



Universidade Federal da Paraíba
Centro de Tecnologia
Programa de Pós-Graduação em Engenharia Mecânica
Mestrado - Doutorado

CONTROLADOR NEURAL APLICADO A UM SISTEMA POSICIONADOR ACIONADO POR MOTORES DE INDUÇÃO TRIFÁSICOS

por

Carlos Alberto Nóbrega Sobrinho

Dissertação de Mestrado apresentada à Universidade Federal da
Paraíba para obtenção do grau de Mestre

CARLOS ALBERTO NÓBREGA SOBRINHO

**CONTROLADOR NEURAL APLICADO A UM
SISTEMA POSICIONADOR ACIONADO POR
MOTORES DE INDUÇÃO TRIFÁSICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal da Paraíba, em cumprimento às exigências para obtenção do Grau de Mestre.

Orientador: Professor Dr. Simplício Arnaud da Silva

N754C Nóbrega Sobrinho, Carlos Alberto.

Controlador neural aplicado a um sistema posicionador
acionado por motores de indução trifásicos / Carlos Alberto
Nóbrega Sobrinho.- João Pessoa, 2011.

.106f. : il.

Orientador: Simplício Araud da Silva

Dissertação (Mestrado) – UFPB/CT

1. Engenharia Mecânica. 2. Redes neurais. 3. Controle de
posição. 4. Mesa de coordenadas.

UFPB/BC

CDU: 621(043)

**CONTROLADOR NEURAL APLICADO A UM SISTEMA
POSICIONADOR ACIONADO POR MOTORES DE
INDUÇÃO TRIFÁSICOS**

por

CARLOS ALBERTO NÓBREGA SOBRINHO

Dissertação aprovada em 24 de fevereiro de 2011

Período letivo 2010.2

Prof. Dr. José Bezerra de Menezes Filho

Examinador Externo – IFPB

Prof. Dr. Isaac Soares de Freitas

Examinador Interno – UFPB

Prof. Dr. Simplício Arnaud da Silva

Orientador - UFPB

DEDICATÓRIA

Dedico este trabalho a Deus, a meus pais Antônio Roberto Nóbrega e Rosa de Lourdes Melo Silva Nóbrega, ao meu irmão Luiz Henrique Melo Silva Nóbrega, bem como a todas as pessoas que tenho grande admiração, respeito e que contribuíram de forma direta e indireta no decorrer da minha formação.

AGRADECIMENTOS

Primeiramente, a Deus, que me iluminou na realização deste trabalho e por sua presença constante em minha vida.

A minha família pelo grande esforço e dedicação em todas as etapas da minha vida.

A Maura Rodríguez e família, pelo incentivo e compreensão.

Ao meu orientador, professor Simplício Arnaud da Silva pela atenção, apoio e amizade.

Ao professor José Bezerra de Menezes Filho pela dedicação, esforço, paciência e amizade, que foram fundamentais na conclusão desse trabalho.

Ao professor Isaac Soares de Freitas pela atenção e por sempre estar disposto ajudar.

Aos professores Jobson Francisco da Silva e Arnaldo Vilela de Lima, e a Sra. Maria Cléa Cavalcante da Silva, pela contribuição e incentivo no decorrer da montagem experimental desse projeto.

A todos os professores e alunos do Programa de Pós Graduação em Engenharia Mecânica por estarem sempre dispostos em ajudar para o desenvolvimento do trabalho.

À CAPES pelo apoio financeiro.

CONTROLADOR NEURAL APLICADO A UM SISTEMA POSICIONADOR ACIONADO POR MOTORES DE INDUÇÃO TRIFÁSICOS

RESUMO

No presente trabalho apresenta-se um projeto de controladores neurais para uma mesa de coordenadas X-Y com dois graus de liberdade. Ambas as bases que compõem a mesa se deslocam horizontalmente, sendo acionadas por motores de indução trifásicos alimentados através de inversores de frequência. Para a detecção de posição das bases, encoders ópticos foram acoplados aos eixos dos motores, a fim de serem obtidos os deslocamentos angulares desses últimos. Uma placa de aquisição de dados realizou a interface entre um computador Core2Duo 2,4 GHz e a planta, para captar os sinais provenientes dos encoders e fornecer os sinais de controle aos inversores de frequência. No ambiente de programação LabVIEW®, implementaram-se os controladores neurais, os quais determinam as variáveis de controle que acionam os motores. Sinais de referência do tipo degrau e acompanhamento de trajetória foram utilizados para a avaliação do desempenho do sistema. Resultados experimentais são apresentados.

