema de tempo real, pois a fase de treinamento que é mais demorada pode ser realizada de forma *off-line*, enquanto a fase de diagnóstico obteve um tempo de resposta de 13 milissegundos por sinal analisado, tempo este aceitável para um sistema de tomada de decisão *online*. Portanto, conclui-se que o sistema para monitoramento de falhas em estruturas proposto a partir de uma rede neural artificial ARTMAP-Fuzzy é confiável e preciso quando utilizado com objetivo de manter a integridade de estruturas mecânicas.

Considerando que o objetivo deste trabalho foi o de desenvolver um método que pudesse determinar as falhas de um sistema de engrenagens acopladas, é possível de se determinar que o resultado foi obtido com sucesso, eficiência e acurácia.

## REFERÊNCIAS

ALTRAN, A. B. **Sistema inteligente para previsão de carga multinodal em sistemas elétricos de potência**. 2010. 86 f. Tese (Doutorado em Engenharia Elétrica)-Faculdade de Engenharia Elétrica, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2010.

ANAND, A.; RAM, M. **System reliability management: solutions and technologies**, Boca Raton: CRC, 2019. 277 p.

BIGUS, J. P. **Data mining with neural networks: solving business problems from application development to decision support**. New York: MacGraw-Hill Companies, 1996. 237 p.

BIONDI, L. N. *et al.* Minicurso de sistema especialista nebuloso. *In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL*, 38., Goiânia, 2006. **Anais [...]** [S. l.: s. n.], 2006. p. 2508-2543.

CARPENTER, G. A. *et al.* Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, Piscataway, v. 3, n. 5, p. 698-713, set 1992.

CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer Vision, Graphics, and Image Processing**, Maryland Heights, v. 37, n. 1, p. 54-115, 1987a.

CARPENTER, G. A.; GROSSBERG, S. ART2: self-organization of stable category recognition codes for analog input patterns. **Applied Optics**, Washington, v. 26, n. 23, p. 4919-4930, 1987b.

CARPENTER, G. A.; GROSSBERG, S. ART3: hierarchical search using chemical transmitters in self-organizing pattern recognition architectures. **Neural Networks**, Oxford, v. 3, n. 2, p. 129-152, 1990.

CARPENTER, G. A.; GROSSBERG, S. **Pattern recognition by self organizing**. Cambridge: MIT, 1991.

CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised real-time learning and classification of nonstationary data by a self-organizing neural network. **Neural Networks**, Oxford, v. 4, n. 5, p. 565-588, 1991a.

CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Networks**, Oxford, v. 4, n. 6, p. 759-771, 1991b.

CHEN, Y., LI, Y. **Computational intelligence assisted design: in industrial revolution 4.0**. Boca Raton: CRC Press, 2018. 527 p.

COLLINS, J. A.; BUSBY, H. R.; STAAB, G. H. **Mechanical design of machine elements and machines**: a failure prevention perspective. 2. ed. Hoboken: John Wiley & Sons, 2010. 912 p.

CROCKER, M. J. **Handbook of noise and vibration control**. Hoboken: John Wiley & Sons, 2007. 1569 p.

DA SILVA, I.N., SPATTI, D.H., FLAUZINO, R.A., LIBONI, L.H.B., ALVES, S.F.R., **Artificial neural networks**: a practical course. Switzerland: Springer International, 2017. 309 p.

DE SILVA, C. W. **Vibration**: fundamentals and practice. 3. ed. Boca Raton: CRC Press, 2006. 1061 p.

FELICI, G.; VERCELLIS, C. **Mathematical methods for knowledge discovery and data mining**. Convent Garden: IGI Global, 2008. 394 p.

FUKUSHIMA, K. Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. **Biological Cybernetics**, New York, v. 36, p. 193-202, 1980.

GROSSBERG, S. Adaptive pattern classification and universal recoding I: Parallel development and coding of neural feature detectors. **Biological Cybernetics**, New York, v. 23, n. 3, p. 121-134, 1976.

GROSSBERG, S. How does a brain build a cognitive code? **Psychological Review**, Washington, v. 87, p. 1-51, january 1980.

HALL, S. R. The effective management and use of structural health data. **International Workshop on Structural Health Monitoring**, Lancaster, p. 265-275, 1999.

