

**UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA**

Renato Leitão Chaves dos Santos

**APLICAÇÃO DAS REDES NEURAIS
ARTIFICIAIS NO CONTROLE DE CARGAS
ATRAVÉS DO FREIO DE FOUCAULT**

Recife

2018

Renato Leitão Chaves dos Santos

**APLICAÇÃO DE REDES NEURAIIS ARTIFICIAIS NO
CONTROLE DE CARGAS ATRAVÉS DO FREIO DE
FOUCAULT**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco como parte dos requisitos para obtenção do grau de Mestre em Engenharia Elétrica. Área de Concentração: Processamento de Energia.

Orientador: Doutor, Ronaldo Ribeiro Barbosa de Aquino, *D.Sc.*

Recife

2018

AGRADECIMENTOS

Agradeço primeiramente ao Mestre Divino que, com sua infinita bondade, permitiu-me ter forças para seguir em frente nessa longa caminhada e também toda minha gratidão aos irmãos d'outro plano que me deram inspiração, paciência e sabedoria para enfrentar os obstáculos.

Um agradecimento especial para meus pais que me fortaleceram e estiveram comigo cada etapa do meu crescimento pessoal e profissional, formando a base para o meu caráter e sem os quais eu não teria alcançado nada. A eles minha eterna gratidão.

Outro para minha namorada que com toda sua paciência e dedicação me deu suporte, força, motivação e incentivos para que continuasse firme no desenvolver do trabalho. Também quero agradecer profundamente a meus familiares e em especial as minhas tias que, com seus cabelos brancos, forneceram-me ensinamentos para toda a vida, assim como um imenso agradecimento aos meus avós, presentes e aos que já partiram, que sem eles não poderia ter adquirido aprendizados tão valiosos.

Agradeço ao professor Ronaldo Ribeiro pelo grande companheirismo e paciência durante o período de aprendizado e também por ter me dado a oportunidade de trabalhar junto à equipe LEEQE e LDSP.

Com todo carinho um agradecimento aos amigos dos laboratórios, em especial aos amigos Davidson Marques, Jeydson Lopes, Guilherme Delgado, Roberto Menezes e Jonata Campelo pela amizade, suporte e incentivo.

À FACEPE, por todo o apoio financeiro oferecido durante o período da pós-graduação, tornando possível este trabalho.

Por fim, agradeço a todos os amigos e professores por me proporcionar mais conhecimentos e que de alguma forma contribuíram para o desenvolver da minha formação pessoal e profissional.

RESUMO

Os motores de indução são amplamente utilizados em sistemas industriais, entretanto, a implementação de um sistema de controle adequado para determinadas aplicações não é uma tarefa fácil, visto que não há conhecimento preciso o suficiente do comportamento das cargas acopladas ao seu eixo. Elas podem se modificar e, portanto, alterar toda a configuração dos processos. Desta forma o presente trabalho apresenta uma abordagem de um controle inteligente aplicado a um sistema de Freio Eletromagnético, também conhecido como Freio de Foucault, em que se busca investigar aspectos relacionados ao uso de Redes Neurais Artificiais (RNA's) em sistemas dinâmicos, envolvendo principalmente motores de indução. O sistema inteligente implementado é baseado em Redes Neurais Artificiais cujos dados de treinamento foram coletados através de ensaios realizados numa bancada de testes, que é controlada através de um Controlador Lógico Programável (CLP) e está localizada no Departamento de Engenharia Elétrica, mais especificamente no Laboratório de Eficiência Energética e Qualidade de Energia (DEE-LEEQE-UFPE). A partir do levantamento da planta do sistema e também do desenvolvimento de um controlador tradicional do tipo proporcional-integral, um controlador neural foi construído com o objetivo de controlar o sistema do Freio de Foucault e apresentar um desempenho satisfatório na malha de controle e desta forma evidenciar que controladores inteligentes tem uma excelente capacidade de adaptação em sistemas dinâmicos cujos parâmetros são modificados, justificando assim sua utilização em sistemas motrizes industriais.

ABSTRACT

Induction motors are widely used in industrial systems, however, the implementation of a suitable control system for certain applications is not an easy task since there is not enough precise knowledge of the behavior of the loads coupled to their axis. They can be modified and therefore change the entire process configuration. In this way the present work presents an approach of intelligent control applied to an Electromagnetic Brake system, also known as Foucault Brake, in which were investigated aspects related to the use of Artificial Neural Networks (RNA's) in dynamic systems, mainly involving motors of induction. The intelligent system implemented is based on Artificial Neural Networks whose training data were collected through tests carried out on a test bench, which is controlled through a Programmable Logic Controller (CLP). From the survey of the system plan and also the development of a proportional-integral type controller, a neural controller was constructed with the objective of controlling the Foucault Brake system and presenting a satisfactory performance, thus evidencing that intelligent controllers have an excellent adaptability in dynamic systems whose parameters are modified, thus justifying their use in industrial power systems.

LISTA DE FIGURAS

Figura 1 – Sistema de Controle	17
Figura 2 - Diagrama dos sistemas em Malha Aberta.....	17
Figura 3 - Diagrama dos sistemas em Malha Fechada	18
Figura 4 - Diagrama de Blocos da Ação Proporcional.....	20
Figura 5 - Diagrama de Blocos da Ação Integral em um controlador PI.....	21
Figura 6 - Diagrama de Blocos da Ação Derivativa em um controlador PD	22
Figura 7 - Curva de Resposta do Sistema ao Degrau	25
Figura 8 - Método de Sintonia de Smith.....	26
Figura 9 - Método de Sundaresan e Krishnaswamy	27
Figura 10 - Modelo do Neurônio Artificial	29
Figura 11 - Funções de Ativação.....	30
Figura 12 - Tipos de Arquiteturas das Redes Neurais Artificiais.....	32
Figura 13 - Rede MLP com uma camada intermediária.....	32
Figura 14 - Controlador Neural Pelo Modelo Direto	37
Figura 15 - Controlador Neural Pelo Modelo Inverso.....	38
Figura 16 - Esquema ilustrativo do Freio Eletromagnético de Foucault.....	40
Figura 17 - Correntes de Foucault em um disco metálico girante submetido a um campo magnético.	41
Figura 18 - Dínamo de Faraday, o primeiro gerador elétrico.....	43
Figura 19 – Sistemas Industriais de Comportamento de Conjugado Variável.....	45
Figura 20 - Foto da bancada do Freio Eletromagnético localizado no LAMOTRIZ – LEEQE – UFPE	47
Figura 21 - Disco metálico acoplado no eixo do motor	48
Figura 22 -Motor de indução trifásico WEG (à esquerda) e dados de placa (à direita)	49
Figura 23 - Tela de Visualização da Bancada do Freio Eletromagnético e dos parâmetros do Controlador Neural.....	50
Figura 24 - Etapas para Identificação do Sistema	51
Figura 25 - Curva dos parâmetros do modelo matemático de primeira ordem.....	52
Figura 26 - Malha de Controle com PI.....	57
Figura 27 - Simulink Control Desgin do MATLAB®	58
Figura 28 - Arquitetura da Rede Neural Proposta	67
Figura 29 - Malha de Controle com a RNA	68

LISTA DE GRÁFICOS

Gráfico 1 - Curva de Reação do Freio de Foucault em Malha Aberta	54
Gráfico 2 - Curva de Resposta Real do Sistema Versus Curva de Resposta da Função de Transferência Estimada	56
Gráfico 3 - Curvas de Resposta do FEF com o controlador PI	60
Gráfico 4 - Sobressinais das Curvas de Respostas do Sistema com o controlador PI.....	60
Gráfico 5 - Resposta do FEF Controlado Pelo PI Com Modificações Nas Velocidades de Referência.....	61
Gráfico 6 - Resposta do Sistema Controlado Pela RNA para carga de 0,1A	69
Gráfico 7 - Resposta do Sistema Controlado Pela RNA para carga de 0,2A	69
Gráfico 8 - Resposta do Sistema Controlado Pela RNA para carga de 0,3A	70
Gráfico 9 - Resposta do FEF Controlado Pelo PI e Pelo Controlador Neural.....	71
Gráfico 10 - Controlador PI e Neural Para Velocidade de 1675rpm e 0,1A de Carga no Freio	72
Gráfico 11 - Controlador PI e Neural Para Velocidade de 2238rpm e 0,2A de Carga no Freio.	73
Gráfico 12 - Controlador PI e Neural Para Velocidade de 2799rpm e 0,3A de Carga no Freio.	73
Gráfico 13 - Curva de Resposta Do Controlador Neural Para Velocidade de 1675rpm e 0,1A	75
Gráfico 14 - Erro entre o Valor de Referência e a Resposta do Controlador	75
Gráfico 15 - Curva de Resposta Do Controlador Neural Para Velocidade de 2238rpm e 0,2A	76
Gráfico 16 - Erro entre o Valor de Referência e a Resposta do Controlador	76
Gráfico 17 - Curva de Resposta Do Controlador Neural Para Velocidade de 2799rpm e 0,3A	77
Gráfico 18 - Erro entre o Valor de Referência e a Resposta do Controlador	77
Gráfico 19 - Resposta do Controlador Neural às variações de Velocidades Angulares.....	78
Gráfico 20 - Resposta do Controlador Neural às Variações de Cargas no Freio	79
Gráfico 21 - Resposta do Controlador Neural para Velocidade de 1675rpm e Variações de Carga do Freio	80
Gráfico 22 - Resposta do Controlador Neural para Velocidade de 2222rpm e Variações de Carga do Freio	81
Gráfico 23 - Resposta do Controlador Neural para Velocidade de 2222rpm e Variações de Carga do Freio	81

LISTA DE TABELAS

Tabela 1 - Dados de Placa do motor de indução da bancada do freio eletromagnético	49
Tabela 2 - Cenários de Simulações	59
Tabela 3 – Parâmetros de Desempenho do Sistema com o Controlador PI	61
Tabela 4 - Testes das Funções de Ativação	65
Tabela 5 - Testes dos Algoritmos de Treinamento.....	65
Tabela 6 - Testes do Número de Neurônios da Camada Oculta.....	66
Tabela 7 - Configuração Final da RNA.....	66
Tabela 8 - Parâmetros de Desempenho do Sistema com o Controlador Neural.....	70

LISTA DE SIGLAS E ABREVIATURAS

ACI – AÇÃO DE CORRENTES INDUZIDAS

CLP – CONTROLADOR LÓGICO PROGRAMÁVEL

FEACI – FREIO ELETROMAGNÉTICO POR AÇÃO DE CORRENTES INDUZIDAS

FEF – FREIO ELETROMAGNÉTICO DE FOUCAULT

GDM – ALGORITMO DO GRADIENTE DESCENDENTE COM MOMENTO

IA – INTELIGÊNCIA ARTIFICIAL

LAMOTRIZ – LABORATÓRIO DE SISTEMAS MOTRIZES

LEEQE – LABORATÓRIO DE EFICIÊNCIA ENERGÉTICA E QUALIDADE DE ENERGIA

LM – ALGORITMO DE LEVENBERG-MARQUADT

MSE – ERRO QUADRÁTICO MÉDIO

MIT – MOTOR DE INDUÇÃO TRIFÁSICO

MIT – MOTOR DE INDUÇÃO TRIFÁSICO

MITRGE – MOTOR DE INDUÇÃO TRIFÁSICO ROTOR GAIOLA DE ESQUILO

MLP – *MULTI LAYER PERCEPTRON*

PD – CONTROLADOR PROPORCIONAL DERIVATIVO

PI – CONTROLADOR PROPORCIONAL INTEGRAL

PID – CONTROLADOR PROPORCIONAL DERIVATIVO INTEGRATIVO

RNA – REDES NEURASIS ARTIFICIAIS

RP – ALGORITMO *RESILIENT PROPAGATION*

SP – *SETPOINT*

SUMÁRIO

1 INTRODUÇÃO	12
1.1 CONTEXTUALIZAÇÃO	12
1.2 OBJETIVO DO TRABALHO	14
1.3 ORGANIZAÇÃO TEXTUAL	14
2 SISTEMAS DE CONTROLES	16
2.1 BREVE INTRODUÇÃO AO CONTROLE AUTOMÁTICO	16
2.1.1 Sistema em Malha Aberta	17
2.1.2 Sistema em Malha Fechada	18
2.2 CONTROLADORES PID TRADICIONAIS	19
2.2.1 Controlador Proporcional (P)	20
2.2.2 Controlador Proporcional Integral (PI)	20
2.2.3 Controlador Proporcional Derivativo (PD)	21
2.2.4 Controladores PID	22
2.3 MÉTODOS DE IDENTIFICAÇÃO DE SISTEMAS	24
2.3.1 Identificação do Sistema Pelo Método de Ziegler e Nichols	24
2.3.2 Identificação do Sistema Pelo Método de Smith e Sundareshan/Krishnaswamy	26
2.3.3 Identificação do Sistema Pelo Método Computacional Iterativo	27
2.4 CONTROLADORES INTELIGENTES	28
2.4.1 As Redes Neurais Artificiais	28
2.4.2 O Neurônio Artificial e a Arquitetura das Redes	29
2.4.3 A Rede Perceptron Multicamadas	32
2.4.4 Processos de Aprendizagem e Algoritmos de Treinamento	33
2.5 REDES NEURAS EM SISTEMAS DE CONTROLE	36
2.5.1 Formas de Controle com as Redes Neurais Artificiais	36
3 BANCADA DO FREIO ELETROMAGNÉTICO	39
3.1 FREIO ELETROMAGNÉTICO POR AÇÃO DE CORRENTES INDUZIDAS	39
3.1.1 Descrição Básica	39
3.1.2 Princípio Físico	40
3.2 BREVE HISTÓRICO DOS FREIOS ELETROMAGNÉTICOS	42
3.3 BANCADA DO FREIO ELETROMAGNÉTICO	44
3.3.1 Apresentação da Bancada	44
3.3.2 Descrição da Bancada do Freio	46
3.3.3 Descrição do Motor de Indução Trifásico	48
3.3.4 Descrição da Bancada do Freio no Supervisório	49
4 METODOLOGIA E RESULTADOS	51
4.1 MODELO DO SISTEMA	51
4.1.1 Identificação do Modelo do Processo	51
4.1.2 Métodos de Identificação dos Parâmetros do Modelo	54
4.2 CONTROLE DO SISTEMA	56
4.2.1 Sistema com Controlador Convencional	56
4.2.2 Simulações com Controlador Proporcional-Integral	59
4.3 CONTROLE COM A REDE NEURAL ARTIFICIAL	62
4.3.1 Construção da Rede Neural Artificial	62
4.3.2 Simulação da Rede	68
4.4 RESULTADOS EXPERIMENTAIS	74

5 CONCLUSÃO E TRABALHOS FUTUROS.....	82
REFERÊNCIAS BIBLIOGRÁFICAS	85
ANEXOS	88
ANEXO I – TABELA DE DISPOSITIVOS DA BANCADA DO FREIO ELETROMAGNÉTICO – LEEQE – DEE – UFPE	88

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Os motores elétricos impulsionaram o desenvolvimento e progresso tecnológico do mundo, alterando o modo como é utilizada a eletricidade em favor das necessidades das pessoas. Os equipamentos de forças motrizes representam uma fração significativa do conjunto de maquinário industrial. Destaca-se que em média, de 50% a 60% das cargas elétricas numa indústria são compostas por motores elétricos. Outras regiões onde a indústria automobilística está mais presente, a porcentagem pode chegar até 70% (ELETROBRÁS/PROCEL, 2001). Em outras palavras, estas máquinas têm presença significativa no setor industrial.

Em especial, os motores de indução trifásicos têm papel fundamental nas atividades industriais e utilizam estas máquinas com finalidades diversas, desde a movimentação de cargas, sistemas de refrigeração e até mesmo confecção de peças. Dessa forma, as atividades fabris necessitam que os sistemas motrizes sejam robustos, com boa confiabilidade, tenha boa resposta a variações de cargas, sejam eficientes e principalmente tenham um baixo custo de aquisição e manutenibilidade.

Estes motores são utilizados em uma vasta área industrial, fábricas de alimentos e bebidas, por exemplo, possuem diversas máquinas rotatórias, que produzem latas, garrafas, recipientes, entre outros objetos. Este ramo industrial geralmente utiliza motores de pequeno porte, mas com construção específica para suas tarefas. Outro setor que utiliza os motores elétricos são as indústrias têxteis, que possuem máquinas com operações diferenciadas e delicadas, como por exemplo a confecção de roupas e tecidos. Ainda, os setores da indústria química, como fábricas de cimento, papel, borracha, tintas e plásticos apresentam um elevado número de motores elétricos com finalidades diferentes, por exemplo, bombas hidráulicas, compressores, ventiladores, esteiras transportadoras, agitadores, peneiras, entre outros.

De um modo geral os motores elétricos compõem sistemas de automação industrial que estão utilizando cada vez mais tecnologias que se direcionam para o aumento da qualidade dos processos e a eficiência dos métodos de produção (OGATA, 2010). Nestes sistemas automáticos, sistemas de controles são utilizados para automatizar a produção dando maior flexibilidade e confiabilidade as indústrias.

Paralelamente a evolução tecnológica, os processos industriais estão gradativamente aumentando o seu grau de complexidade, isto é, estão influenciando diretamente no modo

como os sistemas de controle são desenvolvidos. Assim, os requisitos necessários para um bom desempenho dos sistemas de controles também estão mudando com esta evolução.

Os sistemas de controle são construídos a partir de diversas abordagens e uma das mais utilizadas se baseia em modelos matemáticos do sistema que representam as principais características da dinâmica do processo (AGUIRRE, 2007). Apesar deste método de identificação de processo ser bastante usual para diversas situações, alguns casos a representação matemática dos processos se tornam complexas, devido principalmente as dinâmicas não-lineares ou fatores externos que influenciam no comportamento do sistema. Nos sistemas compostos por motores de indução, por exemplo, variações bruscas de cargas no eixo do motor acarretam em modificações significativas na dinâmica do processo, implicando que a modelagem matemática pode não representar fielmente todas as alterações.

Os controladores do tipo Proporcional-Integral (PI) são vastamente utilizados nos sistemas de automação com a finalidade de ajustar os processos de acordo com as modificações que se apresentam, no entanto, estes controladores não possuem boas respostas para situações transitórias e não fornecem robustez suficiente em relação às variações dos parâmetros do processo (WONG, 1998).