Palavras chaves – redes neurais, controle de posição, mesa de coordenadas.

NEURAL CONTROLLER APPLIED TO A POSITIONER SYSTEM DRIVED BY TREE-PHASE INDUCTION MOTORS

ABSTRACT

This work presents the design of neural controllers for a X-Y table with two degrees of freedom. Both bases of the table moves horizontally, powered by tree-phases induction motors operated by frequency inverters. For detection position of bases, optical encoders were engaged to the axes of the engines to be obtained the angular displacement. A data acquisition board made the interface between a 2.4 GHz Core2Duo computer and the system. This board catches signals from the encoders and provides control signals to the frequency inverters. Neural controllers implemented in LabVIEW® software, determinate the control variables to power the engines. Step, sine and cosine reference were used to evaluate the system performance, in position control and following trajectory. Experimental results are presented.

Keywords – neural network, position control, X-Y table.

SUMÁRIO

CAPÍTULO I.....	18
APRESENTAÇÃO	18
1.1 INTRODUÇÃO.....	18
1.2 OBJETIVOS E MOTIVAÇÃO DA PESQUISA	20
1.3 ORGANIZAÇÃO DA DISSERTAÇÃO	20
CAPÍTULO II	22
REVISÃO BIBLIOGRÁFICA	22
2.1 INTRODUÇÃO.....	22
2.2 HISTÓRICO	22
2.3 FUNCIONAMENTO DA MÁQUINA-FERRAMENTA COM CNC	23
2.4 HISTÓRICO E EVOLUÇÃO DOS MÉTODOS DE CONTROLE	25
2.5 SISTEMAS DE CONTROLE EM MALHA ABERTA E MALHA FECHADA.....	26
2.6 CONTROLE CLÁSSICO E MODERNO	28
2.7 CONTROLE ADAPTATIVO	29
2.8 CONTROLE FUZZY	31
2.9 REDES NEURAIS ARTIFICIAIS	33
2.10 ALGORITMOS GENÉTICOS	36
2.11 CONTROLADORES HÍBRIDOS INTELIGENTES	37
<i>2.11.1 Híbridos de Função-Reposição (Substituição)</i>	<i>38</i>
<i>2.11.2 Híbridos de Intercomunicações</i>	<i>39</i>
<i>2.11.3 Híbridos Polimórficos</i>	<i>41</i>
2.12 COMENTÁRIOS E CONCLUSÕES	42
CAPÍTULO III DESCRIÇÃO DO FUNCIONAMENTO DA MESA DE COORDENADAS — MONTAGEM E INSTRUMENTAÇÃO.....	43
3.1 INTRODUÇÃO.....	43
3.2 MESA DE COORDENADAS.....	43
<i>3.2.1 Sistema de Aquisição de Dados</i>	<i>44</i>
<i>3.2.2 Sistema de Acionamento.....</i>	<i>45</i>
<i>3.2.3 Sistema de Medição</i>	<i>47</i>
<i>3.2.4 Sistema de Comando e Proteção</i>	<i>50</i>
3.3 COMENTÁRIOS E CONCLUSÕES.....	52
CAPÍTULO IV IDENTIFICAÇÃO DO SISTEMA E PROJETO DO CONTROLADOR NEURAL	53
4.1 INTRODUÇÃO.....	53
4.2 IDENTIFICAÇÃO, PROJETO E SIMULAÇÃO DO SISTEMA DE CONTROLE	53
<i>4.2.1 Identificação experimental (caixa preta).....</i>	<i>54</i>
<i>4.2.2 Modelo do Controlador Neural</i>	<i>59</i>
<i>4.2.3 Implementação do Controlador Neural</i>	<i>60</i>
<i>4.2.4 Algoritmo de Retropropagação da Rede Neural.....</i>	<i>64</i>