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

HAN, J., KAMBER, M., PEI, J. **Data Mining concepts and techniques**. Waltham: Elsevier, 2012. 740 p.

HEBB, D. O. **The Organization of Behavior**: a neuropsychological theory. New York: Wiley, 1949.

HECHT-NIELSEN, R. Counterpropagation networks. **Applied Optics**, Washington, v. 26, n. 23, p. 4979-4984, dec. 1987.

HEO, S., LEE, J.H., Fault detection and classification using artificial neural networks, **IFAC-PapersOnLine**, [s. l.], v. 51, n. 18, p. 470-475, 2018. doi.org/10.1016/j.ifacol.2018.09.380.

HOLMAN, J. P. **Experimental methods for engineers**. 8 ed. New York: McGraw-Hill Companies, 2012. 769 p.

HOPFIELD, J. J. Neural network and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences of the USA**, Washington, v. 79, p. 2554-2558, 1982.

HUSSAIN, Z. M; SADIK, A. Z.; O'SHEA, P, **Digital signal processing: an introduction with MATLAB and Applications**. Heidelberg: Springer-Verlag, 2011.

INGLE, V. K.; PROAKIS, J. G. **Digital signal processing using MATLAB**. 3. ed. Stamford: Cengage Learning, 2012. 671 p.

INMAN, D.J., Engineering vibration. 3. ed. Upper Saddle River: Pearson Education, 2014. 720 p.

KOHONEN, T. Correlation Matrix Memories. **IEEE Transactions on Computers**, New York, v. c-21, n. 4, p. 353-359, apr 1972.

KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, v. 43, p. 59-69, 1982.

KOSKO, B. Bidirectional associative memories. **IEEE Transactions on Systems, Man and Cybernetics**, New York, v. 18, n. 1, p. 49-60, jan/feb 1988.

KROSE, B.; SMAGT, P. V. **An introduction to neural network**. Amsterdam: University of Amsterdam, 1996.

LEE, K. H. First course on fuzzy theory and applications. Berlin: Springer-Verlag Berlin Heidelberg, 2005.

LIMA, F. P. A. *et al.* ARTMAP-Fuzzy artificial neural network applied to the monitoring and fault identification in structural. **Lecture Notes in Information Technology**, Korea, v. 39, p. 3-9, 2013.

LIMA, F. P. A. *et al.* Diagnóstico de falhas em estruturas mecânicas utilizando rede neural artificial ARTMAP-Fuzzy. **Congresso de Matemática Aplicada e Computacional - CMAC**, Curitiba, 1, 2014. 1-6.

LOPES, M. L. M. **Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica**, 2005. 149. Tese (Doutorado em Engenharia Elétrica)-Faculdade de Engenharia Elétrica, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2005.

LYONS, R. G. **Streamlining digital signal processing: a tricks of the trade guidebook**, New Jersey: John Wiley & Sons, 2012. 466 p.

MACHADO, R. J.; ROCHA, A. F. **Handling knowledge in high order neural networks: the combinatorial neural network**. Rio de Janeiro: IBM Rio Scientific Center, 1989. (Technical Report, CCR076).

MARTINS, J. R. D. **Detecção e classificação de curtos-circuitos em sistemas de distribuição usando rede neural artificial ARTMAP nebulosa**. 2010. 84 f.

Dissertação (Mestrado em Engenharia Elétrica)-Faculdade de Engenharia Elétrica, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2010.

MATLAB (R2013a). 8.1 Version, Mathworks Company.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin Mathematical Biophysics**, New York, v. 5, p. 115-133, 1943.

MEIROVITCH, L. **Principles and techniques of vibrations**. Prentice Hall, Inc., Upper Saddle River, New Jersey, 1997. 694 p.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons**: an introduction to computational geometry. Cambridge: MIT Press, 1969.

OLIVEIRA, D.C.; CHAVARETTE, F.R.; LOPES, M.L.M., Damage diagnosis in an isotropic structure using an artificial immune system algorithm. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, Heidelberg, v. 41, p. 485-492, 2019. doi:10.1007/s40430-019-1971-9.

OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R. **Discrete-Time Signal Processing**. 2 ed. New Jersey: Prentice Hall, 1999. 897 p.

OUTA, R.; CHAVARETTE, F.R.; MISHRA, V.N.; GONCALVES, A.C.; ROEFERO, L.G.P.; MORO, T.C., Prognosis and fail detection in a dynamic rotor using artificial immunological system. **Engineering Computations**, Bingley, v. 37, n. 9, p. 3127-3145, 2020. doi.org/10.1108/EC-08-2019-0351.

OUTA, R.; CHAVARETTE, F.R.; TORO, P.F.; GONCALVES, A.C.; SANTOS, L.H., Prognosis and Detection of Experimental Failures in Open Field Diesel Engines Applying Wieners Artificial Immunological Systems. **Journal of Applied and Computational Mechanics**, Iran, v. 7, p. 1-12, 2021. doi: 10.22055/JACM.2020.34972.2525.

PALMER, D.; FISH, M. Evaluation of Methods or Calculating Effects of Tip Relief on Transmission Error, Noise and Stress in Loaded Spur Gears, *Gear Technology*, 01-12 p. 2012.

PARK. S.; KIM, S.; CHOI, J. Gear Fault Diagnosis Using Transmission Error And Ensemble Empirical Mode Decomposition. **Mechanical Systems and Signal Processing**, London, v. 108, n. 1, p. 262–275, 2018. DOI.org/10.1016/j.ymssp.2018.02.028.

RIBEIRO, D. T. M.; MELO, D. T. **Sistemas especialistas e lógica fuzzy**: análise de risco cardíaco. Mococa: [s. n.], 2013.

ROSENBLATT, F. The Perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, v. 65, p. 386-408, 1958.

ROSENBLATT, F. **Principles of neurodynamics**. Washington: Spartan Books, 1962.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. *In*: RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Parallel distributed processing**. Cambridge: MIT Press, v. 1, 1986. Cap. 8.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, London, v. 323, n. 9, p. 533-536, oct 1986.

SAKAI, K. **Nonlinear dynamics and chaos in agricultural systems**. Amsterdam: Elsevier Science, 2001.

SERRANO-GOTARREDONA, T.; LINARES-BARRANCO, B.; ANDREOU, A. G. **Adaptive resonance theory microchips: circuit design techniques**. New York: Springer, 1998.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

SILVESTRI, G., VERONA, F. B., INNOCENTI, M., NAPOLITANO, M. Fault detection using neural networks. *In*: IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS (ICNN'94), [s. l.], v. 6, n. 1, **Proceedings [...]** [S. l.: s. n.], 1994. p. 3796-3799 DOI: 10.1109/ICNN.1994.374815.

SMITH, J. D. **Gear noise and vibration**. 2. ed. New York: Marcel Dekker, 2003. 318 p.

TONELLI-NETO, M. S. **Formulação do controle preventivo em sistemas de distribuição de energia elétrica baseada na lógica fuzzy e redes neurais**. 2012. 137 f. Dissertação (Mestrado em Engenharia Elétrica)-Faculdade de Engenharia Elétrica, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2012.

VULLO, V. **Gears: Geometric and kinematic design**. Switzerland: Springer Nature, 2020. 880 p.

WANG, L.; FU, X. **Data mining with computational intelligence**. Springer-Verlag, Heidelberg, 2005. 280 p.

WERBOS, P. J. Beyond regression: new tools for prediction and analysis in the. [S. l.: s. n.]. 1974. (Thesis) - Harvard University, Harvard, 1974.

WIDROW, B.; HOFF, M. E. **Adaptive switching circuits**. IRE WESCON Convention Record. California: Institute of Radio Engineers. 1960. p. 96-104.

WOJCIECHOWSKA, W. S., **Technical System Maintenance: Delay-Time-Based Modelling**, Springer Nature, Gewerbestrasse, 2019. 361.

YE, N. **The Handbook of Data Mining**. Lawrence Erlbaum Associates, Mahwah, 2003. 722p.

YEGNANARAYANA, B. **Artificial Neural Networks**. New Delhi: Prentice-Hall of India, 2005.

ZADEH, L. A. Fuzzy sets. **Information and Control**, Maryland Heights, v. 8, p. 338-353, 1965.