Diante desta perspectiva, os sistemas de controle que apresentam motores elétricos com dinâmicas variáveis são abordados através de técnicas alternativas aos controladores tradicionais do tipo proporcional-integral. Uma destas abordagens é a utilização da inteligência artificial, que é utilizada para consolidar o controle do sistema sem a necessidade do conhecimento prévio do mesmo, tais como Redes Neurais Artificiais (RNA's) e Lógica *Fuzzy* (HAYKIN, 2007).

Controladores que utilizam as Redes Neurais Artificiais estão sendo foco de vários estudos nos mais variados sistemas de controles, devido principalmente, a diversos fatores como, por exemplo, a sua facilidade de implementação e demonstração de bons resultados (TAJNE; SRIVASTAVA, 2012). A grande vantagem dos controladores com inteligência artificial é sua adaptação às variações da dinâmica dos processos, visto que as redes neurais são alternativas bastante eficientes por sua capacidade de aprendizagem.

De acordo com o artigo de Hamza Mediouni (2017) um controlador neural tem boa performance no controle de um sistema que apresenta variações paramétricas e distúrbios desconhecidos, quando é comparado a um controlador PI (MEDIOUNI et al., 2017). Neste artigo o sistema foi aplicado a um veículo elétrico e foi constatado que o controlador neural tem uma boa eficiência.

1.2 OBJETIVO DO TRABALHO

Este trabalho tem como objetivo projetar um controlador inteligente constituído por uma Rede Neural Artificial que atenda as solicitações de conjugado em um motor de indução trifásico quando há variações de cargas em seu eixo. Todo o experimento será realizado numa bancada de testes conhecida como Freio de Eletromagnético Foucault que é controlado por um sistema supervisorio.

Um modelo matemático do sistema será obtido através de experimentos que permitem um estudo analítico por simulações computacionais que auxiliam o desenvolvimento do controlador. Através de técnicas de modelagem de sistemas apresentadas pelas referências bibliográficas, um modelo matemático do sistema foi elaborado e testado através do software computacional MATLAB ®. Posteriormente, tendo em vista a veracidade das respostas das simulações do modelo, um controlador do tipo proporcional integral foi utilizado para controlar o sistema e servir de base para o desenvolvimento de um controlador inteligente. O controlador neural foi desenvolvido também através de um modelo computacional e através de simulações a rede neural foi testada. Posteriormente o controlador neural será implementado no sistema real para verificação dos resultados obtidos.

Por fim, a partir das respostas do sistema em estudo, várias análises qualitativas do controlador neural serão realizadas para demonstrar que a utilização de inteligência artificial em sistemas de controle apresenta respostas satisfatórias, destacando também que há boa adaptação às variações de parâmetros do sistema. As curvas de respostas do sistema controlado pela rede neural foram construídas a partir dos dados coletados pelo sistema supervisorio e então foi possível uma análise detalhada do desempenho do controlador neural proposto.

1.3 ORGANIZAÇÃO TEXTUAL

- **Capítulo 2** – Nesta seção é realizada uma revisão dos sistemas de controle utilizados e abordam as principais características dos controladores do tipo Proporcional-Integral. Ainda, é introduzido alguns conceitos sobre RNA's e sua importância em sistemas de controle, seus algoritmos de treinamento e arquitetura.

- **Capítulo 3** – Este capítulo apresenta o que é o Freio de Foucault, como surgiram os primeiros experimentos e seu funcionamento baseado no eletromagnetismo. Também é mostrado uma visão geral deste equipamento como simulador de cargas e como o sistema deste trabalho é controlado através de um sistema supervisório.
- **Capítulo 4** – Neste capítulo são apresentados os resultados obtidos do trabalho, desde a obtenção de um modelo matemático, sua modelagem computacional e finalmente a implementação do controlador no sistema real.
- **Capítulo 5** – Por fim, este capítulo apresenta as conclusões obtidas neste trabalho destacando a importância das RNA's como controladores em sistemas industriais, realçando que a robustez deste controlador é de fato relevante. Também são apresentadas as sugestões para trabalhos futuros correlacionados à área.

2 SISTEMAS DE CONTROLES

2.1 BREVE INTRODUÇÃO AO CONTROLE AUTOMÁTICO

No atual contexto da nossa sociedade o avanço da ciência e da engenharia contribuiu para que o controle automático dos sistemas seja fundamental para os processos industriais modernos de produção. Neste cenário, a engenharia de controle tem papel primordial pois permite que os sistemas sejam automatizados, garantido uma melhor qualidade de produção, agilidade, versatilidade e segurança.

O controle automático desempenha um papel fundamental no avanço da engenharia e da ciência (OGATA, 2010). Este controle se tornou peça chave dos processos industriais e é essencial em operações como o controle de parâmetros dos processos, como por exemplo, pressão, temperatura, umidade, vazão, velocidade, entre outros. As indústrias que atuam nas áreas de petróleo, química, alimentos, cerâmicas, siderurgia, celulose e papel, têxtil e geração de energia utilizam sistemas de controles para administrar e manter as variáveis dos processos. Desta forma os instrumentos de medição e controle permitem manter e controlar as variáveis em condições mais adequadas e precisas do que se elas fossem controladas por um operador humano (FAVARO, 2012).

Com o desenvolvimento tecnológico, a automação industrial produz maneiras para otimizar o desempenho dos sistemas, desde aspectos técnicos (produtividade, segurança, qualidade, etc.) quanto aspectos financeiros (maximização do lucro, minimização dos custos, diminuição de operações manuais e repetitivas, etc.). Com o mercado econômico altamente competitivo, as empresas se veem obrigadas a melhorar continuamente a produtividade de suas plantas industriais (CAMPOS, 2006). Diante disto os sistemas de controle são fundamentais para se aumentar a rentabilidade dos processos tomando como base o controle, automação e otimização dos setores fabris.

Um sistema de controle consiste em subsistemas e processos (ou plantas) construídos com o objetivo de se obter uma saída desejada com bom desempenho, para uma entrada específica fornecida (NISE, 2011). Em outras palavras, o sistema de controle visa manter a variável controlada no valor determinado, comparando o valor da variável medida, ou condição a controlar, com o valor desejado (*setpoint*) e desta forma faz-se correções em função do desvio existente entre estes dois valores, sem a necessidade da intervenção de um operador (BEGA *et al*, 2006). A Figura 1 ilustra o processo de forma simplificada.

Figura 1 – Sistema de Controle



Fonte: Próprio Autor

Nesta figura está representado, de forma ilustrativa, como o sistema de controle mapeia as entradas e saídas para atender à solicitação dada na entrada do processo.


Os sistemas de controle são classificados em dois tipos: sistemas em malha aberta e sistemas em malha fechada.

2.1.1 Sistema em Malha Aberta

Um sistema em malha aberta pode ser considerado como um sistema que o controle é independente do valor de saída, em outras palavras, não há uma realimentação conectando a saída do processo à entrada do mesmo. Os sistemas em malha aberta não são capazes de corrigir perturbações e são comandados simplesmente pela entrada (NISE, 2011).

Neste tipo de sistema de controle o sinal de saída não exerce qualquer ação no sinal de controle e desta forma a saída do processo não é medida nem comparada com o valor de referência de entrada. A Figura 2 ilustra um sistema em malha aberta cuja saída do processo não tem relação com sua entrada.

Figura 2 - Diagrama dos sistemas em Malha Aberta




Fonte: Adaptado de OLIVEIRA (1999)

Pode ser observado na Figura 2 que não há controle do sistema quando há presença de perturbações externas. Na prática, o controle em malha aberta somente deve ser utilizado em sistemas que a relação de entrada e saída do sistema sejam conhecidas e que não ocorra perturbações significativas.

2.1.2 Sistema em Malha Fechada

Já no sistema de controle em malha fechada o sinal de saída possui um efeito direto na ação de controle. A este efeito é dado o nome de retroação ou realimentação (*feedback*). Em sistemas com esta configuração o sinal do erro corresponde à diferença entre os valores de referência e o valor da saída do processo e este sinal é introduzido no controlador de modo a modificar o processo e assim reduzir a discrepância entre o valor desejado (*setpoint*) e a saída do processo (OLIVEIRA, 1999). A Figura 3 representa um sistema de controle em malha fechada cuja realimentação conecta a saída do processo com o valor de referência.

Figura 3 - Diagrama dos sistemas em Malha Fechada



Fonte: Adaptado de OLIVEIRA (1999)

Uma vantagem dos sistemas em malha fechada é o fato de que o uso da realimentação faz com que a resposta do sistema seja insensível a distúrbios externos e variações dos parâmetros do sistema (OGATA, 2010). Isto se deve ao fato de que quando ocorre alguma mudança do sistema, a realimentação em malha fechada modifica a configuração do controlador de modo a adaptar o processo para esta nova mudança, assim sendo, a saída do processo também é alterada para o novo sistema.

As vantagens do sistema em malha aberta que se destacam são a simplicidade de construção e fácil manutenção, são menos dispendiosos em relação ao sistema de malha fechada, não apresentam problemas de estabilidade e são adequados somente quando existem dificuldades da medição da saída o quando não é possível economicamente (OGATA,2010).

2.2 CONTROLADORES PID TRADICIONAIS

Os controladores dos processos industriais são os principais responsáveis em manter as variáveis de um sistema em valores pré-determinados, ou seja, são eles que modificam o comportamento da planta a fim de alcançar os valores de referência desejados (*setpoint's*). Estes controladores são um importante recurso que visam atender a automação industrial ajustando os parâmetros do sistema para que o processo atinja um bom desempenho.

Os controladores do tipo PID (Proporcional-Derivativo-Integrativo) são os que têm papel em destaque no setor industrial pois eles apresentam uma série de fatores que são atrativos para sua aceitação (CAMPESTRINI, 2006). São utilizados para controles de nível de fluidos, monitoramento de temperatura, controle da velocidade dos motores, controle da pressão, pH, entre outros. Estes controladores são vastamente utilizados devido principalmente por se tratar de um método de controle simples, de baixo custo, facilidade de implementação e principalmente por atender a uma grande maioria dos processos industriais.

A sintonia de um controlador é fundamental para o seu correto e adequado funcionamento, pois se trata de determinar seus parâmetros internos para realizar um bom controle do processo. No entanto, apesar desta sintonia dos controladores ser um trabalho simples, ele é relativamente impreciso, já que muitas vezes é realizado experimentalmente e por tentativas e erros.

Uma das principais vantagens dos controladores PID é que quando não é possível uma abordagem analítica do processo, ou seja, não se conhece o modelo matemático da planta, ainda assim é possível obter a sintonia dos seus parâmetros por meio de testes experimentais. No entanto estas sintonias apresentam pequenos erros que podem ocasionar diferenças significativas na otimização de um sistema de controle.

O controlador PID é uma combinação de três ações diferentes: Proporcional (P), Integral (I) e Derivativo (D). Estes controladores podem ser configurados para atuarem individualmente ou juntos, como o controlador puramente Proporcional (P), o controlador Proporcional Integrador (PI) e Proporcional Derivativo (PD).

Cada um destes apresenta características distintas e resultam em controles diferenciados e a escolha depende principalmente do sistema a ser controlado. A ação de cada controlador em uma malha fechada influencia principalmente no erro do sistema, isto é, as ações de controle diferenciam-se entre si pela forma como diminui a diferença entre o valor real do sistema e o valor desejado (*setpoint*).

2.2.1 Controlador Proporcional (P)

O controlador proporcional utiliza uma constante proporcional K_p para relacionar o sinal de saída do sistema e o erro. O comportamento da resposta do sistema com esta ação é diminuir o tempo de subida, diminuir o erro do regime permanente e uma apresenta uma pequena variação do tempo de acomodação, entretanto, ocorre um pequeno aumento do sobressinal, tornando o controlador mais oscilatório. A relação no domínio do tempo e no domínio da frequência (após aplicação da transformada de Laplace) são dadas pelas seguintes equações (OLIVEIRA, 1994):


$$u(t) = K_p * e(t) \quad (1)$$

$$U(s) = K_p * E(s) \quad (2)$$

Onde $u(t)$ e $U(s)$ são as saídas do controlador, K_p é o ganho proporcional do controlador e $e(t)$ e $E(s)$ são os erros do processo dado pela diferença entre valor real e *setpoint*.

A Figura 4 apresenta um diagrama de blocos do controlador proporcional em um sistema cuja função de transferência é G_p e cujo valor de referência é SP.

Figura 4 - Diagrama de Blocos da Ação Proporcional



Fonte: Adaptado de OLIVEIRA, 1994

2.2.2 Controlador Proporcional Integral (PI)

O controlador proporcional integral consiste basicamente em eliminar as oscilações características de um sistema puramente proporcional, ou seja, através da integração do sinal do erro a ação integral apresenta oscilações descendentes e com pequenas amplitudes. A ação integral não é considerada uma ação de controle se estiver isolada da ação proporcional. A equação a seguir mostra a relação dos ganhos do controlador PI.


$$u(t) = K_p * e(t) + K_i * \int_0^t e(t) dt \quad (3)$$

Aplicando a transformada de Laplace à equação 3, considerando as condições iniciais como nulas, a função de transferência do controlador PI no domínio da frequência é:

$$U(s) = K_p \left(1 + \frac{1}{T_i s} \right) \quad (4)$$

Onde K_i é o ganho da ação integral. A Figura 5 a seguir ilustra o diagrama de blocos de um controlador PI cujo K_i é dada pela divisão do K_p e T_i , em que T_i é o tempo integral.

Figura 5 - Diagrama de Blocos da Ação Integral em um controlador PI



Fonte: Adaptado de OLIVEIRA, 1994

2.2.3 Controlador Proporcional Derivativo (PD)

A ação derivativa, semelhante a ação integral, também não pode ser empregada separadamente de uma ação proporcional. Esta ação de controle atua basicamente na taxa de variação do sinal do erro, isto é, seus principais efeitos são: pequena variação no tempo de subida, diminuição do tempo de estabilização, pequena variação do erro em regime permanente e diminuição do sobressinal. Um detalhe importante é que esta ação só ocorre quando o erro é oscilante, ou seja, quando o sistema estiver em regime permanente seu efeito é nulo.

A equação abaixo apresenta a relação dos ganhos do controlador PD.


$$u(t) = K_p * e(t) + K_d * \frac{de(t)}{dt} \quad (5)$$

A partir da aplicação da transformada de Laplace na equação 5 a função de transferência do controlador PD no domínio da frequência é dada por:

$$U(s) = K_p(1 + T_d s) \quad (6)$$

Onde $K_d = K_p T_d$ é o ganho da ação derivativa e T_d é o tempo derivativo. A Figura 6 mostra um diagrama de blocos de um controlador PD atuando num sistema em malha fechada.

Figura 6 - Diagrama de Blocos da Ação Derivativa em um controlador PD



Fonte: Adaptado de OLIVEIRA, 1994

2.2.4 Controladores PID

O controlador PID é uma junção das ações de controle proporcional, integral e derivativa e a equação que representa seus parâmetros de controle é dada por:

$$G_c(s) = K_p + \frac{K_i}{s} + K_d s \quad (7)$$

Ou ainda

$$G_c(s) = K_p \left(1 + \frac{1}{T_i s} + T_d s \right) \quad (8)$$

Onde K_p é o ganho proporcional, T_i o tempo integral e T_d o tempo derivativo.

É possível determinar os parâmetros dos controladores PID para um determinado sistema em malha fechada através de diversas técnicas de sintonia, este processo identifica como a dinâmica de um processo reage aos esforços de controle, e de acordo com requisitos de desempenho, determina os parâmetros do PID necessários para a eliminação de erros (VANDORE, 2006)

A sintonia dos parâmetros dos controladores PID é de fundamental importância para um sistema de controle e seu aprofundamento abrange um vasto leque de estudos na área de controladores e sistemas de controle. Como o objetivo deste trabalho não é de alcançar os

melhores parâmetros do controlador deste trabalho, então não foi necessária uma abordagem detalhada no que diz respeito a este assunto.

2.3 MÉTODOS DE IDENTIFICAÇÃO DE SISTEMAS

Na determinação dos melhores parâmetros de um determinado controlador é necessário ter um conhecimento prévio da planta em estudo, em outras palavras, para realizar a sintonia de um controlador deve ser conhecido o comportamento do sistema a fim de que se obtenha o melhor ajuste para minimizar o erro.

A modelagem e identificação matemática de um sistema nada mais é do que a representação dos aspectos principais através de uma relação particular de variáveis. Este modelo matemático permite um estudo mais detalhado do sistema trabalhado e permite avaliações qualitativas sobre diversas perspectivas (AGUIRRE, 2007).

Diante disto, existem diversos métodos de modelagem e identificação dos sistemas e neste trabalho serão abordados alguns destes métodos:


- 1 – Método de Ziegler e Nichols;
- 2 – Método de Smith;
- 3 – Método de Sundaresan/Krishnaswamy;
- 4 – Método Iterativo Computacional.

2.3.1 Identificação do Sistema Pelo Método de Ziegler e Nichols

O método proposto por Ziegler Nichols é baseado na resposta do sistema a um sinal de degrau. Este método é limitado a sistemas em que a resposta ao degrau é estável, isto é, não oscilatório e cuja saída da planta tenha um formato tipo “S” (OGATA, 2010).

Com o sistema em malha aberta, aplica-se um sinal de degrau e a partir da avaliação gráfica do sistema é obtido alguns parâmetros relevantes. A curva é caracterizada por duas constantes, o atraso L e a constante de tempo T (OGATA, 2010). Estes parâmetros são obtidos quando é desenhado uma linha reta tangente ao ponto de inflexão da curva de formato S, intersectando a tangente com o eixo dos tempos e uma reta constante K .

Figura 7 - Curva de Resposta do Sistema ao Degrau



Fonte: Adaptado de OGATA, 2010

Com a obtenção dos valores das constantes L , K e T é possível a obtenção dos parâmetros da função de transferência de um sistema que é representado matematicamente por uma função de primeira ordem dada pela seguinte equação:

$$G_c = \frac{K e^{-Ls}}{Ts + 1} \quad (9)$$

O valor do parâmetro K é dado pela relação entre a variação do sinal de entrada (degrau) e a variação do sinal de saída:

$$K = \frac{\Delta y}{\Delta u} \quad (10)$$

Onde Δy corresponde ao sinal de saída e Δu corresponde ao sinal de entrada.


Já o valor do atraso de tempo L é calculado pelo intervalo de tempo entre a aplicação do degrau na entrada do processo e o instante em que a reta tangente toca o eixo em $c(0)$. Por fim a constante de tempo T é dada pela diferença entre o tempo que a reta tangente toca a reta constante e o valor do atraso.

$$T = t - L \quad (11)$$

2.3.2 Identificação do Sistema Pelo Método de Smith e Sundaresan/Krishnaswamy

No método identificação do modelo matemático do sistema de Smith, também é feita uma avaliação na curva de resposta do sistema ao degrau, sendo que neste caso é marcado dois instantes de tempo t_1 e t_2 que correspondem aos pontos em 28,3% e 63,2% da curva de resposta do sistema (COELHO, 2004).