4.2.5 <i>Simulação do sistema e aquisição dos pesos sinápticos</i>	66
4.6.1 <i>Resposta do sistema para simulação dos controladores neurais</i>	67
4.7 COMENTÁRIOS E CONCLUSÕES	72
CAPÍTULO V	73
UTILIZAÇÃO DO CONTROLADOR NEURAL NO ACIONAMENTO DA MESA	73
5.1 INTRODUÇÃO	73
5.2 NOTAS SOBRE O SISTEMA	73
5.3 ENSAIOS DE ACIONAMENTO DO SISTEMA	74
5.4 COMENTÁRIOS E CONCLUSÕES	98
CAPÍTULO VI	99
COMENTÁRIOS E CONCLUSÕES FINAIS	99
6.1 COMENTÁRIOS E CONCLUSÕES	99
6.2 PROPOSTAS PARA TRABALHOS FUTUROS	100
REFERÊNCIAS BIBLIOGRÁFICAS	101

LISTA DE TABELAS

Tabela 3.1 – Conversão Gray – Decimal	49
Tabela 4.1 – Valores observados na simulação para referência ao degrau	69
Tabela 4.2- Valores simulados do controle neural de posição para referências com funções circulares	71
Tabela 5.1 – Índices de desempenho experimentais extraídos das curvas de resposta da base X.....	77
Tabela 5.2 – Índices de desempenho experimentais extraídos das curvas de resposta da base Y.....	79
Tabela 5.3 – Índices de desempenho experimentais para degraus de amplitudes variadas extraídos das curvas de resposta da base Y.....	80
Tabela 5.4 – Índices de desempenho experimentais para degraus de amplitudes variadas extraídos das curvas de resposta da base Y.....	81

LISTA DE FIGURAS

Figura 2.1 – Esquema de um CNC	24
Figura 2.2 – Torno CNC	24
Figura 2.3 – Sistema de Controle em Malha Alberta (SCMA)	27
Figura 2.4 – Sistema de Controle em Malha Fechada (SCMF)	27
Figura 2.5- Diagrama de blocos do sistema de controle de ganho escalonado	30
Figura 2.6 – Modelo do Neurônio de McCulloch e Pitts	33
Figura 2.7 - Codificação do cromossomo de uma rede neural	38
Figura 2.8 - Definições das funções de pertinência	39
Figura 3.1 – Sistema de Posicionamento Expandido.....	44
Figura 3.2 – Equipamentos da Interface e aquisição de dados.....	45
Figura 3.3 – Diagrama de blocos do sistema de acionamento em malha aberta.....	45
Figura 3.4 – Circuito de condicionamento de sinal digital	46
Figura 3.5 – Sensor de posição	48
Figura 3.6 – Circuito Shcmitt Trigger.....	48
Figura 3.7 – Conversão Gray – Decimal para 1/4 de revolução do encoder.....	49
Figura 3.8 - Incremento e decremento dos números inteiros pelo contador.	50
Figura 3.9 – Diagrama de acionamento, comando e proteção do sistema	51
Figura 3.10 – Diagrama esquemático geral da disposição dos equipamentos do sistema de posicionamento	51
Figura 4.1 – Sinal de excitação da base X.....	55
Figura 4.2 – Curva de resposta experimental para base X.....	56
Figura 4.3 - Curvas de Resposta Experimental e Simulada do Sistema Para Base X	57
Figura 4.4 – Sinal de Excitação Para Base Y	57
Figura 4.5 – Curva de resposta experimental para base Y	58
Figura 4.6 - Curvas de Resposta Experimental e Simulada do Sistema Para Base Y	58
Figura 4.7 – Arquitetura Multicamada Utilizada no Controle do Sistema	59

Figura 4.8 – Rede Neural detalhada.....	63
Figura 4.9 – Controlador Neural Para a Base X.....	64
Figura 4.10 – Controlador Neural Para a Base Y	64
Figura 4.11 – Curva de resposta da base X para uma referência degrau de 14 mm.....	67
Figura 4.12 – Variável de controle para resposta da base X para referência ao degrau de 14 mm.....	67
Figura 4.13 – Resposta da base Y para referência ao degrau de 10 mm	68
Figura 4.14 – Variável de controle para resposta da base Y para referência ao degrau de 10 mm.....	68
Figura 4.15 – Curva de Resposta da Base X ao Sinal de Excitação Senoidal para um período $T = 15$ s.....	69
Figura 4.16 – Variável de controle para resposta da base X ao sinal de excitação senoidal	70
Figura 4.17 – Curva de resposta da base Y ao sinal de excitação cossenoidal para um período $T = 15$ s.....	70
Figura 4.18 – Variável de Controle para Resposta da Base Y ao Sinal de Excitação Cossenoidal.....	71
Figura 4.19 – Composição dos Sinais Senoidais para um período $T = 15$ s.....	72
Figura 5.1 – Curvas de resposta e de referência ao Degrau de 100 mm da base X.....	75
Figura 5.2 – Curva de resposta da variável de controle da base X para uma referência do tipo degrau de 100 mm.....	75
Figura 5.3 – Curvas de resposta e de referência ao degrau de -100 mm da base X	76
Figura 5.4 – Curva de Resposta da variável de controle da base X para uma Referência do tipo Degrau de -100 mm.....	76
Figura 5.5 - Curvas de Resposta e de Referência ao Degrau de 70 mm da base Y.....	77
Figura 5.6 - Curva de Resposta da variável de controle da base X para uma Referência do tipo Degrau de 70 mm.....	78
Figura 5.7 - Curvas de Resposta e de Referência ao Degrau de -70 mm da base Y	78
Figura 5.8 - Curva de Resposta da variável de controle da base X para uma Referência do tipo Degrau de -70 mm.....	79
Figura 5.9 – Curva de Resposta e de Referência a Perturbações na base X	82
Figura 5.10 – Curva de resposta da variável de controle resultante das perturbações na base X.....	82
Figura 5.11 – Curva de Resposta e de Referência a Perturbações na base Y	83

Figura 5.12 – Curva de resposta da variável de controle devido resultantes das Perturbações na base Y	83
Figura 5.13 – Curvas de resposta e de referência degrau variável e retorno a posição inicial da base X.....	84
Figura 5.14 – Variável de controle para curvas de resposta e de referência degrau variável e retorno a posição inicial da base X	84
Figura 5.15 – Curvas de resposta e de referência degrau variável e retorno a posição inicial da base Y.....	85
Figura 5.16 – Variável de controle para curvas de resposta e de referência degrau variável e retorno a posição inicial da base Y	85
Figura 5.17 – Curvas de resposta e de referência senoidal da base X (T = 160s).....	86
Figura 5.18 - Variável de controle para curva de resposta senoidal da base X (T = 160 s).....	87
Figura 5.19 – Curvas de resposta e de referência cossenoidal da base Y (T = 160s).....	87
Figura 5.20 – Variável de controle para curva de resposta cossenoidal da base Y (T = 160 s).....	88
Figura 5.21 – Curvas de resposta e de referência, compostas pelas bases X e Y (T = 160 s).....	88
Figura 5.22 – Curvas de resposta e de referência senoidal da base X (T = 80s).....	89
Figura 5.23 – Variável de controle para curva de resposta senoidal da base X (T = 80s).....	89
Figura 5.24 – Curvas de resposta e de referência cossenoidal da base Y (T = 80s).....	90
Figura 5.25 – Variável de controle para curva de resposta cossenoidal da base Y (T = 80s).....	90
Figura 5.26 – Curvas de resposta e de referência, compostas pelas bases X e Y (T = 80 s).....	91
Figura 5.27 - Curvas de resposta e de referência senoidal da base X (T = 40 s).....	91
Figura 5.28 - Variável de controle para curvas de resposta e de referência senoidal da base X (T = 40 s)	92
Figura 5.29 - Variável de controle para curva de resposta senoidal da base Y (T = 40 s).....	92