Figura 8 - Método de Sintonia de Smith



Fonte: Adaptado de COELHO, 2004

Desta forma, calcula-se os parâmetros da função de transferência de primeira ordem através das equações a seguir:

$$K = \frac{\Delta y}{\Delta u} \quad (12)$$


$$T = 1,5 (t_2 - t_1) \quad (13)$$

$$L = t_2 - T \quad (14)$$

Onde Δu é o valor do degrau, Δy os valores dos pontos na curva de resposta e os respectivos valores de tempo t_1 e t_2 .

Semelhante ao método de Smith, o método de Sundaresan e Krishnaswamy também determina dois instantes de tempo t_1 e t_2 sendo que estes são estimados a partir da curva de resposta ao degrau correspondentes aos pontos de 35,3% e 85,3% respectivamente (COELHO, 2004). Estes pontos estão mostrados na Figura 9.

Figura 9 - Método de Sundaresan e Krishnaswamy



Fonte: Adaptado de COELHO, 2004

Os parâmetros da função de transferência são calculados pelas seguintes equações:

$$K = \frac{\Delta y}{\Delta u} \quad (15)$$

$$T = 0,67 (t_2 - t_1) \quad (16)$$

$$L = 1,3t_1 - 0,29t_2 \quad (17)$$

2.3.3 Identificação do Sistema Pelo Método Computacional Iterativo

Além dos métodos analíticos já comentados, existem diversos outros métodos que esboçam um modelo matemático para os sistemas reais que são explorados por literaturas diversas na área de modelagem de sistemas.

Alguns destes processos de identificação de sistemas utilizam métodos computacionais que aproximam com significativa precisão o comportamento dos sistemas reais por funções matemáticas, dentre eles o *System Identification Toolbox*TM do MATLAB®. Este programa é usado para construção de modelos matemáticos de sistemas dinâmicos a partir de dados de entrada e saída medidos. Ela permite facilmente a criação de funções no domínio do tempo ou no da frequência e ainda tem uma série de ferramentas que fornecem ajustes finos para melhorar o modelo do sistema que está sendo trabalhado.

2.4 CONTROLADORES INTELIGENTES

Para a grande maioria dos sistemas industriais os controladores tradicionais atuam de forma bastante satisfatória e atendem aos principais requisitos solicitados nos processos. Desde os primeiros projetos os controladores PID mantiveram posição de destaque devido a sua simplicidade, robustez e facilidade de implementação. Entretanto, com o avanço da tecnologia e com a velocidade do surgimento de novos componentes eletrônicos, aliado ao desenvolvimento da computação, os sistemas industriais sofreram grandes mudanças e conseqüentemente os processos tornaram-se mais complexos.

Diante desta perspectiva surgiram alternativas paralelas aos controladores tradicionais PID, dentre eles podem ser citados os controladores que utilizam inteligência artificial, ou controladores inteligentes. O termo inteligência artificial (IA) remetem a sistemas que percebem e interagem com o ambiente em que se encontram, eles aprendem a interpretar as informações e passam a atingir os objetivos e realizar tarefas específicas através de uma adaptação flexível (ANDREAS, 2018).

Neste cenário as Redes Neurais Artificiais (RNA's) tem sua importância em destaque na área de sistemas de controle, visto que suas características intrínsecas têm atraído a atenção de diversos pesquisadores pelo mundo. Elas vêm sendo utilizadas amplamente em controles de sistemas industriais e apresentam ganhos significativos em termos de eficiência nos processos.

2.4.1 As Redes Neurais Artificiais

As redes neurais artificiais são paradigmas computacionais que apresentam um modelo matemático inspirado na estrutura do sistema nervoso de organismos inteligentes e que adquirem o conhecimento através da experiência (ROCHA, 2006).

Uma RNA é um processador composto por unidades de processamento simples, que têm a capacidade de armazenar conhecimento experimental e torna-lo possível para uso (HAYKIN, 2001). Em outras palavras as redes neurais artificiais são sistemas que mimetizam o comportamento e a estrutura do cérebro humano, se adequando as limitações computacionais, visto que não se assemelham ao sistema nervoso dos seres vivos. Uma de suas principais características é a capacidade de interagir com o meio em que se encontra e adaptar-se a ele, além de processar informações maciçamente, tornando-a uma poderosa ferramenta computacional e multidisciplinar.

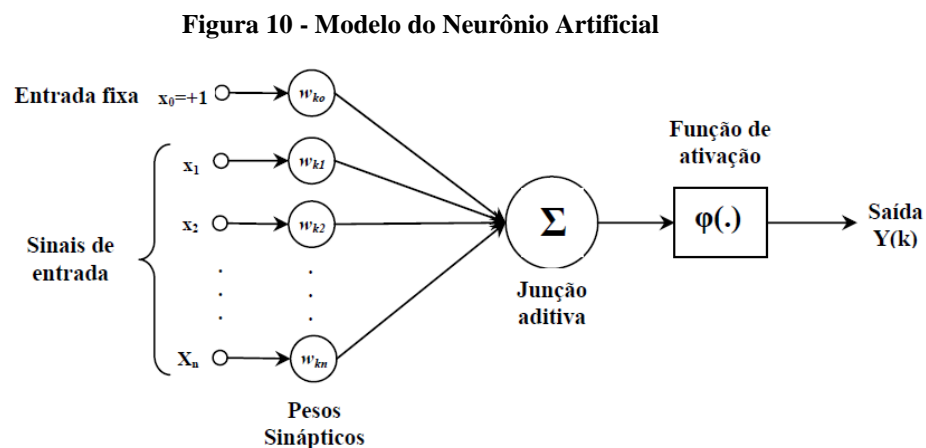
As redes neurais se assemelham ao cérebro humano em dois aspectos principais:

- Através de uma aprendizagem o conhecimento é adquirido pela rede neural pelo ambiente, isto é, dados externos são coletados e através de um algoritmo de aprendizagem os pesos sinápticos são ajustados para alcançar um objetivo desejado.;
- Pesos sinápticos, ou forças de conexão entre neurônios, são utilizados para armazenar o conhecimento adquirido (HAYKIN, 2001).

Semelhante ao cérebro humano as redes neurais são estruturadas com um grande número de elementos individuais simples (neurônios) que se interconectam uns com os outros e formam redes capazes de armazenar e transmitir informação provida do exterior. Além disto, uma característica muito importante das RNA's é a auto-organização ou plasticidade, isto é, através de um processo de aprendizado é possível alterar os padrões de conexão entre os neurônios de forma semelhante ao sistema nervoso biológico (TAFNER, 1996).

2.4.2 O Neurônio Artificial e a Arquitetura das Redes

As redes neurais apresentam uma unidade de processamento singular que é conhecida como neurônio artificial, que simula o comportamento de um neurônio biológico. Este neurônio possui entradas, que correspondem às conexões sinápticas com outras unidades similares e uma saída, cujo valor depende de uma soma ponderada. O neurônio artificial é mostrado na Figura 10 sendo uma generalização do modelo desenvolvido por McCulloch e Pitts (MCCULLOCH, 1943)



Fonte: Adaptado de HAYKIN, 2001

Este modelo inclui o *bias* que favorece ou limita a possibilidade de ativação do neurônio, os pesos sinápticos representados por w , que amplificam os sinais recebidos pelas entradas, um somador para somar os sinais de entradas, ponderando as respectivas sinapses e a função de ativação φ que modela a forma como o neurônio responde a excitação, restringindo a amplitude do sinal de saída de um neurônio.

O modelo artificial do neurônio em termos matemáticos pode ser descrito pelas seguintes equações.


$$V_k = \sum_{j=1}^m w_{kj}x_j + b_k \quad (18)$$

$$y_k = \varphi(v_k) \quad (19)$$

Onde os sinais de entrada são $x_1, x_2, x_3, \dots, x_n$, o *bias* b_k , os pesos sinápticos são $w_1, w_2, w_3, \dots, w_n$ associados ao neurônio k definido em um campo local induzido v_k como sendo a saída do combinador linear e finalmente a função de ativação $\varphi(\cdot)$ que limita os valores ponderados dos pesos e resulta na saída do neurônio y_k .

As funções de ativação do modelo proposto por McCulloch e Pitts podem ser funções matemáticas já conhecidas e que estão apresentadas na figura abaixo.

Figura 11 - Funções de Ativação



Através de um sistema composto pelos neurônios artificiais, as redes neurais artificiais possuem elevado poder de processamento por utilizarem um número elevado de elementos processadores com alta taxa de conectividade entre si. De forma geral, as RNA's podem ser modelos computacionais com propriedades particulares cujas principais características são:

- Capacidade de operação em paralelo;
- Não é preciso ter um conhecimento a priori de eventuais modelos matemáticos que descrevem o comportamento de determinada aplicação;
- Tem a habilidade de aprender a partir da experiência através de um algoritmo de aprendizagem determinado;
- É tolerante a falhas sob condições adversas, ou seja, são capazes de modificar seu desempenho de acordo com a modificação do seu meio, adaptando seus pesos sinápticos.

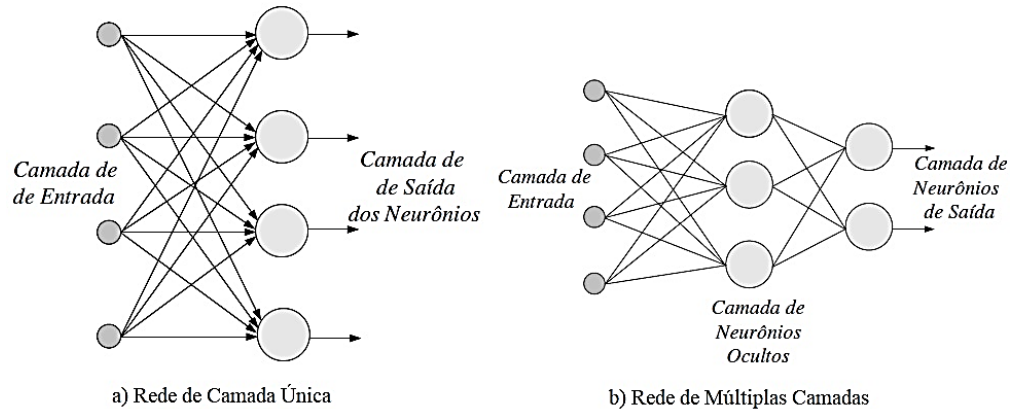
As disposições dos neurônios e a forma como eles estão interconectados é o que se chama de arquitetura da rede neural. De acordo com a aplicação da RNA e com o algoritmo de aprendizagem usado para treinar a rede, a estrutura de uma rede neural é escolhida com base nas modificações dos principais itens da arquitetura da rede neural:

1. Camadas Intermediárias;
2. Quantidade de Neurônios;
3. Função de Ativação;
4. Algoritmo de Aprendizado.

Uma rede neural é formada por diversos neurônios conectados e a forma como estão dispostas as conexões sinápticas é o que diferencia as arquiteturas das redes neurais. Os neurônios estão organizados em forma de camadas e quando existe apenas uma única camada, ela se refere a camada de saída dos neurônios. No entanto, quando existem uma ou mais camadas intermediárias (ou ocultas) de neurônios então significa que a rede apresenta arquitetura de múltiplas camadas.

A Figura 12 mostra algumas arquiteturas de redes neurais que apresentam uma única camada e com múltiplas camadas intermediárias.

Figura 12 - Tipos de Arquiteturas das Redes Neurais Artificiais




Fonte: Adaptado de HAYKIN, 2001

2.4.3 A Rede Perceptron Multicamadas

As redes MLP (*Multilayer Perceptron*) tem uma estrutura bem definida de um conjunto de unidades sensoriais (nós de fonte) que constituem a camada de entrada, uma ou mais camadas ocultas de nós computacionais (neurônios) e a camada de saída. (HAYKIN, 2001).

O fluxo de informações desta rede segue estritamente uma única direção, no sentido da entrada para saída, existindo ligações nas saídas dos nós de um nível inferior para entradas dos nós de um nível superior, não existindo conexões entre os elementos de uma mesma camada. A este processamento de informações é conhecido como *feed-forward*. A Figura 13 mostra uma rede MLP.

Figura 13 - Rede MLP com uma camada intermediária



Fonte: Adaptado de HAYKIN, 2001

2.4.4 Processos de Aprendizagem e Algoritmos de Treinamento

No desenvolvimento deste trabalho foram utilizados três algoritmos de treinamento para definir qual a melhor arquitetura da RNA do sistema de controle inteligente abordado. Portanto breves considerações serão realizadas a respeito dos algoritmos utilizados, que foram:

- Levenberg-Marquadt (LM);
- Resilient Propagation (RP);
- Gradiente Descendente com Momento (GDM).

O treinamento ou processo de aprendizagem de uma rede neural artificial consiste basicamente em ajustar os pesos sinápticos da rede (w) de forma que a aplicação de um conjunto de entradas produza um conjunto de saída desejadas. O processo de aprendizagem pode ser entendido como um procedimento de ajustes de parâmetros da rede, baseado em estímulos apresentados com a finalidade de alcançar objetivos determinados.

Os principais tipos de aprendizagem são o aprendizado supervisionado e o não-supervisionado. O primeiro, e o mais comum nos treinamentos da RNA, as entradas e saídas desejadas de uma rede neural são fornecidas por um supervisor externo, também chamado de professor. Este processo consiste em coletar dados do ambiente, fornecer à rede neural este conjunto de informações e também fornecer a resposta desejada para estes dados (tarefa do professor). Assim, os pesos sinápticos e bias são ajustados conforme a regra definida pelo algoritmo de aprendizagem e desta maneira obtém-se uma rede neural treinada.

O aprendizado não-supervisionado não há a presença do professor, ou seja, não são fornecidos a rede dados ou exemplos do problema. Neste processo a aprendizagem se dá pela modificação dos pesos da rede em resposta as entradas fornecidas a ele, definido pelo algoritmo de aprendizagem. Neste caso tem-se, por exemplo, o treinamento por competição, em que os neurônios vão se ajustando de maneira que só ficam ativos os que apresentarem padrões semelhantes. Os que não foram ativados podem ser ajustados ou não no treinamento.

Dentre os algoritmos utilizados no treinamento da rede neural deste trabalho, se destaca o Algoritmo de Levenberg-Marquadt (LM). Neste treinamento a atualização dos pesos se dá pela seguinte equação:

$$\Delta w = [J^T J + \mu I]^{-1} J^T e \quad (20)$$

Esta equação é uma modificação do método de Gaus-Newton (HAGAN, 1994)

Pode ser observado nesta equação que quando μ é grande o algoritmo torna-se o da máxima declividade, enquanto para um μ pequeno o algoritmo torna-se o de Gauss-Newton (HAGAN 1994).

Uma grande vantagem deste algoritmo é sua velocidade no tempo de iterações e apresenta erro bem pequenos, o que significa bons resultados. No entanto para problemas que envolvam grande número de informações, ele não consegue obter resultados tão bons.

Outro dos algoritmos utilizados é o Resilient Propagation, que apresenta um eficiente esquema de aprendizagem, o qual tem como característica uma adaptação do peso da rede neural baseada na informação do gradiente local.

Cada peso é alterado individualmente através de um valor adaptativo Δ_{ij} , cujo valor é baseado na função do erro de acordo com a seguinte regra de aprendizagem:

$$\begin{cases} \eta^+ \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E^{(t-1)}}{\partial w_{ij}} \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ \eta^- \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E^{(t-1)}}{\partial w_{ij}} \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{caso contrário} \end{cases} \quad (21)$$

Em que $0 < \eta^- < 1 < \eta^+$

A regra da adaptação dos pesos ocorre quando cada vez que a derivada parcial da função erro em relação ao peso w_{ij} muda seu sinal, indicando que a última atualização foi tão grande que fez o erro da função ultrapassar o mínimo local, então o valor Δ_{ij} é decrementado pelo fator $\eta^- \Delta_{ij}$. Se a derivada mantém seu sinal, então Δ_{ij} permanecerá o mesmo a fim de acelerar a convergência.

Desta forma, sabendo os valores adaptativos para cada peso, a atualização ocorre da seguinte maneira:

$$\Delta w_{ij}^{(t)} = \begin{cases} -\Delta_{ij}, & \text{se } \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ +\Delta_{ij}, & \text{se } \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (22)$$

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} + \Delta w_{ij}^{(t)}$$

De acordo com a equação, quando a derivada for positiva o peso é diminuído, caso contrário, o peso é aumentado. Todavia, se a derivada parcial muda de sinal, ou seja, o passo previsto foi grande a ponto de passar do mínimo desejado, então a atualização do peso deve ser revertida de acordo com a seguinte equação:

$$\Delta w_{ij}^{(t)} = -\Delta w_{ij}^{(t-1)}, \quad \text{se } \frac{\partial E^{(t-1)}}{\partial w_{ij}} \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \quad (23)$$

Portanto, é de se esperar que no próximo passo essa derivada mude de sinal mais uma vez. Para que não ocorra isto, então deve-se fazer $\frac{\partial E^{(t-1)}}{\partial w_{ij}} = 0$ na regra de adaptação de $\Delta w_{ij}^{(t)}$.

Este algoritmo apresenta em uma de suas vantagens o fato de que para a grande maioria dos problemas não é necessário fazer uma boa escolha dos parâmetros iniciais a fim de garantir a convergência, mas usa-se $\Delta w_{ij}^{(0)} = 0,1$ para iniciar e satura-se os valores máximos e mínimos de Δ_{ij} para evitar problemas de *overflow* e *underflow*.

Por fim, utilizou-se o algoritmo Gradiente Descendente com Momento (GDM) para realizar o treinamento do controlador inteligente. Este algoritmo surgiu para aumentar a taxa de aprendizagem do algoritmo *backpropagation* (HAYKIN, 2001). O algoritmo *backpropagation* é baseado na aproximação para a trajetória no espaço de pesos calculada pelo método da máxima declividade, ou seja, quanto menor o parâmetro da taxa de aprendizagem η menor será a variação dos pesos sinápticos da RNA de uma iteração para outra e mais suave a trajetória no espaço dos pesos. Esta melhoria ocorre a uma taxa de aprendizagem lenta. Entretanto, caso a taxa de aprendizagem seja muito grande, as modificações nos pesos serão muito grandes e pode tornar a rede instável, ou seja, muito oscilatória. Uma maneira de aumentar a taxa de aprendizagem sem que ocorra a instabilidade da rede é incluir um termo chamado de momento, cuja equação é dada a seguir:

$$\Delta w_{ij}(n) = \alpha \Delta w_{ij}(n-1) + \eta \delta_j(n) y_1(n) \quad (24)$$

Onde α é um número positivo conhecido como momento. Este termo contribui para uma melhoria no comportamento da aprendizagem do algoritmo.