Figura 5.30 - Variável de controle para curva de resposta cossenoidal da base Y (T = 40s).....	93
Figura 5.31 - Curvas de resposta e de referência, compostas pelas bases X e Y (T = 40 s).....	93
Figura 5.32 - Curvas de resposta e de referência senoidal da base X (T = 20 s).....	94
Figura 5.33 - Variável de controle para curva de resposta senoidal da base X (T = 20 s).....	94
Figura 5.34 - Curvas de resposta e de referência cossenoidal da base Y (T = 20 s).....	95
Figura 5.35 - Variável de controle para curva de resposta cossenoidal da base Y (T = 20 s).....	95
Figura 5.36 - Curvas de resposta e de referência, compostas pelas bases X e Y (T = 20 s).....	96
Figura 5.37 - Curvas de resposta e de referência senoidal da base X (T = 5 s).....	97
Figura 5.38 - Curvas de resposta e de referência cossenoidal da base Y (T = 5 s).....	97
Figura 5.39 - Curvas de resposta e de referência, compostas pelas bases X e Y (T = 5 s).....	98

LISTA DE SÍMBOLOS

$e(k)$	Erro de posição no instante de amostragem k
$e(k-1)$	Erro de posição armazenado no instante anterior ao tempo k
$e(k-2)$	Erro de posição armazenado no instante anterior ao tempo $k-1$
$e_{ss}(\%)$	Erro de regime permanente do sinal em porcentagem
f	Frequência aplicada ao estator do motor de indução
UP %	Ultrapassagem Percentual do sinal
n_r	Velocidade de rotação do rotor do motor de indução
n_s	Velocidade de rotação síncrona do campo magnético do estator do motor de indução
p	Número de pólos do motor de indução
s	Escorregamento do motor de indução
T	Período do sinal
$T_s(s)$	Tempo de assentamento do sinal em segundos
V_{cc}	Tensão de corrente contínua
in(i)	Sinais de entrada para uma rede neural de multicamadas
S	Operador da Transformada de Laplace
Z	Operador da Transformada Z
W_{hid}	Matriz de pesos sinápticos entre a camada oculta e a camada de saída de uma Rede Neural de Multicamadas
W_{in}	Matriz de pesos sinápticos entre a camada de entrada e a camada oculta de uma Rede Neural de Multicamadas
V_{in}	Matriz do campo induzido na camada oculta da Rede Neural
Y	Matriz do sinal funcional dos neurônios da Rede Neural
vout	Campo induzido na camada de saída da Rede Neural
out	Sinal de saída da Rede Neural
∇_{out}	Gradiente local da camada de saída da Rede Neural
Δ_{hid}	Matriz de variação dos elementos de W_{hid}

∇_{in}	Gradiente local da camada oculta da Rede Neural
Δ_{in}	Matriz de variação dos elementos de W_{in}
η	Fator de convergência da Rede Neural

CAPÍTULO I

APRESENTAÇÃO

1.1 INTRODUÇÃO

Os métodos de processamento de sistemas inteligentes são alvo de estudo desde a época de filósofos como Platão (427 – 347 a.C.) e Aristóteles (384 – 322 a.C.). Apesar disso, pode-se afirmar que os fundamentos dos sistemas inteligentes artificiais são resultados dos últimos 50 anos de pesquisa. Particularmente, o que hoje é conhecido como Redes Neurais Artificiais (RNA) começou a ser desenvolvido em meados do século passado, mas foi no início dos anos 80 que os resultados mais importantes do ponto de vista de aplicação foram obtidos. Com isso, o campo de atuação se ampliou muito, inclusive gerando perspectivas de aplicação na área de controle de sistemas dinâmicos (ZUBEN, 1993).

Atualmente, com a crescente demanda de mercado, seja ela na indústria alimentícia, química, aeroespacial, bélica, entre outras, se faz necessário não só a rapidez, como também a qualidade de produção, exigência cada vez maior do mundo moderno, estando estas características diretamente atreladas as máquinas responsáveis pela fabricação de cada bem; máquinas que antes eram controladas por operadores dos quais dependiam a qualidade de cada produto. A partir do momento que o homem não consegue dar conta da produção, ou seja, suprir às necessidades do mercado consumidor, tanto em relação quantitativa quanto em relação qualitativa, se faz necessário a automação dos equipamentos, isto é, automatizar o processo para que se possa controlá-lo através de sensores, atuadores e controladores, objetivando a realização de alguma tarefa com menor tempo e maior exatidão. Uma mudança significativa foi a substituição do acionamento manual pelos motores elétricos, pelo fato

de apresentarem uma maior eficiência e exatidão, devido à utilização de malhas fechadas de controle com sensores de posição (MENEZES, 2007).

No âmbito da manufatura industrial tem-se como elemento fundamental o posicionamento de um objeto para realização de uma tarefa específica. No que diz respeito à mesa de coordenadas, sua principal função é posicionar uma peça a ser usinada, para que uma ferramenta possa realizar algum trabalho de corte, desbaste, polimento, entre outros.

Para manipulação desses equipamentos, de forma automatizada, dispõe-se de várias técnicas de controle, tais como: os controles clássicos, modernos e inteligentes.

São considerados controles inteligentes, sistemas especialistas e controle baseado em lógica fuzzy, redes neurais e algoritmos genéticos, segundo PARASKEVOPOULOS (1995).

As redes neurais artificiais são baseadas no funcionamento do cérebro humano, e podem ser definidas como um modelo matemático com uma estrutura conveniente que tem analogia com o neurônio biológico; KOVÁCS (1996). O nome rede neural foi dado a tais estruturas matemáticas por sua semelhança com a estrutura e funcionamento das células e dos tecidos nervosos. As redes neurais artificiais são utilizadas para obter resultados aproximados de problemas não lineares através de um mapeamento de entradas e saídas, com habilidade de aprendizagem e armazenamento de dados adaptados ao ambiente computacional.

São inúmeras as aplicações das redes neurais no campo da engenharia mecânica, uma delas foi feita por ARCOS CAMARGO (2002) que apresentou o planejamento de trajetórias de um manipulador robótico usando redes neurais, tendo como principais objetivos mostrar a aplicação de redes neurais artificiais num sistema robótico, realizar um algoritmo para o mapeamento do volume de trabalho e controle da trajetória do manipulador, além de realizar simulações e validar experimentalmente o algoritmo. MENEZES (2007) implementou uma rede de controladores neurais independentes para uma mesa de coordenadas de dois eixos e um controlador neural atuando no modo vetorial em uma mesa de coordenadas acionada por motores de corrente contínua. Seu objetivo foi apresentar uma proposta de acionamento de uma mesa de coordenadas X-Y que utilizasse as informações de referência e de posição no formato de vetores.

1.2 OBJETIVOS E MOTIVAÇÃO DA PESQUISA

O objetivo do presente trabalho é apresentar um acionamento automático de uma mesa de coordenadas X-Y alimentada por motores de indução trifásicos, utilizando redes neurais artificiais para o seu controle de posição e acompanhamento de trajetória.

A aplicação de motores de indução alimentados por inversores de frequência foi motivada pelo fato dessas máquinas serem amplamente utilizadas na automação industrial devido seu preço de aquisição e manutenção, bem como sua robustez proporcionando uma maior versatilidade na variação de velocidade de processos.

A implementação de controladores inteligentes por redes neurais ainda é reduzida em comparação aos controladores clássicos e do tipo adaptativos, no acionamento de mesa de coordenadas (MENEZES, 2007), o que motiva realizar pesquisas científicas quanto às características dessa técnica de controle.