O algoritmo de treinamento GDM apresenta uma desvantagem em relação aos demais pelo fato de ser lento em termos do tempo de iteração, tornando-o pouco utilizado.

2.5 REDES NEURAIIS EM SISTEMAS DE CONTROLE

Paralelamente aos controladores tradicionais PID, as redes neurais artificiais também exercem funções em sistemas de controle. Existem diversas aplicações na literatura técnica que mostram sistemas reais controlados por controladores inteligentes. As aplicações destes controladores inteligentes apresentam diversos aspectos que são atrativos, dentre eles: controle flexível, isto é, poder operar em diferentes condições, adaptação em novas condições quando há mudança no processo, utilização em uma vasta gama de processos diferentes, desde controle de pequenos sistemas eletrônicos até sistemas industriais de grande porte (ZURADA, 1992).

Algumas aplicações conhecidas pelo uso das redes neurais artificiais estão no processamento digital de sinal, onde há reconhecimento de voz e caracteres, compressão de dados, diagnósticos médicos, identificação de códigos, entre outros. Outras aplicações conhecidas são os controles dinâmicos, utilizados em manipuladores mecânicos, braços robóticos, veículos auto-guiados e processos da agroindústria como geo-rastreamento, monitoramento via satélite, etc. (HASSOUN, 1995). Ainda, existem diversas aplicações em sistemas de decisão, como por exemplo, análises financeiras, identificação de doenças, análises de risco em sistemas monetários e numerosas outras possibilidades.


As redes neurais podem atuar em sistemas de controle de diversas maneiras, diferenciando-se umas das outras pela forma como o sinal de controle atua na planta numa malha fechada.

2.5.1 Formas de Controle com as Redes Neurais Artificiais

Para a modelagem de sistemas dinâmicos, existem basicamente duas configurações de controladores neurais para atuar em sistemas de controle, um modelo direto e um modelo inverso (BROWN, 1994).

No modelo direto, a RNA “copia” as características de um controlador convencional e o sinal de saída é aplicado diretamente na planta do sistema. Neste caso, os sinais de entrada do controlador neural seria os mesmos sinais de entrada de um controlador convencional. O treinamento da RNA associa-se a um modelo direto, no qual a ação no sinal de entrada da rede deverá levar à entrada da planta um sinal de controle correspondente a ação de um controlador tradicional. A figura a seguir ilustra através de diagramas de bloco uma concepção simples de um sistema de controle em que o controlador é baseado em redes neurais artificiais.

Figura 14 - Controlador Neural Pelo Modelo Direto

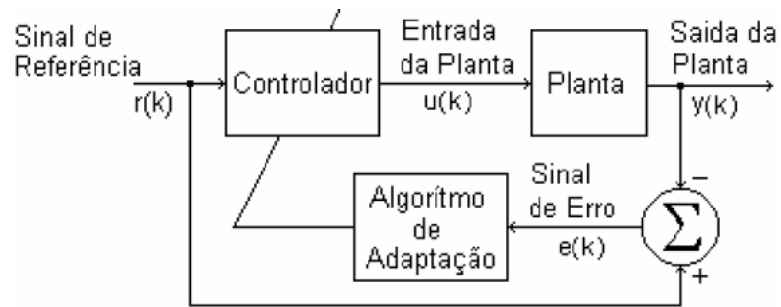


Fonte: Adaptado de WIDROW, 1996

Neste modelo pode ser observado que o sinal de saída da planta é comparado com o sinal de referência, cujo controlador realizará os ajustes necessários para então emitir um sinal de entrada à planta, configurando uma realimentação convencional de um sistema.

Já no modelo inverso, na concepção dos controladores neurais, a rede neural procura um mapeamento entre a resposta desejada e a respectiva ação de controle. Nesta abordagem a entrada do controlador neural é interligada com a saída da planta real e assim, a saída da rede deverá ser treinada para apresentar os respectivos valores de entrada dos pares de entrada/saída admitidos para o treinamento, o que caracteriza um processo de aprendizagem de um modelo inverso. Neste modelo o algoritmo de treinamento adapta os pesos de acordo com o erro.

A Figura 15 também ilustra através de diagrama de blocos uma malha fechada de um sistema de controle através do modelo inverso de controladores neurais.

Figura 15 - Controlador Neural Pelo Modelo Inverso

Fonte: Adaptado de WIDROW, 1996

Neste sistema é notado que o sinal de erro da planta retorna para o controlador neural como uma entrada para a rede, ajustando os pesos para forçar uma ação de controle que leve a saída da planta a ter o menor erro possível e então convergir para o sinal de referência.

3 BANCADA DO FREIO ELETROMAGNÉTICO

Neste capítulo é apresentado a bancada de simulação de cargas por ação das correntes de Foucault presente no Laboratório de Sistemas Motrizes (LAMOTRIZ) do LEEQE - UFPE. Será descrito detalhadamente a bancada do Freio Eletromagnético de Foucault com todos os aspectos importantes que sustentam a base para o desenvolvimento do trabalho.

Também será apresentado como é o funcionamento de um Freio por Ação de Correntes Induzidas (ACI), um breve histórico de como foi desenvolvido este equipamento e também quais as suas aplicações. Além disto, será realizada uma breve revisão das equações do eletromagnetismo que fundamentam a teoria do assunto.

3.1 FREIO ELETROMAGNÉTICO POR AÇÃO DE CORRENTES INDUZIDAS


3.1.1 Descrição Básica

O Freio Eletromagnético de Foucault (FEF) é basicamente um dispositivo eletromecânico rotativo, que quando acionado por um motor elétrico, apresenta em seu eixo um conjugado resistente ao motor que é ajustável através de uma corrente de controle de excitação (PEREIRA, 2006). Ele é comumente utilizado onde é necessário a frenagem dinâmica, contínua e controlada, ou seja, com extrema precisão. Exemplos desta utilização são os guinchos e guindastes, pontes rolantes, alguns tipos de elevadores, frenagem de veículos de grandes proporções como trens e metrô e mais recentemente, no reaproveitamento de energia em frenagens de veículos elétricos.

Um exemplo usual deste dispositivo são as locomotivas que utilizam sapatas polares localizadas na parte inferior com a finalidade de frear ou diminuir sua velocidade. A redução da velocidade se dá quando estas sapatas são aproximadas dos trilhos criando correntes induzidas de Foucault, que produzem um campo magnético oposto que cria um conjugado de frenagem responsável pela desaceleração.

Quando o Freio de Foucault é construído de forma dinamométrica (disco metálico oscilante apoiado em um suporte) ele é utilizado para medir o conjugado resistente e assim levantar curvas características de motores a ele acoplado, sendo, portanto, um instrumento de simulação de cargas e para ensaios de máquinas motrizes. A Figura 16 mostra um desenho esquemático de um Freio de Foucault utilizado como simulador de carga para motores.

Figura 16 - Esquema ilustrativo do Freio Eletromagnético de Foucault



Fonte: Adaptado de PEREIRA (2006)

O Freio de Foucault utilizado neste trabalho se caracteriza como um simulador de carga e tem como principal objetivo levantar os parâmetros do motor de indução que está acoplado no seu eixo.

3.1.2 Princípio Físico

Um Freio de Foucault, ou Freio Eletromagnético por Ação de Correntes Induzidas (FEACI), tem seu princípio de funcionamento baseado no eletromagnetismo, mais especificamente na Lei de Indução de Faraday, que relaciona a variação de um campo magnético à criação de uma diferença de potencial elétrico (GRIFFITHS, 1999).

$$\vec{\nabla} \times \vec{E} = - \frac{\partial \vec{B}}{\partial t} \quad (25)$$

Em que \vec{E} é a intensidade de campo elétrico e \vec{B} é a densidade de fluxo magnético

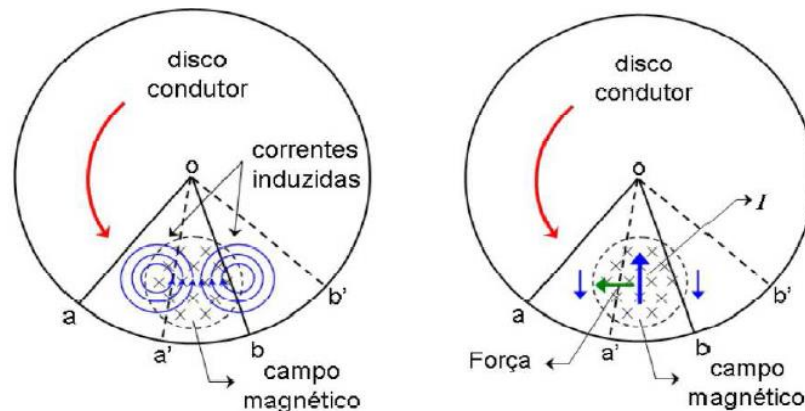
Desta lei, traduz-se que uma força eletromotriz e uma corrente elétrica são induzidas em um condutor metálico quando este é exposto a um campo magnético variante no tempo. A polaridade da corrente induzida deve ser tal que o campo magnético gerado por ela se oponha ao campo magnético que a gerou, sendo esta relação conhecida como Lei de Lenz.

As correntes induzidas são produzidas em qualquer condutor metálico maciço que esteja em movimento num campo magnético ou esteja submetido a um campo magnético de intensidade variável. No material condutor existem percursos fechados que permite a circulação da corrente elétrica. Em cada percurso circulam correntes induzidas e estas correntes são chamadas de correntes de Foucault. As correntes de Foucault se apresentam em

pequenos circuitos fechados concêntricos e circulares e em cada ponto do interior do condutor estas correntes se anulam entre si.

A Figura 17 ilustra um esquema simplificado da circulação das correntes de Foucault que originam uma força contrária ao movimento do disco.

Figura 17 - Correntes de Foucault em um disco metálico girante submetido a um campo magnético.



Fonte: Adaptado de SOUZA, 2005

A intensidade destas correntes induzidas de Foucault tem relação direta com a resistência do condutor metálico (disco), com a magnitude do campo magnético que a origina e com a frequência de oscilação deste campo magnético.

Para as máquinas elétricas como motores, geradores e transformadores as correntes de Foucault são fontes de perdas de energia e no projeto destes equipamentos são estudadas maneiras de atenuar estas correntes, por exemplo, utilizam-se núcleos magnéticos com chapas muito finas empilhadas e isoladas uma das outras como forma de atenuação.

Então, o funcionamento do freio eletromagnético se dá quando ao alimentar as bobinas da bancada do freio com corrente contínua, estabelece-se entre as faces do magneto um campo magnético estacionário, similar a um ímã. O disco de metal condutor desloca-se entre as faces do magneto, ortogonalmente às linhas deste campo. Este disco pode ser considerado como um sistema de infinitos condutores elétricos se deslocando em um campo de indução. Portanto, estes condutores terão induzidas forças eletromotrizes, as quais darão origem à circulação de correntes no material. Estas correntes no disco, por sua vez, interagem com o campo magnético estabelecido pelos magnetos e dão origem a forças mecânicas entre o disco e os próprios magnetos, de forma que se opõe ao movimento, no sentido de frear o disco.

Como o material condutor do disco tem uma resistividade elétrica definida, a circulação das correntes induzidas dará origem a perdas por efeito Joule, sendo que essa

potência dissipada no disco em forma de calor é igual à potência mecânica no eixo (produto do conjugado resistente pela frequência de rotação). Como toda a potência se transforma em calor no disco, ele pode atingir temperaturas elevadas, podendo chegar a até 150°C aproximadamente.

As correntes de Foucault são utilizadas por outros equipamentos como princípio fundamental para o seu funcionamento, por exemplo, instrumentos de medidas, fornos de indução, sensores diversos, agitadores eletromagnéticos para fluidos metálicos, dispositivos de amortecimento aeroespaciais, dinamômetros para ensaios de turbinas, freios auxiliares de veículos de grande porte e finalmente os Freios Eletromagnéticos de Foucault. Um exemplo bastante comum são os trens que utilizam sapatas polares localizadas na parte inferior das locomotivas com a finalidade de freiar e diminuir a velocidade. A redução da velocidade se dá quando estas sapatas são aproximadas dos trilhos criando correntes induzidas de Foucault, que produzem um campo magnético oposto que cria um conjugado de frenagem.

3.2 BREVE HISTÓRICO DOS FREIOS ELETROMAGNÉTICOS

Em 1819 o físico e cientista dinamarquês F. Oersted percebeu que quando a agulha de uma bússola é colocada próximo a um condutor que circula uma corrente elétrica, esta agulha desvia de sua posição natural (PAUL, 1931). Esta observação deu origem ao estudo da interação entre o campo magnético com a corrente elétrica. Por volta do mesmo ano, André-Marie Ampère realizou experimentos da mesma natureza e, da mesma forma que Oersted, concluiu que se uma espira condutora for submetida a um campo magnético variável, obtido pelo movimento relativo entre o condutor e o campo, ela apresentará em seus terminais uma tensão elétrica. Esta tensão foi denominada por força eletromotriz induzida (KRAUS, 1978).


Michael Faraday deu prosseguimento aos experimentos realizados com campos magnéticos e correntes elétricas e em 1831 elaborou a Lei de Faraday, que de uma forma geral quantifica e determina a força eletromotriz. A Lei de Faraday afirma que:

“A corrente elétrica induzida por um campo magnético em um circuito fechado é proporcional à taxa de variação temporal do número de linhas de fluxo magnético que atravessam a área delimitada pelo circuito” (WHITTAKER, 1910).

Ainda em 1831, M. Faraday observou que um comportamento análogo ocorre quando, ao invés de utilizar uma espira, usa-se um disco condutor submetido a um campo magnético variável. Faraday percebeu que quando o disco gira perpendicularmente às linhas de fluxo de

um campo magnético, o disco apresentava uma tensão induzida entre o seu centro e sua borda. Este experimento construiu o que ficou denominado como Dínamo de Faraday e está ilustrado na Figura 18.

Figura 18 - Dínamo de Faraday, o primeiro gerador elétrico



Fonte: Adaptado de PAUL, 1931

Este dínamo de Faraday ficou conhecido como o primeiro gerador elétrico da história, pois ele transformava a energia mecânica rotacional em energia elétrica. Apesar de todo o trabalho e experiências de M. Faraday na lei da indução eletromagnética, esta lei não foi apresentada através de equações matemáticas para o colegiado da época. Foi quando, posteriormente, James Clerk Maxwell criou as quatro leis fundamentais do eletromagnetismo apresentadas em equações matemáticas, que deu sequência aos estudos de linhas de forças e campos magnéticos estudados por Michael Faraday.

Já em 1855, o físico e astrônomo chamado Jean Bernard León Foucault desenvolveu estudos em correntes induzidas em um condutor (disco rotatório) quando esta fica em movimento na presença de um campo magnético intenso. Ele observou que fazendo um disco de cobre atravessar linhas de fluxo magnéticos promovidos por um eletroímã, calor é gerado por dissipação de energia e isto se dá devido a ação de correntes induzidas no disco, as quais deu origem ao nome Correntes de Foucault. (PLONUS, 1978).

A partir deste trabalho de Foucault, uma série de outros estudos foram realizados em discos submetidos a campos magnéticos. Dentre os estudos, Reinhold Rudenber, em 1906, que realizou uma análise de aplicação das correntes induzidas em freios, observando o comportamento do conjugado de frenagem (WOUTERSE, 1991). Mais tarde, em 1921, Zimmerman complementou o estudo de Reinhold. Depois em 1935 Powell e Gough conseguiram gerar curvas de conjugado versus velocidade de um freio por correntes induzidas

comercial. Em 1942, Smythe elaborou estudos sobre a distribuição das correntes induzidas no disco e mostrou que o conjugado de frenagem era proporcional até um determinado ponto e depois passava a ser inversamente proporcional a velocidade (WOUTERSE, 1991). Em 1974, David Schieber conseguiu descrever analiticamente o conjugado de frenagem sobre o disco condutor e desenvolveu uma relação para determinar a dimensão dos polos de um eletroímã (SCHIEBER, 1975).

Em 1991, Wouterse descreve a influência do campo magnético criado pelas correntes de Foucault sobre a força da frenagem em função da velocidade de rotação do disco. Mais tarde, em 1995, Simeu e Georges desenvolveram um tipo de controle para a variação de velocidade do disco a partir do controle da corrente aplicada nos eletroímãs (SIMEU, 1995). Já na década de 2000, trabalhos na área desenvolveram técnicas de obtenção de conjugado de frenagem através de levantamentos experimentais.

Nos dias de hoje os freios eletromagnéticos por ação de correntes induzidas já são fabricados comercialmente para diversas aplicações e tem sistemas de controles que permitem variar as correntes induzidas no disco, assim como existem técnicas de medição e controle de conjugado de frenagem, sendo bastante utilizados para ensaios de máquinas elétricas.

3.3 BANCADA DO FREIO ELETROMAGNÉTICO

3.3.1 Apresentação da Bancada

A bancada do Freio Foucault presente no LAMOTRIZ – LEEQE – UFPE tem como finalidades estudos do comportamento dos motores elétricos, principalmente, simulações de cargas com atuação variável e levantamento de parâmetros motrizes. Alguns exemplos de sistemas industriais cujos motores trabalham com variações de conjugado em seu eixo devido às cargas de comportamento dinâmico são, por exemplo, as bombas centrífugas, grande ventiladores, misturadores centrífugos, bobinadeiras, tornos elétricos, pontes rolantes, descascadores de madeira, trituradores, entre outros.

A Figura 19 apresenta alguns exemplos de sistemas com cargas variáveis. No item a) temos uma ponte rolante cujo conjugado do motor depende da carga a ser içada. O item b) mostra uma esteira transportadora cuja carga varia com o peso das embalagens. Já no item c) há uma máquina bobinadeira de chapas metálicas. No item d) temos uma bomba centrífuga

para um sistema de exaustão industrial. O item e) apresenta um sistema de bombeamento de fluídos e por fim, no item f), temos uma bobinadeira de fios de cobre.

Figura 19 – Sistemas Industriais de Comportamento de Conjugado Variável



a)



b)



c)



d)



e)



f)

Fonte: Próprio Autor

Estes sistemas operam variando o conjugado motor e por esta razão um sistema de controle eficiente é necessário por diversas razões, dentre as quais, diminuição dos custos de manutenção, melhor planejamento da produção, prolongamento da vida útil do motor, e de uma maneira geral, redução dos custos operacionais.

Diante desta perspectiva, uma bancada de testes como o Freio Eletromagnético de Foucault permite toda uma avaliação técnica e econômica a respeito destes sistemas. Assim, a bancada do FEF presente no Departamento de Engenharia Elétrica da UFPE apresenta uma grande contribuição em estudos que visam a efficientização de sistemas industriais.

O sistema é operado e supervisionado através de uma estação de operação, que serve de Interface Homem-Máquina (IHM) entre o operador e o sistema de controle da bancada. A bancada é composta por um conjunto de equipamentos e dispositivos eletrônicos de controle, proteção e medição. O sistema possui basicamente as seguintes características:

- a) Interface entre o Controlador Lógico Programável (CLP) e os dispositivos de medição e controle da bancada via rede PROFIBUS-DP;
- b) Conexão entre a estação de operação (OS) da bancada e o sistema de controle (AS) via rede INDUSTRIAL-ETHERNET;
- c) Operação total via sistema, ou parcialmente operadas através de dispositivos de acionamento local dispostos na porta do painel de automação;
- d) A bancada é dotada de dispositivo de proteção e segurança com intertravamento.


Com esta bancada é possível realizar ensaios de cargas de comportamentos dinâmicos para analisar o comportamento do motor, simulando um sistema industrial que utiliza motores de indução trifásicos que são submetidos a variações de conjugado.

Além disto, o Freio de Foucault também permite fazer o levantamento da curva característica do motor acoplado. Variando-se a excitação do freio, pelos magnetos, e medindo-se a força resultante na balança, é possível levantar a característica do conjugado do motor.

3.3.2 Descrição da Bancada do Freio

A bancada do Freio Eletromagnético utilizada neste trabalho pode ser visualizada na Figura 20, onde é apresentada toda a estrutura, que contém o suporte, o motor, o disco metálico e equipamentos de medição e controle.

Figura 20 - Foto da bancada do Freio Eletromagnético localizado no LAMOTRIZ – LEEQE – UFPE




Fonte: Próprio Autor

1. Motor de Indução Trifásico rotor do tipo Gaiola de Esquilo, fabricante WEG;
2. Conversor de Frequência, fabricante Siemens;
3. Indicador digital de força ou torque (Kgf);
4. Conjunto disco metálico, bobinas e dispositivos;
5. Variador de tensão para controle dos eletroímãs do disco;
6. Amperímetro analógico para medição de corrente no motor.

A Figura 21 detalha a configuração do disco condutor maciço e os eletroímãs do conjunto. Ela apresenta o disco condutor acoplado no eixo do motor trifásico de indução, juntamente com os quatro eletroímãs, um sistema do tipo pedestal que serve de suporte para toda a estrutura, um transdutor de força para medição do conjugado de frenagem e um dispositivo eletromecânico de mede a velocidade de rotação do eixo do motor, conhecido como encoder rotativo.

Figura 21 - Disco metálico acoplado no eixo do motor



Fonte: Próprio Autor

Os itens indicados pelas setas têm as seguintes legendas:


- 1- Disco condutor metálico maciço, suspenso pelo eixo;
- 2- Magnetos com bobinas excitadas em corrente contínua;
- 3- Transdutor de força tipo NA 330 (0 – 20 Kgf);
- 4- Encoder rotativo;
- 5- Pedestais de apoio do conjunto, fixados a base;
- 6- Estrutura oscilante de suporte dos magnetos e do disco, montados sobre mancais de oscilação.

Todos os materiais e dispositivos utilizados na construção da bancada, juntamente com sua descrição detalhada, estão apresentados na Tabela A1 dos Anexos.

3.3.3 Descrição do Motor de Indução Trifásico

Nesta bancada é utilizado um motor de indução trifásico do tipo rotor de gaiola de esquilo do fabricante WEG. A figura e a tabela a seguir mostram o motor e seus dados de placa.

Figura 22 -Motor de indução trifásico WEG (à esquerda) e dados de placa (à direita)



Fonte: Próprio Autor

Tabela 1 - Dados de Placa do motor de indução da bancada do freio eletromagnético

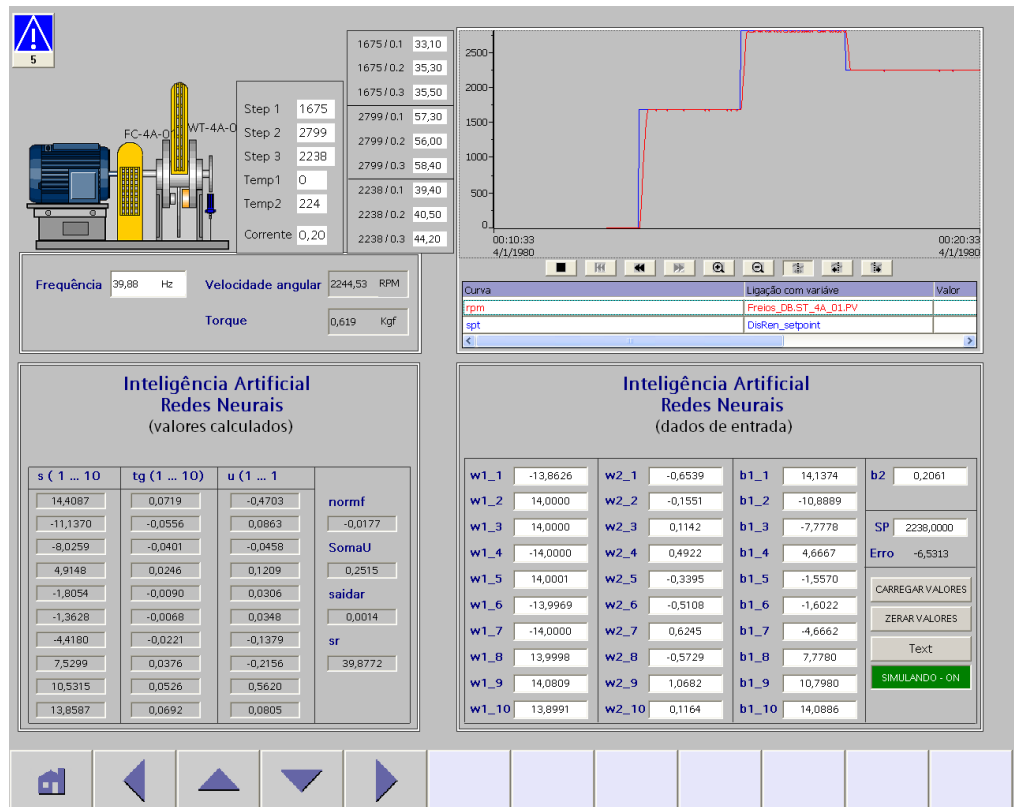
1. Motor de indução – Gaiola de esquilo;	9. IP55;
2. Frequência 60Hz;	10. Alimentação: 220/380 V;
3. CAT: N;	11. Corrente Nominal: 4.28/2.48 A;
4. Potência: 1.1 kW (1.5 HP);	12. Regime de Serviço S1;
5 Velocidade: 3370 rpm;	13. Rendimento 78.5%;
6. FS: 1.15;	14. Temperatura de trabalho 40°C;
7. Isolamento B;	15. Fator de potência 0.86;
8. Ip/In: 7.5;	17. Rolamento dianteiro e traseiro: 6204ZZ e 6203ZZ respectivamente.

Fonte: Placa do motor de MITRGE – LEEQE

3.3.4 Descrição da Bancada do Freio no Supervisório

A bancada do freio eletromagnético é representada no computador através do programa WinCC[®] onde são modelados todos os componentes do sistema incluindo o motor e o conjunto de freio. Para a configuração estudada, a representação no programa WinCC[®] tem a tela principal conforme se verifica na Figura 23. Além de apresentar a configuração do sistema, o sistema supervisório mostra todos os parâmetros do controlador neural que será desenvolvido, tanto os dados de entrada da rede quanto os dados de saída.

Figura 23 - Tela de Visualização da Bancada do Freio Eletromagnético e dos parâmetros do Controlador Neural.



Fonte: Próprio Autor

Como pode ser observado, além das informações do controlador neural proposto, a bancada possibilita monitorar também os calores de velocidade angular, frequência e conjugado do motor através deste sistema supervisor. Ainda no canto superior direito, é possível observar o comportamento do sistema real através de gráficos, cujos valores são coletados para uma avaliação mais detalhada.

4 METODOLOGIA E RESULTADOS

4.1 MODELO DO SISTEMA

Para que um controlador seja implementado em um sistema industrial real deve se ter um conhecimento do comportamento deste sistema através de uma representação matemática e essa representação é dada por um modelo. Quanto mais o modelo do sistema tem comportamento igual ao do sistema original, mais significativo é esta representação matemática, visto que as informações do sistema aproximado estão muito semelhantes das informações do processo real.

No entanto, algumas informações podem ser perdidas durante a modelagem do sistema, o que pode comprometer a representação matemática e conseqüentemente originar erros inesperados durante o processo. Desta forma, deve haver uma rigorosa análise para que o modelo represente de forma mais fidedigna possível o sistema em estudo.

4.1.1 Identificação do Modelo do Processo

A identificação do modelo da planta em estudo foi obtida através da construção da função de transferência do sistema e foi realizada de forma experimental na bancada do Freio de Foucault. A partir de um conjunto de experimentos realizados na bancada, foi possível obter dados de entrada e saída do sistema em malha aberta. Isto é, dado um sinal de controle no sistema em malha aberta, obteve-se a curva de reação do sistema. A Figura 24 ilustra o processo de identificação.

Figura 24 - Etapas para Identificação do Sistema



Fonte: Próprio Autor


O sistema do Freio Eletromagnético de Foucault deste trabalho tem como objetivo controlar a velocidade angular de rotação do motor à medida que a carga acoplada ao seu eixo

(corrente nos magnetos) se modifique com o tempo. Esta velocidade angular é controlada no motor através de um inversor de frequência implantado no sistema, que ajusta a velocidade de rotação à medida que sua carga varia. Todo o processo é monitorado e controlado através de um sistema supervisorio que está conectado com a bancada do FEF através de uma rede de computadores localizado remotamente no laboratório LEEQE.

A planta do sistema foi configurada de forma que o sinal de controle do processo é a frequência do motor e o sinal de resposta do sistema é a velocidade angular. Assim, de acordo com a característica de resposta dinâmica do sistema é possível aproximar o sistema real por um modelo matemático de primeira ordem representado pela Equação 26. Os parâmetros da equação estão mostrados na Figura 25, como abordado no Capítulo 2.

$$G_c = \frac{K e^{-Ls}}{T_S + 1} \quad (26)$$

Figura 25 - Curva dos parâmetros do modelo matemático de primeira ordem



Fonte: Adaptado de OGATA, 2010

Existem nas literaturas de sistemas de controle diversas formas de se obter os parâmetros do modelo matemático descrito anteriormente, dentre os quais se destacam:

- 1 – Método de Ziegler Nichols;
- 2 – Método de Smith;
- 3 – Método de Sundareshan/Krishnaswamy;
- 4 – Método computacional iterativo (MATLAB®).

Entre os métodos listados, será escolhido o que mais apresentar o modelo que se aproximar dos parâmetros da curva real do processo, pois desta forma a curva obtida será a que tem comportamento mais semelhante do sistema real em estudo.

Por meio do sistema supervisorio que monitora o processo, a planta foi configurada em malha aberta e então foram realizados os experimentos para a identificação do seu modelo matemático. Vários degraus de frequência foram aplicados como sinais de testes através do sistema supervisorio e para cada valor de entrada (frequência) foi obtido uma curva de resposta do sistema, ou seja, um valor de saída. Os valores das frequências de entrada aplicados no sistema foram de 20Hz até 60Hz em passos unitários e os valores de saída são as velocidades angular do motor.


Para cada par de valores de entrada e saída do sistema foi obtido o modelo matemático, no entanto, para valores menores que 39Hz os sinais de resposta apresentaram muitos ruídos oriundos de imprecisões obtidas pelos sensores da bancada, tornando estes valores para levantamento da função de transferência bastante imprecisos nesta faixa. Para valores acima de 55Hz não houveram problemas de imprecisão, no entanto, foram medidos os valores dos parâmetros elétricos do motor e notou-se que eles se aproximaram dos limites da proteção de sobrecorrente do sistema, o que significa que esta faixa de operação pode apresentar riscos para a vida útil do sistema devido a correntes elevadas no circuito.

Os resultados experimentais foram coletados através do sistema supervisorio e depois de tratados adequadamente foram realizadas as análises gráficas pela ferramenta de identificação de sistemas, que será utilizada para definir os valores dos parâmetros da função de transferência. Esta ferramenta é a *System Identification Toolbox* do software MATLAB®. Foi notado que a função de transferência estimada deste sistema para a faixa de frequência entre 39Hz até 55Hz têm valores muito próximos uns dos outros, apresentando diferenças de pouco menos que 5%, significando que o comportamento deste sistema nesta faixa de valores é aproximadamente linear e, portanto, pode ser representado por apenas um único modelo matemático.

Diante disto, foi adotado o valor de 50Hz de degrau de frequência aplicado para a configuração da planta e então foram realizados os ensaios experimentais. Em seguida foram obtidos os valores de saída do processo que é a velocidade angular no disco. Estes dados foram obtidos através de sensores instalados na própria bancada que estão em comunicação com o sistema supervisorio. Por fim, com o auxílio da ferramenta computacional MATLAB® e com os dados coletados no sistema de supervisão foi possível construir a curva de resposta

do sistema. Para 50Hz de frequência, a curva de resposta ao degrau do sistema em malha aberta tem o comportamento mostrado no Gráfico 1.

Gráfico 1 - Curva de Reação do Freio de Foucault em Malha Aberta



Fonte: Autor Próprio

A partir da avaliação deste gráfico, é possível obter os parâmetros da equação de primeira ordem que representa o comportamento do sistema.

4.1.2 Métodos de Identificação dos Parâmetros do Modelo

Como já citado anteriormente, alguns métodos descritos na literatura de sistemas de controle estabelecem critérios para determinar os parâmetros da função de transferência de primeira ordem.

Foram escolhidos alguns destes métodos para este trabalho e os valores encontrados estão descritos conforme os autores desenvolveram.

Baseado no método de Ziegler Nichols, os valores de K, L e T são:

$$K = \frac{\Delta y}{\Delta u} = \frac{2798}{50} = 55,96 \quad (27)$$

$$L = 0,01s \quad (28)$$

$$T = 4,66 - L = 4,65s \quad (29)$$

De acordo com o método de Smith os valores de L e T são obtidos quando o modelo e as repostas do sistema real se coincidam em dois pontos da mais elevada taxa de mudança, que estão destacados em tempos distintos t_1 e t_2 , cujos valores são 23,8% e 63,5% do valor final Δy . Portanto os valores aproximados obtidos para encontrar estes parâmetros são:

$$T = 1,5 * (t_2 - t_1) = 4,58s \quad (30)$$

$$L = t_2 - \tau = 0,012s \quad (31)$$

Ainda, através do método de Sundaresan e Krishnaswamy os valores de L e T são obtidos de forma semelhante, só que utiliza os dois tempos t_1 e t_2 diferentes, cujos valores são 35,3% e 85,3% do valor final de Δy . Portanto temos

$$T = 0,67 * (t_2 - t_1) = 4,55s \quad (32)$$

$$L = 1,3 * (t_1 - 0,29 * t_2) = 0,01s \quad (33)$$

Finalmente, através do método iterativo do MATLAB® os parâmetros K, L e T foram obtidos através da ferramenta *System Identification Toolbox*™ do próprio software e os parâmetros encontrados foram:


$$K = 55,949$$

$$L = 0,01s$$

$$T = 4,65s$$

A partir do critério de erro entre as curvas reais e a do modelo, foram determinados os parâmetros obtidos (ganho e constante de tempo) pelo MATLAB® para definir a função de transferência do sistema, já que eles apresentaram a curva de resposta com menores discrepâncias em relação a curva real da bancada. O Gráfico 2 mostra a curva real do sistema e a curva obtida pelo modelo matemático de primeira ordem do sistema.

Gráfico 2 - Curva de Resposta Real do Sistema Versus Curva de Resposta da Função de Transferência Estimada



Fonte: Próprio Autor

Portanto foi definido que a função de transferência que melhor representa o comportamento do Freio de Eletromagnético Foucault é:

$$G(s) = \frac{55,944 e^{-0,01s}}{4,65s + 1} \quad (34)$$

4.2 CONTROLE DO SISTEMA

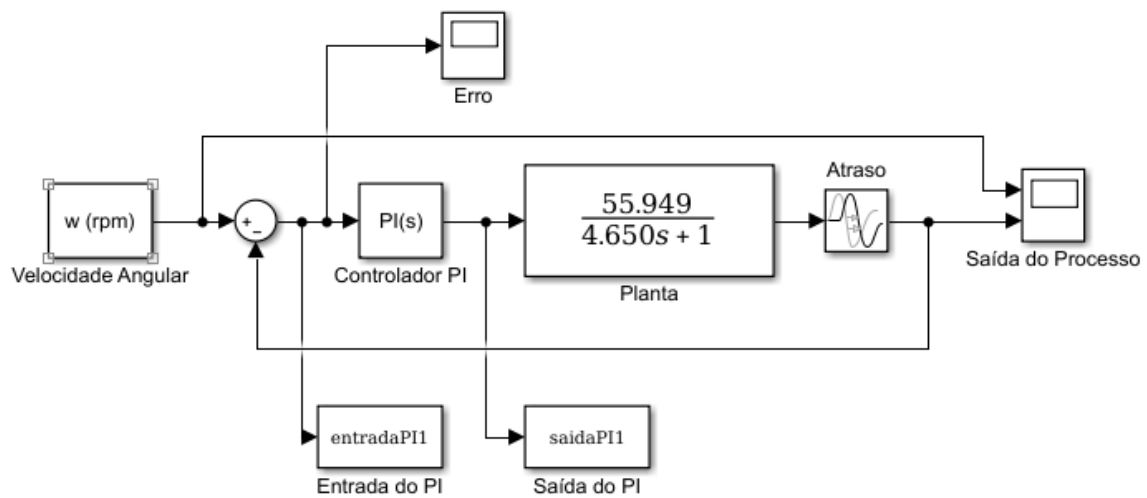
A partir da modelagem da planta, um sistema de controle PID foi desenvolvido para controlar a velocidade angular do sistema quando a carga acoplada ao seu eixo varia. A partir do controlador adotado será possível utilizar as ferramentas de inteligência artificial para elaborar um outro controlador, sendo que este usa as redes neurais artificiais, com a finalidade de desenvolver um sistema de controle mais adaptável a variações de cargas.