Diante do exposto acima, esta pesquisa visa contribuir para a implementação de controladores inteligentes em controle de posição de máquinas ferramentas acionadas por motores de indução trifásicos, devido a crescente tendência de automação do setor industrial que demandam continuamente novas estratégias de acionamentos. No caso específico dos controladores neurais, as vantagens residem em sua capacidade de adaptação frente a eventuais variações da planta e em sua fácil implementação, utilizando-se a linguagem C ou ambientes de programação do tipo LabVIEW® ou MATLAB®.

1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

O trabalho está organizado em seis capítulos, de forma que cada capítulo apresenta os seguintes conteúdos:

O Capítulo II é iniciado com uma revisão bibliográfica. Em seguida, inicia-se um breve histórico sobre máquinas - ferramentas com ênfase em Controle Numérico Computadorizado (CNC). Logo em seguida é abordado o funcionamento das máquinas-ferramentas com CNC. Na seqüência, é realizada uma abordagem histórica e a evolução dos métodos de controle utilizados em máquinas ferramentas. O capítulo se encerra com comentários e conclusões.

O Capítulo III aborda a descrição do funcionamento de mesa de coordenadas. São mostrados detalhes da montagem e instrumentação do sistema. Será feita a explanação a respeito das partes mecânicas, eletrônicas e elétricas, bem como o

funcionamento do acionamento e captação do deslocamento angular. O capítulo encerra-se com comentários e conclusões.

No Capítulo IV é descrito o processo de identificação para aquisição dos pesos sinápticos iniciais e desenvolvimento dos controladores neurais do sistema de posicionamento estudado. O Capítulo é finalizado com comentários e conclusões.

No Capítulo V são mostrados os resultados experimentais obtidos em testes realizados em laboratório com a estratégia de controle utilizada. Os ensaios apresentados foram obtidos com foco em controle de posição e acompanhamento de trajetória. O capítulo encerra-se com comentários e conclusões.

O capítulo VI, são feitos alguns comentários finais e a conclusão do projeto. Em complemento, é apresentado algumas propostas para trabalhos futuros.

CAPÍTULO II

REVISÃO BIBLIOGRÁFICA

2.1 INTRODUÇÃO

Neste capítulo é apresentada uma breve revisão bibliográfica a respeito da história e aplicação de sistemas de posicionamento em ambientes industriais, bem como a evolução dos acionamentos para estes tipos de sistemas. Será feito um comparativo do ponto de vista técnico citando algumas das vantagens do acionamento por motores de indução trifásicos em relação aos motores de corrente contínua. No que diz respeito aos métodos de controle de sistemas, serão apresentados algumas metodologias de controle clássico, moderno, adaptativos. Ainda serão apresentados os métodos de controle inteligente, tais como, controladores nebulosos, baseados em redes neurais, algoritmos genéticos e a necessidade da fusão dessas técnicas. O capítulo se encerra com a apresentação de comentários e conclusões na seção 2.12.

2.2 HISTÓRICO

A máquina-ferramenta convencional surgiu juntamente com a revolução industrial no século XIX. O torno mecânico, por exemplo, teve sua performance sensivelmente melhorada com a invenção da “máquina a vapor”. Um desses motores girava o eixo-mestre, próximo ao teto da fábrica, cujo movimento era transmitido a vários tornos ao mesmo tempo através de correias de couro. Uma espécie de “motor comunitário”.

Avançando para o século XX, mais precisamente em 1949, o Instituto de Tecnologia de Massachusetts (MIT) e a U.S. Air Force uniram esforços para desenvolver o primeiro comando numérico. O protótipo foi testado com sucesso em uma *fresadora* de três eixos, da *Cincinnati Milling Machine Company*, que até hoje é uma das maiores fabricantes mundiais de máquinas ferramentas e injetoras de termoplásticos (entre outros equipamentos) do mundo.

Em 1962, os maiores fabricantes estavam empenhados no controle numérico, estimulados pela demanda militar. No início dos anos setenta, outra onda de incentivo ao comando numérico surgiu. Desta vez, foi oriunda do desenvolvimento dos microprocessadores. Já no início da década de 1980, esse equipamento era comum no parque industrial mundial. Nessa época o “apenas” comando numérico, passou a ser chamado comando numérico computadorizado (CNC).