4.2.1 Sistema com Controlador Convencional

O sistema de controle foi elaborado utilizando um controlador proporcional-integral, também conhecido como controlador PI, e sua configuração foi montada através do software

computacional MATLAB®. Foi possível desenvolver um sistema em malha fechada através de diagramas de blocos por meio da ferramenta de modelagem e simulação chamado *Simulink* (MATLAB®). Através de uma biblioteca de modelos pré-configurados voltados para simulações de sistemas, o bloco utilizado para implementar o controlador PI foi o *PID Controller*. O sistema de controle desenvolvido está mostrado na Figura 26.

Figura 26 - Malha de Controle com PI



Fonte: Próprio Autor

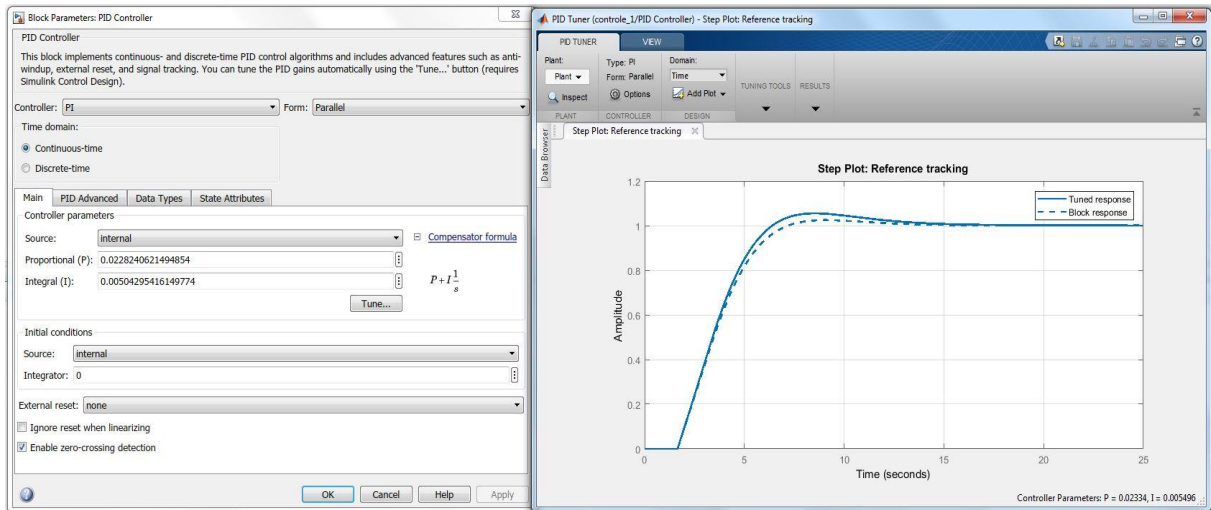
O diagrama de blocos consiste em um conjunto de blocos individuais com funções bem definidas, dentre eles um que simula a velocidade angular do disco em rpm quando é estabelecido um valor de frequência de referência no inversor, em seguida, um controlador proporcional-integral e a função de transferência do freio eletromagnético. No sistema há blocos de coletas de dados “Entrada do PI” e “Saída do PI” que serão posteriormente utilizados para o treinamento do controlador neural. Há ainda um atraso no tempo que representa o valor da função exponencial da equação de primeira ordem da planta e também ferramentas de visualização gráfica do próprio programa MATLAB® como o bloco “Erro” e “Saída do Processo”.

Com o sistema projetado, a etapa seguinte consistiu em realizar a sintonização do controlador PI de forma a obter a melhor performance possível, no sentido de bons parâmetros de desempenho, como por exemplo, menor sobressinal e menor tempo de estabilização. A ferramenta utilizada para esta tarefa foi a *PID Tuner*, presente no *Simulink Control Design* do software MATLAB®. Esta ferramenta escolhe automaticamente os parâmetros do controlador de acordo com o sistema projetado, que neste trabalho consiste nos

ganhos K_p e K_i do controlador. Ainda, o programa permite um ajuste fino manual cuja finalidade é melhorar ainda mais a performance do controlador.

A Figura 27 mostra no lado esquerdo a ferramenta *Simulink Control Design* e no lado direito o ajuste fino visual dos parâmetros do controlador (*PID Tuner*).

Figura 27 - Simulink Control Design do MATLAB®



Fonte: Próprio Autor

Finalizado a sintonização do controlador PI através da ferramenta descrita, os ganhos proporcionais (K_p) e integral (K_i) foram encontrados e são, respectivamente:

$$K_p = 0.022824$$

$$K_i = 0.005042$$

Depois de projetado o sistema de controle e seu controlador devidamente sintonizado, foi possível realizar diversas simulações com valores de referências diferentes para verificar as curvas de respostas da planta para cada valor de velocidade angular e carga acoplada.

A Tabela 2 mostram três cenários simulados com diferentes valores de referência e de carga no eixo do motor. Os valores de referência (*setpoint*) são as velocidades angulares em rotações por minuto, que correspondem aos valores de frequência no inversor da bancada. Para cada valor de frequência no inversor foram aplicadas nas bobinas do freio eletromagnético correntes elétricas de 0,1A, 0,2A e 0,3A que resultam em torques resistentes ao conjugado normal do motor e desta forma simula cargas de comportamentos distintos. Os experimentos destes cenários permitiram avaliar o comportamento do controlador PI para

posteriormente servirem como parâmetros no desenvolvimento do controlador inteligente proposto.

Tabela 2 - Cenários de Simulações

Frequência	Velocidade Angular	Carga acoplada
30 Hz	1675 rpm	0,1 A
		0,2 A
		0,3 A
40 Hz	2238 rpm	0,1 A
		0,2 A
		0,3 A
50 Hz	2799 rpm	0,1 A
		0,2 A
		0,3 A

Fonte: Próprio Autor


4.2.2 Simulações com Controlador Proporcional-Integral

Com o sistema de controle projetado foi possível realizar as simulações do cenário mostrado na Tabela 2, através do software matemático. Estas simulações têm papel fundamental no trabalho pois elas irão servir de base para a construção de um controlador inteligente, visto que a rede neural terá um treinamento supervisionado e que precisa de um conjunto de dados previamente preparado.

Através da ferramenta de simulação *Simulink*, do MATLAB®, foram construídos os gráficos para as velocidades angulares configuradas como valores de referência.

Foi escolhido um valor de carga de 0,2A nos magnetos do Freio Eletromagnético de Foucault e a curva de resposta do sistema para cada valor de referência estão mostrados no Gráfico 3. Três valores de referência foram utilizados e eles são, respectivamente, os valores de 30Hz, 40Hz e 50Hz que simulam as frequências do inversor de frequência que controla o motor. Para cada um destes valores o motor responde com uma velocidade angular de 1675rpm, 2238rpm e 2800rpm respectivamente.


Gráfico 3 - Curvas de Resposta do FEF com o controlador PI



Fonte: Próprio Autor

É possível avaliar nestas curvas que o controlador PI tem um bom desempenho ao considerar que o sistema respondeu aos valores desejados, no entanto ele apresenta pequenos sobressinais. O Gráfico 4, logo abaixo, é uma aproximação do gráfico anterior numa região próxima dos sobressinais e nele é possível avaliar, nos pontos indicado pelas setas, o valor máximo do sobressinal que ocorreu para cada curva de resposta do sistema.

Gráfico 4 - Sobressinais das Curvas de Respostas do Sistema com o controlador PI



Fonte: Próprio Autor

Uma análise gráfica foi realizada através da ferramenta *stepinfo* do software MATLAB® para avaliar os valores do sobressinal, tempo de estabilização da resposta do sistema e valores de pico da curva para cada valor de referência do sistema. Esta ferramenta calcula as características da resposta dinâmica do sistema e retorna valores como, por exemplo, o tempo de estabilização da curva de reação do sistema, máximo valor do sobressinal, valores de pico e outros parâmetros de desempenho dos sistemas. A Tabela 3 mostram os resultados.


Tabela 3 – Parâmetros de Desempenho do Sistema com o Controlador PI

Valores de Referência (rpm)	Valor de Pico (rpm)	Sobressinal (%)	Tempo de Estabilização (s)
1675	1686	0,65	12,51
2238	2254	0,71	13,82
2800	2818	0,67	14,23

Fonte: Próprio Autor

Uma outra análise gráfica foi realizada com o sistema controlado pelo PI e desta vez a planta do sistema teve que atingir os valores de referência quando as velocidades angulares foram modificadas depois de um certo intervalo de tempo. Inicialmente o *setpoint* escolhido foi de 1675rpm e em seguida subiu para o valor de 2800rpm e por fim foi decrescido para 2238rpm. A curva de reação do sistema também foi construída através do *Simulink* MATLAB® e está mostrada no Gráfico 5.

Gráfico 5 - Resposta do FEF Controlado Pelo PI Com Modificações Nas Velocidades de Referência



Fonte: Próprio Autor

Por fim, é possível observar que o controlador PI atua no sistema de forma que sua resposta as variações de velocidades apresentam um tempo de estabilização maior e também um sobressinal pequeno e discreto. Nos casos que ocorrem variações nas dinâmicas dos processos, o controlador PI apresenta desvantagens em relação aos controladores que utilizam técnicas de inteligência artificial que apresentam desempenho mais precisos. Desta forma, é justificado o uso do controlador neural proposto para estes tipos de situações.

4.3 CONTROLE COM A REDE NEURAL ARTIFICIAL

Através do sistema desenvolvido, foi possível elaborar uma rede neural artificial cuja finalidade também é realizar o controle da planta abordada. Graças a capacidade da rede de aprendizado, a habilidade de generalização e facilidade de implementação, estas características justificam o uso da rede neural em aplicações em sistemas industriais.

No sistema do Freio Eletromagnético de Foucault, onde as variações de correntes no magneto alteram o comportamento da carga do motor, o uso das redes neurais auxilia no controle desta máquina com a finalidade de ajustar a frequência do inversor e conseqüentemente realizar uma melhor adaptação deste motor para situações de cargas de comportamento dinâmico.

4.3.1 Construção da Rede Neural Artificial

O controlador que utiliza uma rede neural proposto neste trabalho foi construído com objetivo de controlar o Freio Eletromagnético de Foucault de forma semelhante ao controlador PI já desenvolvido. Sabe-se que as redes neurais têm grande capacidade de processamento e são capazes de generalizar o conhecimento adquirido durante o treinamento e por isto foi necessário elaborar algumas etapas para a construção da rede com a finalidade de treiná-la e definir as variáveis necessárias para o seu desenvolvimento.

Para a construção da rede neural artificial desta pesquisa foram realizadas duas etapas distintas, cada uma com sua devida contribuição. Estas duas etapas consistem basicamente em coletar e tratar um banco de dados para o treinamento da rede e em seguida desenvolver a arquitetura da rede. Ao final do processo a rede neural será simulada e implementada na no sistema real. O passo-a-passo das etapas são descritos como se segue.

Etapa 1 – Coleta/Tratamento dos Dados

Na primeira etapa da construção da rede o objetivo foi levantar um banco de dados para utilizá-los para o treinamento da rede. As redes neurais artificiais são capazes de aprender e generalizar o conhecimento adquirido durante o treinamento e como a rede escolhida é do tipo supervisionada, foi necessário apresentar exemplos do sistema real.

Portanto, nesta fase do trabalho, informações foram coletadas na entrada e na saída do controlador PI com a finalidade de utilizar estes pares de informações para servir como exemplo para a rede e, conseqüentemente, treinar o controlador neural como deve ser seu comportamento. Graças ao controlador PI já desenvolvido para o sistema, a coleta do banco de dados foi realizada através da ferramenta de simulação do MATLAB® (*Simulink*) e a extração das informações foi possível graças a um bloco pré-configurado da ferramenta chamado “*To Workspace*”. Os valores coletados foram obtidos pelos blocos “Entrada do PI” e “Saída do PI” mostrados na Figura 25.

Além disto, também foram inseridos nos conjuntos de dados para o treinamento os valores de correntes dos magnetos do Freio Eletromagnético, que foram os valores de 0,1A a 0,3A (Carga Acoplada - Tabela 2) e também os próprios valores de velocidade angular desejados (*setpoint*), ou seja, os valores de referência. Assim, através destas variáveis e dos dados de entrada e saída do controlador PI, o controlador neural foi desenvolvido.

Uma vez que estes dados foram extraídos do sistema controlado pelo PI, eles foram analisados cuidadosamente e passou por um tratamento cuidadoso com a finalidade de apresentar para a rede neural as informações mais cruciais.

O tratamento dos dados consistiu numa normalização cuja finalidade seja que estas informações tenham proporções igualitárias. A normalização dos dados foi escolhida pelo critério de magnitude das variáveis, considerando uma faixa de 10% a 90% das variáveis, utilizando a seguinte equação:

$$x_{norm} = \frac{x - 0,9x_{min}}{1,1x_{máx} - 0,9x_{min}} \quad (35)$$

Após a normalização, os dados foram divididos três blocos, o conjunto de treinamento, o conjunto de validação e o conjunto de teste. Estes procedimentos para tratamento das redes neurais artificiais estão de acordo com as regras de Benchmark para Redes Neurais Artificiais – PROBEN 1 (PRECHELT, 1994).

A subdivisão do conjunto de dados foi constituída de 50% para o conjunto de treinamento, 25% para o conjunto de validação e 25% para o conjunto de teste. O conjunto de treinamento é o principal responsável pelos ajustes dos pesos sinápticos da rede neural. Vale salientar que este conjunto de treinamentos será o que fornecem informações para o aprendizado da rede. Ainda, 25% dos dados foram selecionados arbitrariamente para o conjunto de validação que fica responsável por verificar a capacidade da rede de generalizar seu conhecimento durante o treinamento, quando são apresentados conjunto de dados desconhecidos. Este conjunto de validação não é usado para o ajuste dos pesos e tem a finalidade de evitar o *overfitting* da rede.

Finalmente, o conjunto de testes com 25% dos dados restantes fica responsável por estimar o desempenho da rede quando ela estiver em operação, medindo a performance e verificando os erros percentuais da rede resultante com dados que ela desconhece. Da mesma forma que o conjunto de validação, o conjunto de testes não modifica os parâmetros da rede.

Etapa 2 – Seleção da Arquitetura da Rede

Esta fase da construção da rede neural tem papel fundamental no trabalho, pois consiste na seleção da arquitetura e da topografia da rede, além da escolha do algoritmo de treinamento que é usado para ponderar os pesos sinápticos dos neurônios.

Os parâmetros da arquitetura da rede neural foram testados um a um para então ser escolhida a melhor configuração que apresenta o menor erro. O critério de escolha da arquitetura da rede é o menor erro médio quadrático (MSE), em outras palavras, a rede escolhida será a que apresentar a melhor performance em seu comportamento.

Inicialmente os testes foram realizados considerando apenas dois neurônios na camada oculta e com o algoritmo de treinamento gradiente descendente com momento (GDM). A camada de saída com apenas um neurônio, que é justificado pelo fato de que a rede neural terá apenas uma saída que representa o sinal de controle do controlador neural.

O primeiro teste realizado foi a escolha da função de ativação da rede para a camada oculta e para camada de saída, dentre elas foram testadas as funções Tangente Hiperbólica (Tangh) e a Logística Sigmoidal (Sigm). A Tabela 4 mostra o resultado das simulações com o erro médio quadrático para cada teste.

Tabela 4 - Testes das Funções de Ativação

Camada Oculta / Saída	MSE
Tangh/Tangh	0,1327
Tangh/Sigm	0,4535
Sigm/Tangh	0,3254
Sigm/Sigm	0,2918

Fonte: Próprio Autor

Em seguida foram realizados dez testes para a escolha do algoritmo de aprendizagem. Os algoritmos testados foram o Levenberg-Marquardt (LM), o Resilient Propagation (Rprop) e o Gradiente Descendente com Momento (GDM). O algoritmo escolhido será o que apresentar em média o menor valor do erro quadrático médio (MSE). A Tabela 5 mostram as dez inicializações simuladas. Ao final da tabela é apresentado o valor médio dos valores de MSE encontrados, sinalizando desta forma o algoritmo que destaca a melhor performance (ou menor erro médio) entre os demais.

Tabela 5 - Testes dos Algoritmos de Treinamento

Inicializações	Erro Quadrático Médio - MSE		
	LM	Rprop	GDM
1	0,20205	0,2002	0,21563
2	0,21955	0,3226	0,18573
3	0,19059	0,19872	0,22651
4	0,20681	0,21259	0,18694
5	0,19399	0,2925	0,21034
6	0,20174	0,20762	0,21419
7	0,21164	0,28999	0,19254
8	0,18961	0,21664	0,25888
9	0,21013	0,27999	0,22023
10	0,2027	0,18935	0,2795
Erro Médio	0,2028	0,2410	0,2190

Fonte: Próprio Autor

Como pode ser notado na tabela 5 o algoritmo de aprendizado que apresentou os menores valores do erro quadrático médio foi o de Levenberg-Marquardt (LM), neste caso, o erro médio dos valores indica que este algoritmo apresentou o melhor comportamento.

Por fim, para a seleção da arquitetura da rede neural foi necessário escolher a quantidade de neurônios da camada oculta. Para esta etapa do trabalho foram simuladas quatro configurações de rede com 5, 10, 15 e 20 neurônios na camada oculta. Seguindo o raciocínio anterior, a rede que apresentou os menores valores do erro médio quadrático terá uma boa performance e, portanto, será escolhida para constituir a arquitetura final da rede do controlador.

A Tabela 6 apresenta os resultados das simulações com os números de neurônios da camada oculta da rede abordada.

Tabela 6 - Testes do Número de Neurônios da Camada Oculta

Inicializações	Erro Quadrático Médio (MSE)			
	5 Neurônios	10 Neurônios	15 Neurônios	20 Neurônios
1	0,20689	0,19451	0,22196	0,20912
2	0,20475	0,19248	0,21549	0,20135
3	0,21218	0,21560	0,21655	0,20484
4	0,21235	0,20216	0,221356	0,21865
5	0,21126	0,20458	0,216587	0,2064
6	0,21657	0,19548	0,22354	0,20168
7	0,2157	0,21354	0,23654	0,21585
8	0,2835	0,21658	0,21026	0,21680
9	0,2153	0,20154	0,21321	0,21595
10	0,2795	0,19654	0,23245	0,20846
Erro Médio	0,2258	0,2033	0,2207	0,2109

Fonte: Próprio Autor

É possível perceber que os menores valores do erro quadrático médio ocorreram com a rede neural com 10 neurônios na camada oculta. Isto significa que esta configuração da rede tem os melhores resultados dentre os demais, justificando assim sua escolha.

Após a seleção dos parâmetros mais importantes da arquitetura, foi resumido na Tabela 7 as configurações finais da arquitetura da rede neural que compõe o controlador proposto.

Tabela 7 - Configuração Final da RNA


Arquitetura da Rede	<i>Perceptron</i> Multicamadas (MLP)
Tipo de Treinamento	Supervisionado

Número de Camadas	2
Neurônios da Camada Oculta	10
Algoritmo de treinamento	Levenberg - Marquardt
Taxa de Aprendizagem	0,001
Épocas	1000
Função de Ativação da Camada Oculta	Função Tangente Hiperbólica
Função de Ativação da Camada de Saída	Função Tangente Hiperbólica
Conjunto de Dados para Treinamento	372
Quantidade de Amostras de Treinamento	186
Quantidade de Amostras de Validação	93
Quantidade de Amostras de Testes	93

Fonte: Próprio Autor

A Figura 28 mostra através de uma representação ilustrativa, a arquitetura final da rede neural desenvolvida. Os três círculos em azul representam as variáveis da camada de entrada da rede, já os círculos de cor cinza representam os dez neurônios da camada oculta e o círculo vermelho representa a camada de saída da RNA cuja informação é o sinal de controle do sistema.

Figura 28 - Arquitetura da Rede Neural Proposta



Fonte: Próprio Autor

4.3.2 Simulação da Rede

A função de transferência do FEF é então é controlada pelo controlador convencional PI. A partir da RNA construída, esta etapa do trabalho consiste em substituir o controlador atual pelo controlador composto pela rede neural. Portanto, neste estágio o controlador tradicional será substituído pelo controlador inteligente no diagrama de blocos da Figura 26.

Com a ferramenta de simulação do MATLAB® o controlador neural foi inserido no sistema e através dos parâmetros encontrados da rede neural, foi possível desenvolver uma linha de código que utiliza os pesos ajustados da RNA. Esta nova configuração permite que o controlador neural possa exercer a função de controlador.

A Figura 29 mostra a nova configuração do sistema de controle só que agora utilizando o controlador neural, e não mais o controlador PI. Este novo cenário tem o objetivo de realizar um controle que se adapte as variações de carga do motor. Além disso, o controlador neural tem uma melhor adaptação a variações paramétricas do sistema ou até mesmo a perturbações que por ventura possam ocorrer (HUNT, 1992).

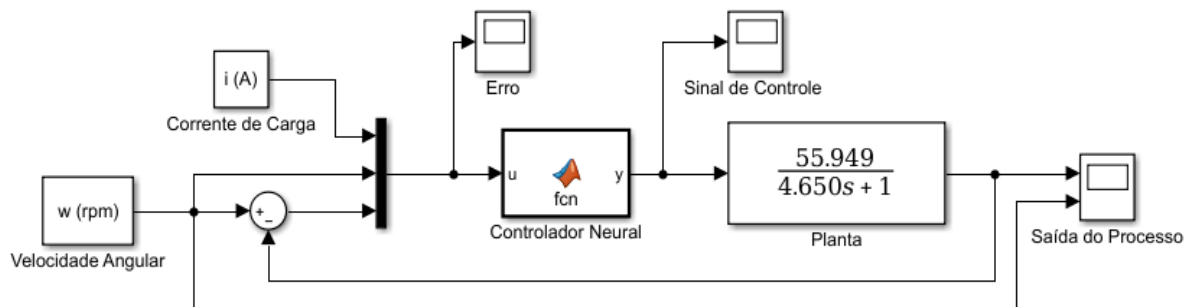


Figura 29 - Malha de Controle com a RNA


Fonte: Próprio Autor

A figura mostra o controlador neural assumindo o papel do controlador PI descrito anteriormente. As entradas da rede são as correntes de carga aplicada no Freio Eletromagnético, os valores de referência, que neste caso são as velocidades angulares do motor e também o erro da realimentação do sistema. A saída da rede neural é o sinal de controle que é monitorado pela ferramenta de visualização do próprio *Simulink*.

Os resultados da simulação da rede implementada foram obtidos através do seguinte procedimento: apresenta-se a rede neural a velocidade angular desejada (valor de referência do sistema) e fornece ao sistema valores de cargas que variam entre 0,1A até 0,3A. Assim, a rede neural já treinada pondera o melhor sinal de controle para aplicar na planta do sistema.


O gráfico 6, 7 e 8 mostram as simulações da rede neural para as velocidades de 1675rpm, 2238rpm e 2799rpm para diversas correntes de cargas nos magnetos do freio eletromagnético de 0,1A, 0,2A e 0,3A.

Gráfico 6 - Resposta do Sistema Controlado Pela RNA para carga de 0,1A




Fonte: Próprio Autor

Gráfico 7 - Resposta do Sistema Controlado Pela RNA para carga de 0,2A



Fonte: Próprio Autor

Gráfico 8 - Resposta do Sistema Controlado Pela RNA para carga de 0,3A

Fonte: Próprio Autor

Pode ser observado nos gráficos 6,7 e 8 que as simulações mostram que as curvas de reação do sistema atingiram os valores de *setpoint* com nenhum sobressinal e também um tempo de estabilização bastante razoável.

Ainda, nota-se que o controlador neural se comportou com uma curva bastante semelhante as curvas do controlador PI para os mesmos valores de referência e corrente de carga, como pode ser visto nos gráficos 3 e 4.

Uma análise semelhante foi realizada, agora com o sistema sob o controle do controlador neural. Através da ferramenta *step info* do MATLAB® os valores dos parâmetros de desempenho do sistema controlado pela rede neural também foram coletados para cada configuração e com eles foi construído a Tabela 8. Nesta tabela, são apresentados as médias dos valores de pico, sobressinal e tempo de estabilização para as configurações da malha de controle apresentadas nos gráficos 6, 7 e 8.

Tabela 8 - Parâmetros de Desempenho do Sistema com o Controlador Neural


Valores de Referência (rpm)	Valor de Pico Médio (rpm)	Sobressinal Médio (%)	Tempo de Estabilização Médio (s)
1675	0	0	9,31
2238	0	0	13,56
2800	0	0	16.25

Fonte: Próprio Autor

De acordo com a tabela, pode ser verificado que o sistema controlado pela rede neural apresenta um desempenho superior em relação ao controlador PI. Nesta configuração as curvas de respostas do sistema não apresentaram sobressinais, como pode ser visto, e conseqüentemente não tiveram valores de pico. Já em relação ao tempo de estabilização os valores não tiveram mudanças significativas se comparado as curvas de reação do sistema ao degrau.

Entretanto, uma outra análise foi realizada através de simulações com o intuito de comparar o controlador inteligente proposto com o controlador PI construído. Da mesma maneira que o sistema controlado pelo PI foi testado, desta vez, o sistema com o controlador neural foi submetido a valores de referência alternados, em que inicialmente o *setpoint* escolhido foi de 1675rpm e em seguida subiu para o valor de 2800rpm e por fim foi decrescido para 2238rpm. A curva de reação do sistema foi construída pelo MATLAB® e o resultado está mostrado no Gráfico 9.

Gráfico 9 - Resposta do FEF Controlado Pelo PI e Pelo Controlador Neural



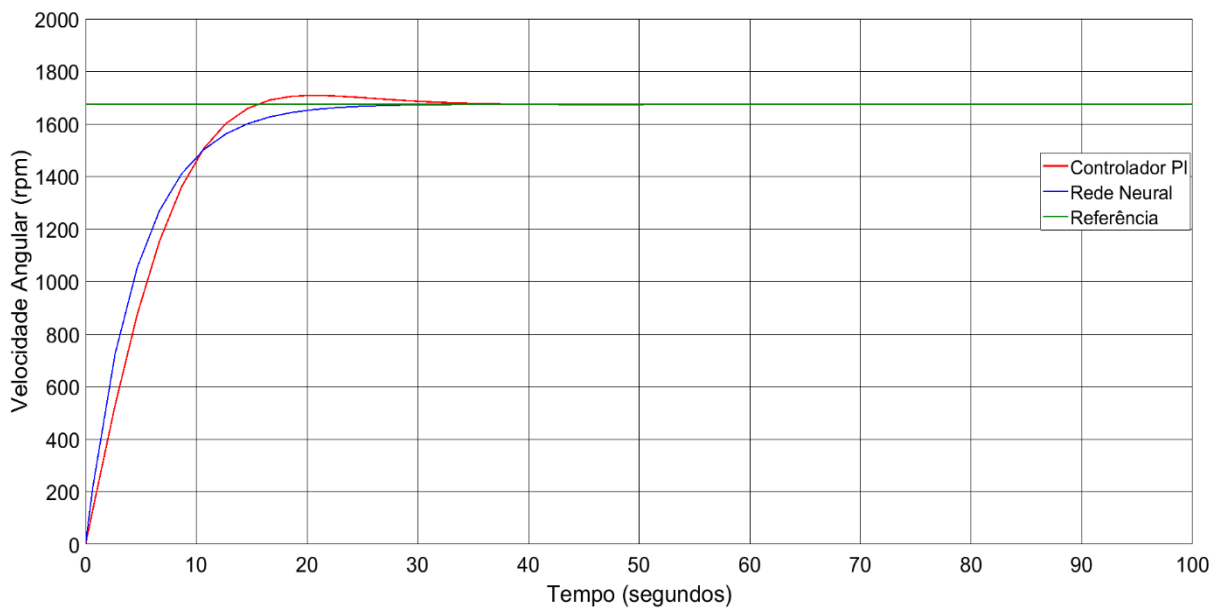
Fonte: Próprio Autor

Pode ser observado que numa situação em que ocorrem variações dos valores de referência, que neste caso é a velocidade angular do motor, o sistema controlado pelo PI apresenta resultados bastante razoáveis, no entanto, o controlador neural tem um desempenho superior. O sistema controlado pela rede neural consegue responder de forma satisfatória aos valores de referência solicitados com um menor tempo de estabilização e nenhum sobressinal.

Vale salientar que a rede neural conseguiu, através do treinamento, aprender os diferentes valores de referência impostos e também os diferentes valores de carga, reforçando o fato de que as redes neurais têm capacidade de generalização. Desta forma o controlador neural conseguiu aplicar na planta do sistema um sinal de controle mais adequado.


Os gráficos 10, 11 e 12 mostrados a seguir apresentam algumas comparações das curvas de resposta do controlador PI e do controlador neural para três diferentes valores de referência e correntes no freio.

Gráfico 10 - Controlador PI e Neural Para Velocidade de 1675rpm e 0,1A de Carga no Freio




Fonte: Próprio Autor

Gráfico 11 - Controlador PI e Neural Para Velocidade de 2238rpm e 0,2A de Carga no Freio.



Fonte: Próprio Autor

Gráfico 12 - Controlador PI e Neural Para Velocidade de 2799rpm e 0,3A de Carga no Freio.



Fonte: Próprio Autor

Estas curvas refletem que a proposta do controlador neural tem bons resultados se comparado aos controladores convencionais proporcional integral. Portanto a proposta do trabalho apresenta bons indícios que os experimentos reais também apresentem desempenho bastante satisfatórios na bancada de testes do Freio Eletromagnético de Foucault.

4.4 RESULTADOS EXPERIMENTAIS

Seguindo a metodologia utilizada neste trabalho, o controlador neural foi implementado na bancada do Freio Eletromagnético de Foucault, descrito no Capítulo 4, com a finalidade de obter os resultados experimentais e verificar a viabilidade prática do controle através de um controle inteligente que utiliza redes neurais artificiais.


Desta forma, o controlador neural elaborado foi implantado no sistema supervisorio da bancada, salientando que toda a implementação neste sistema foi realizada através do uso de *scripts* computacionais em *Visual Basic*. O programa implementado em *VBScripts* seguiu o seguinte passo a passo:

- 1) Declaração de Variáveis;
- 2) Normalização dos Dados;
- 3) Inclusão dos Pesos e Bias da RNA desenvolvida;
- 4) Implementação da rede neural (camada de entrada, camada intermediária e de camada de saída);
- 5) Desnormalização dos dados;
- 6) Obtenção dos valores de Saída (Sinal de Controle)


O resultado final do script do controlador neural representa o sinal de controle que será aplicado no sistema real. Este sinal de controle obtido é monitorado pelo sistema supervisorio e foi configurado para controlar a frequência do inversor conectado ao motor do FEF, desta forma, quando o sistema percebe a variação de corrente nos magnetos do freio, o inversor de frequência recebe o sinal do controlador neural e desta forma é realizado a adaptação do sistema para a nova configuração de carga do motor.

Para verificar a validade do controlador neural e seu correto desenvolvimento, repetimos algumas simulações realizadas pelo *Simulink/MATLAB®* descritas na seção 4.3. Os primeiros testes da bancada consistiram em observar se o controlador neural responderia aos valores de referência solicitados, dentre eles as velocidades angulares de 1675rpm, 2238rpm e 2799 rpm.

Os gráficos abaixo mostram os resultados experimentais das curvas de reação do sistema para cada uma destas velocidades de referência. Ainda, foram montadas as curvas dos valores dos erros do sistema que representam a diferença entre o valor de referência e a resposta do controlador neural.


Gráfico 13 - Curva de Resposta Do Controlador Neural Para Velocidade de 1675rpm e 0,1A

Fonte: Próprio Autor


Gráfico 14 - Erro entre o Valor de Referência e a Resposta do Controlador

Fonte: Próprio Autor

Como pode ser observado no Gráfico 13, o controlador neural conseguiu atingir o valor de referência de 1675rpm quando foi solicitado. Já o Gráfico 14 mostra a curva do erro, que indica a diferença entre o valor de saída do sistema e o valor de referência. Desta forma, é possível perceber que o valor do erro em regime permanente foi aproximadamente zero durante este experimento, ou seja, a rede neural atingiu com precisão significativa o valor desejado.

Gráfico 15 - Curva de Resposta Do Controlador Neural Para Velocidade de 2238rpm e 0,2A


Fonte: Próprio Autor

Gráfico 16 - Erro entre o Valor de Referência e a Resposta do Controlador

Fonte: Próprio Autor


Novamente, é possível avaliar pelo Gráfico 15 e 16 que para a velocidade de 2238rpm com carga de 0,2A o controlador neural também conseguiu atingir o valor de referência com boa performance. Já a curva do erro do sistema apresentou valor aproximadamente zero em regime permanente, indicando que o controlador atuou adequadamente.

Gráfico 17 - Curva de Resposta Do Controlador Neural Para Velocidade de 2799rpm e 0,3A



Fonte: Próprio Autor

Gráfico 18 - Erro entre o Valor de Referência e a Resposta do Controlador




Fonte: Próprio Autor

Por fim, a mesma avaliação pode ser realizada pelos Gráficos 17 e 18 quando a velocidade de referência é de 2799rpm e a corrente nos magnetos é de 0,3A. O controlador neural mais uma vez teve sucesso ao atingir o valor do *setpoint* solicitado. Da mesma forma, o erro medido também se aproximou de zero no regime permanente, ou seja, a o controlador neural teve desempenho satisfatório.

Em um segundo experimento realizado no Freio de Foucault, as velocidades angulares foram modificadas com o intuito de verificar se o controlador neural é capaz de controlar o

sistema caso ocorram variações dos valores de referência, mas a corrente de carga seja fixa. O resultado obtido está mostrado no Gráfico 19.

Gráfico 19 - Resposta do Controlador Neural às variações de Velocidades Angulares



Fonte: Próprio Autor

É possível notar que embora as velocidades angulares do sistema variem arbitrariamente o controlador neural conseguiu responder satisfatoriamente aos valores desejados. Este fato reflete na característica fundamental das redes neurais no que diz respeito ao seu aprendizado. A capacidade do controlador neural de atuar na planta para acompanhar as velocidades angulares solicitadas foi claramente alcançada.

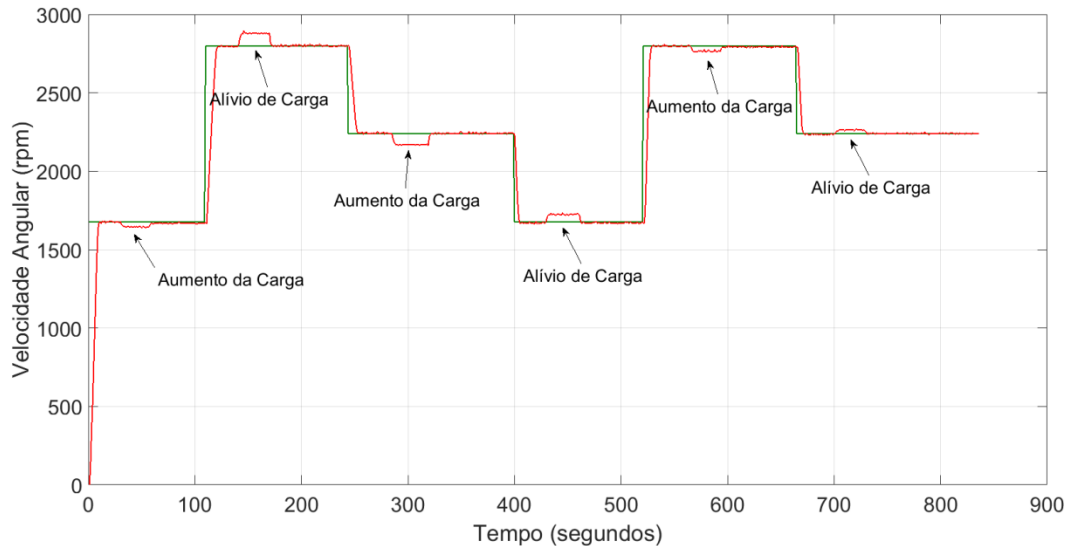
Vale salientar que este experimento não teve modificação nas correntes do freio eletromagnético, mas apenas nas velocidades angulares, ou seja, todo o experimento foi realizado quando a corrente no magneto escolhida foi de 0,2A.

Ainda na tentativa de avaliar a capacidade de controle da rede neural artificial, foi realizado um outro experimento cujos parâmetros de referência foram modificados simultaneamente, ou seja, as velocidades angulares e as correntes de carga do freio eletromagnético foram alterados simultaneamente. O resultado obtido está mostrado adiante.

No Gráfico 20 pode-se perceber que ocorreram variações da velocidade de referência em três passos, o primeiro com 1675 rpm, o segundo com 2799 rpm e o terceiro com 2238 rpm e repetiu-se o ciclo. Ainda, durante o experimento as correntes no magneto do Freio de Foucault foram alteradas entre valores de 0,1A até 0,3A simulando cargas de comportamento dinâmico no eixo do motor.

Estas variações de corrente estão mostradas no gráfico com as setas indicando “Aumento da Carga” e “Alívio de Carga”, ou seja, indica que nestes pontos houve um incremento ou um decremento, respectivamente, das correntes nas bobinas do FEF.

Gráfico 20 - Resposta do Controlador Neural às Variações de Cargas no Freio



Fonte: Próprio Autor

É possível avaliar que nos cenários de aumento ou alívio de carga o sistema (em vermelho) deixa de acompanhar a velocidade de referência (verde) por alguns instantes. Logo em seguida o sistema reestabelece e segue o valor desejado. Esta recuperação do sistema se deve ao fato do controlador neural perceber a mudança das correntes no freio e então atuar no sistema de forma a controlá-lo e assim alcançar novamente o valor de referência.

No entanto, o tempo de recuperação do sistema para a reestabilização para o valor desejado depende exclusivamente do programador da rede neural. Para a finalidade de visualização gráfica, foi escolhido um tempo de recuperação de trinta segundos, e desta forma pode-se perceber no gráfico um pequeno intervalo de tempo para que o sistema volte a atingir o *se point*. Este tempo foi escolhido de forma experimental, ele poderia ser maior ou menor.

Numa abordagem na qual o controlador neural faz esta percepção das mudanças de forma natural, em um sistema real, o tempo de reestabelecimento é grande o suficiente para uma não percepção muito clara desta reestabilização do sistema, e desta forma, não foi adequado para apresentação gráfica deste trabalho.


Com este gráfico de resposta do controlador neural às variações do sistema, pode-se concluir que a rede neural tem uma excelente capacidade de adaptação a variações paramétricas e conseqüentemente apresenta um controle bastante satisfatório.

Por fim, um último experimento foi realizado para a verificar a capacidade de generalização do controlador neural, visto que as redes neurais podem memorizar os dados com os quais ela foi treinada (*overfitting*).

Nesta análise do controlador neural os valores de referência das velocidades angulares foram modificados em faixas próximas para verificar a capacidade da rede em atender as solicitações de velocidades diferentes daquelas trabalhadas até agora. Nesta avaliação experimental foi considerado uma corrente fixa nas bobinas do freio de 0,2A, visto que o sistema já foi avaliado para o caso de correntes variáveis.

Os gráficos a seguir mostram o comportamento do controlador neural nestas situações.

Gráfico 21 - Resposta do Controlador Neural para Velocidade de 1675rpm e Variações de Carga do Freio




Fonte: Próprio Autor

Nesta primeira situação os valores de referência foram de 1675rpm no primeiro momento, 1650rpm no segundo momento e em seguida 1700rpm, repetindo-se o ciclo até o final. É possível observar no Gráfico 21 que o controlador neural conseguiu atingir os valores desejados de velocidade angular dentro desta faixa admitida, validando que não houve memorização dos dados no treinamento da rede.

Num segundo cenário experimental, as velocidades angulares de referência foram de 2238rpm, 2200rpm e em seguida 2276rpm, também repetindo o ciclo até o final do experimento. Pode-se verificar no Gráfico 22 que a rede neural também conseguiu atingir os valores de *setpoint* dentro desta faixa especificada, mais uma vez concluindo que o controlador neural teve bom desempenho na generalização dos dados.


Gráfico 22 - Resposta do Controlador Neural para Velocidade de 2222rpm e Variações de Carga do Freio



Fonte: Próprio Autor

Por fim, o último cenário experimental mostrado no Gráfico 23 foi realizado com a velocidade angular de 2799rpm decaindo para 2759rpm e em seguida subindo para 2839rpm e, da mesma forma, os passos foram repetidos até o final do experimento. Mais uma vez é possível notar que o controlador neural conseguiu alcançar os valores de referência estabelecidos.

Gráfico 23 - Resposta do Controlador Neural para Velocidade de 2222rpm e Variações de Carga do Freio



Fonte: Próprio Autor

Através das análises do comportamento do controlador neural diante de variações dos valores de referência, os resultados demonstraram que a rede neural obteve um desempenho bastante satisfatório e realizou a estabilização do sistema em diversas situações, salientando

que a rede neural não memorizou os dados de treinamento e apresentou o aprendizado esperado.

5 CONCLUSÃO E TRABALHOS FUTUROS

A vasta utilização dos motores elétricos em diversas máquinas e equipamentos nos processos fabris é de fato uma área de grande interesse em pesquisas e estudos no que diz respeito ao controle destes grandes sistemas. Ferramentas cada vez mais sofisticadas são utilizadas para interagir com os motores industriais com a finalidade de executar tarefas das mais variadas possíveis, desde executar pequenas ações com alta precisão ou até mesmo içar grandes blocos maciços que pesam toneladas.

Para todas estas tarefas são utilizados sistemas de controle que atuam diretamente nos parâmetros internos dos processos a fim de que atendam as solicitações exigidas. Diante disto, controladores do tipo PID são utilizados para regular e comandar as variáveis dos sistemas industriais para assim garantir a segurança de operação e a qualidade dos processos. No entanto, ocorrem variações paramétricas destes sistemas que muitas vezes os controladores convencionais não conseguem se adequar.

Diante desta perspectiva, uma abordagem alternativa a estes controles convencionais é a utilização de sistemas de inteligência artificial, mais especificamente as Redes Neurais Artificiais (RNA's) como controladores industriais. Estes sistemas são conhecidos pela alta capacidade de aprendizado e generalização uma vez que sejam treinados a partir de exemplos de um sistema real.

Neste trabalho foi investigado a utilização de uma rede neural artificial para controlar um sistema de simulação de cargas para motores de indução. Através de uma bancada de testes conhecida como Freio Eletromagnético de Foucault, diversas cargas foram simuladas num motor de indução trifásico para verificar sua resposta as variações dos parâmetros internos.

Inicialmente foi utilizado um controlador convencional do tipo proporcional-integral para controlar o sistema do freio de Foucault e a partir de dados obtidos destes experimentos foi desenvolvido um controlador neural que possa operar sob quaisquer cenários de variações que possam ocorrer.

Desta forma, uma rede neural artificial foi criada a partir de um banco de dados que foi adequadamente normalizado. Em seguida, uma série de testes foram realizados com a finalidade de escolher a melhor configuração da arquitetura da rede neural com base no critério de menor erro quadrático. De acordo com os testes de simulação foi criado uma rede

neural para então ser implementada no sistema real do freio eletromagnético através de um *script* da linguagem Visual Basic.

Os resultados da implementação do controlador neural no sistema real demonstraram que a rede neural teve um bom desempenho, atendendo as solicitações de velocidade angular e carga no motor. Foi possível observar através das curvas de respostas que para quaisquer valores de referência dentro das faixas escolhidas, o controlador neural conseguiu responder de forma satisfatória aos valores de referência.

Além disso, os testes mostraram que embora ocorram variações paramétricas do sistema cuja rede não conhece, por não ter sido treinada, o controlador baseado em redes neurais artificiais teve a capacidade de interpretar estes dados desconhecidos e conseqüentemente generalizar o conhecimento, atendendo de forma bastante coerente aos valores de referência.

O sistema de controle baseado em redes neurais artificiais apresentou resultados aceitáveis e adequados para as situações nas quais ele foi submetido. Foi possível observar que os valores alcançados foram eficientes no sentido de um controlador robusto, de precisão relativamente boa e versatilidade na implementação em sistemas reais.

Por outro lado, o treinamento da rede neural artificial e a escolha da arquitetura da rede neural não é de tarefa fácil, o que pode apresentar dificuldades para o seu desenvolvimento em sistemas mais complexos. Embora existam diversas redes neurais alternativas, as redes neurais do tipo MLP apresentam grande aplicabilidade.

Para uma avaliação de trabalhos futuros com ferramentas de inteligência artificial, pode-se destacar algumas propostas:

- Estudo de outros tipos de redes neurais e algoritmos de treinamento aplicado em controle de sistemas industriais.
- Desenvolver um controlador neural que faça o ajuste dos pesos sinápticos de forma automática quando ocorra alguma variação paramétrica do sistema.
- Avaliar a possibilidade de uma rede neural realizar treinamento online, caso ocorram mudanças inesperadas e desta forma ajustar o sistema para a nova configuração.
- Estudar variações de cargas de comportamentos distintos, cujas características variam de dinamicamente no sistema.

- Desenvolver sistemas de controles mistos que utilizem mais de um tipo de inteligência artificial, como por exemplo, lógica *fuzzy* ou *deep-learning*.
- Avaliação da viabilidade do uso de controladores neurais em outras plantas industriais.

REFERÊNCIAS BIBLIOGRÁFICAS

AGUIRRE. L. A. Introdução à Identificação De Sistemas. 3ª. Ed, Editora UFMG, Belo Horizonte, 2007.

ANDREAS K, MICHAEL H, Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence, Business Horizons, Volume 62, Issue 1, 2018, Pages 15-25, ISSN 0007-6813, <https://doi.org/10.1016/j.bushor.2018.08.004>.

BEGA, E.; FINKEL, V. S.; KOCH, R. Instrumentação industrial, Instituto Brasileiro de Petróleo e Gás, Rio de Janeiro, 2006.

BROWN, M., HARRIS, C.: "Neurofuzzy adaptive modelling and control". Prentice Hall 1994.

CAMPESTRINI, L. (2006) Sintonia de controladores PID descentralizados baseada no método do ponto crítico. Tese (Mestrado em Engenharia Elétrica). Porto Alegre – RS, Universidade Federal do Rio Grande do Sul.

CAMPOS, M. C. M. M., TEIXEIRA, H. C. G. (2006). Controles típicos de equipamentos e processos industriais. 1ª ed. São Paulo: Edgard Blücher.

COELHO, A.A.R., LEANDRO, S. C. (2004), Identificação de Sistemas Dinâmicos Lineares, Editora da UFSC, Santa Catarina, SC.

COLACO, D, ALEXANDRIA, A.R. (2007). IV Congresso de Inovação tecnológica em Engenharia Elétrica - IV CITENEL. 10.13140/2.1.2111.9689.

Colaco, Daniel & Alexandria, Auzuir & Cortez, Paulo & B B Frota, J & N De Lima, J & E A L Calazans, A & A Façanha, F. (2007). IV Congresso de Inovação tecnológica em Engenharia Elétrica - IV CITENEL. 10.13140/2.1.2111.9689.

ELETROBRAS/PROCEL. Conservação de Energia: Eficiência Energética de Instalações e Equipamentos. 3º Edição. Itajubá, MG,2001: Editora da EFEI Itajubá, MG,2001. Volume único.

FAVARO, J. Controle preditivo aplicado à planta piloto de neutralização de pH. Escola Politécnica, Universidade de São Paulo. São Paulo, 2012.

GRIFFITHS, D. J, Introduction to Electrodynamics, 3ed, Prentice Hall, New Jersey, 1999.

GUEDES, M, O motor de Indução Trifásico. Faculdade de Engenharia Universidade do Porto. Porto, Portugal, 1994.

- HAGAN, M. T., MEHAJ, M. B., “Training Feedforward Networks with Marquadt Algorithm”. IEEE Transactions on Neural Networks, Vol. 5, NO 6, November 1994, p. 989-993.
- HASSOU, M. H., “Fundamentals of Artificial Neural Networks”. MIT Press, 1995
- HAYKIN, S. Redes Neurais: Princípios e Prática. 2. ed. Porto Alegre: Bookman, 2001.
- HAYKIN, Simon. Redes neurais: princípios e prática. Bookman Editora, 2007.
- HUNT, K.J.; SBARBARO, D.; ZBIKOWSKI, R., Gawthrop, P.J. “Neural network for control systems - a survey”. Automática. Vol. 28 nº 6. pg. 1083-1112. 1992.
- Journal of Scientific Instruments. vol. 8, no. 11, p.337 – 349. nov.1931.
- KRAUS, John Daniel; CARVER, Keith R. Eletromagnetismo. 2. ed. Rio de Janeiro: Guanabara Dois, 1978. 780p.
- MCCULLOCH, W. PITTS, W., “A logical calculus of ideas immanent in nervous activity,” Bulletin of Mathematical Biophysics, vol. 5, pp. 115–133, 1943.
- MEDIOUNI, H. et al. Artificial neural networks applied on double squirrel cage induction motor for an electric vehicle motorisation. 2017 International Conference on Electrical and Information Technologies (ICEIT). Anais. In: 2017 INTERNATIONAL CONFERENCE ON ELECTRICAL AND INFORMATION TECHNOLOGIES (ICEIT). Rabat: IEEE, nov. 2017 disponível em: <<http://ieeexplore.ieee.org/document/8255243/>>
- NISE, N. S. Engenharia de sistemas de controle. 5. ed. Rio de Janeiro: LTC, 2009.
- OGATA, K. Engenharia de Controle Moderno. 3. ed, LTC, Rio de Janeiro, 2010.
- OLIVEIRA, A. L. LIMA, Instrumentação – Fundamentos de Controle de Processo. SENAI - Serviço Nacional de Aprendizagem Industrial. Espírito Santo. 1999
- OLIVEIRA, J. P. B. M. Review of Auto-tuning Techniques for Industrial PI Controllers. Dissertação de Mestrado. University of Salford, 1994.
- PAUL, Robert W. Some electrical instruments at the Faraday centenary exhibition,
- PEREIRA, A. H. Freio Eletromagnético para Ensaio de Motores Elétricos de Indução. Universidade Federal do Ceará, Fortaleza, 2006.
- PLONUS, Martin A. Applied Electromagnetics. New York: McGraw – Hill, 1978.
- PRECHELT, L., PROBEN 1 – A Set of Neural Network Benchmark Problems and Benchmarking Rules, Technical Report 21/94 Fakultät Informatik, Universität Karlsruhe, Germany, September 1994.

RIEDMILLER, M., BRAUN, H., “A direct adaptive method for faster backpropagation learning: The RPROP algorithm.”, IEEE International Conference on Neural Networks, vol 1., 1993, pp. 586-591.

ROCHA, F. L. (2006). Identificação de sistemas não-lineares multivariáveis usando redes neurais perceptron multicamadas e função de base radial. Pontifícia Universidade Católica do Paraná, Paraná, Brasil.

SCHIEBER, David. Optimal dimensions of rectangular electromagnet for braking purposes IEEE Transactions on magnetics. vol. 11, no. 3, p.948 – 952, maio 1975.

SIMEU, E. Application of NARMAX modelling to eddy current brake process. Control Singapore. 19–22, p. 762-768, aug, 2001.

SOUZA, R. D, MANSANARES, A. M. Balança Curie e Correntes de Foucault, Instrumentação para o Ensino, Universidade Estadual de Campinas, Instituto de Física, 2005.

TAFNER, M. A. (1996). Reconhecimento de palavras isoladas usando redes neurais artificiais. Dissertação de mestrado, Universidade Federal de Santa Catarina. Florianópolis, SC.

TAJNE, S. K.; SRIVASTAVA, S. P. Comparative performance analysis of vector controlled induction motor drive for neural controller and dsp implemented pi controller, International Conference on Communication Systems and Network Technologies, 2012.

VANDORE, V. Auto-tuning control using ziegler nichols. 2006. 9th IEEE/AS International Conference on Industry Applications. Disponível em: <<http://www.controleng.com/article/CA6378136.html>>.

WHITTAKER, E.T., A history of the theories of aether and electricity from the age of Descartes to the close of the nineteenth century. Londres, 1910.

WIDRON B., WALACH, E.: “Adaptive Inverse Control”. Prentice Hall. 1996.

WONG, C. F.; SHIPPEN, J. J. B. Neural Network Control Strategies for Low Specification Servo Actuators. Intenational Journal of Machine Tools &Manufacture, 1998.

WOUTERSE, J. H. Critical torque and speed of eddy current brake with widely separated soft iron poles. Electric Power Applications, IEEE Proceedings B; vol. 138, no.4, pp.153-158, jul. 1991.

ZURADA, J.M., “Introduction to Artificial Neural Systems”. West Publishing, 1992.

ANEXOS

ANEXO I – TABELA DE DISPOSITIVOS DA BANCADA DO FREIO ELETROMAGNÉTICO – LEEQE – DEE – UFPE

Tabela A1 - Lista de dispositivos na bancada do Freio de Foucault do LEEQE - UFPE

Identificação dos Equipamentos	Descrição	Fornecedor
4AM81 95-0AN00-0C	Transformador de comando - 300VA - Entrada (220,380,440Vac) saída (110,220Vac)	SIEMENS
6SE6 440-2UD21-1AA1	MM440-380-480V/1,5 CV/3,1-3,4A	SIEMENS
8WA1 011-1SF12	Borne fusível - um polo	SIEMENS AG
8WA2 011-1DF20	2-conductor through terminal block; CAGE CLAMP connection; grey	SIEMENS AG
8WA2 011-1DG20	Conector de passagem cage clamp, até #4mm ² , 32A, cinza	SIEMENS
8WA2 011-1PF20	2-conductor through terminal block; CAGE CLAMP connection; grey	SIEMENS AG
8WA2 831	Ponte de ligação para conector (2,5 à 6 mm)	SIEMENS
Fusível tipo G - 2A/0,5KA	Fusível de vidro tipo G - 2A/0,5KA	Genérico
Fusível tipo G, 1,5A/0,5KA	Fusível de vidro tipo G - 1,5A/0,5KA	Genérico
Fusível tipo G, 1A/0,5KA	Fusível de vidro tipo G - 1A/0,5KA	Genérico
PR-3920-TT T	Transmissor de peso (0-20Kgf) para corrente (4-20mA), alimentado em 220Vca	Transtec
3SB32 02-2KA11	Comutador de duas posições com retenção + 1NA	SIEMENS AG
3SB3317-6AA70	Complete unit, square indicator light operating voltage 24V AC/DC lampholder BA9S clear	SIEMENS AG
54ZT	Encoder magnético, 20KHz, 5 - 18Vcc	Veeder-Root/Dynapar
Freio de Foucault	Eletrodinâmico	Equitron Sistem
FV30S00	Transdutor de frequência para tensão ou corrente	Veeder Root
M-2402 Auto	Auto transformador, 220V, 480W, 2A, 50/60Hz	Auje
Miliamperímetro 4-20mA/0-2,5A	Miliamperímetro com escala em corrente	ENGRO
NA-330 -	Célula de carga - 0-20Kgf	Transtec
Ponte retificadora	Ponte retificadora de onda completa	Genérico

Fonte: Documentação do Freio de Foucault do LEEQE – UFPE