2.3 FUNCIONAMENTO DA MÁQUINA-FERRAMENTA COM CNC

Em um ambiente industrial as máquinas-ferramenta são bastante utilizadas, atuando das mais variadas formas. Seu principal objetivo é a busca pela excelência na qualidade do produto e a redução de custos, seja ele devido a gastos com operadores especializados ou no desperdício de insumos do processo de fabricação. É de fundamental importância conhecer a estrutura de funcionamento de uma máquina equipada com comando numérico computadorizado, tendo em vista que elas representam a essência do trabalho. A Figura 2.1 mostra o esquema genérico de uma máquina equipada com comando numérico computadorizado (CNC). A máquina referida dispõe de três eixos em quadratura. As informações relativas a usinagem, configurações, diagnose, e status podem ser introduzidas e/ou lidas da máquina através da interface homem-máquina (IHM), sendo ela dotada de um papel fundamental e sua tecnologia está intimamente ligada ao poder de operação do restante do sistema. Os dados dos atuadores, sensores, chaves e demais dispositivos utilizados nas funções secundárias chegam ao CNC via interface I/O. Até vinte anos atrás, uma máquina ferramenta era equipada com dois dispositivos de processamento: o CNC (para usinagem) e o controlador lógico programável (para demais funções, tais como: injeção de óleo refrigerante, leitura de sensores, etc.). Hoje o próprio CNC exerce ambas as tarefas.

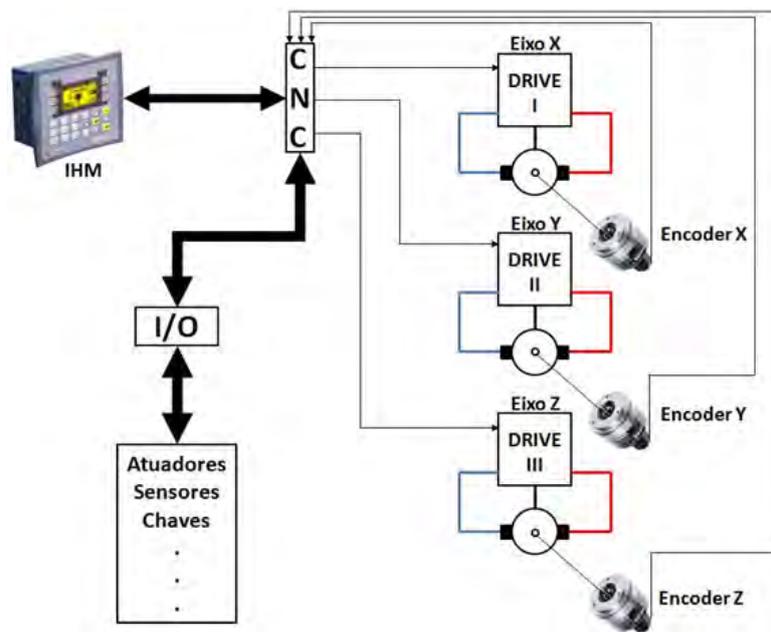


Figura 2.1 – Esquema de um CNC

Para controlar e ativar os motores utiliza-se os circuitos de acionamento. Neste ponto, também houve uma evolução grande, uma vez que os antigos acionamentos e motores de corrente contínua foram substituídos por inversores de frequência e motorização CA. A realimentação do movimento é obtida através de encoders, sensores de posição que enviam pulsos ao sistema de controle. A Figura 2.2 apresenta um torno CNC muito empregado em ambiente industrial.



Figura 2.2 – Torno CNC

2.4 HISTÓRICO E EVOLUÇÃO DOS MÉTODOS DE CONTROLE

O uso de algumas técnicas rudimentares de controle na Grécia e em Alexandria são descritas em documentos históricos. Nos séculos XVII e XVIII vários dispositivos de controle foram criados visando resolver alguns problemas práticos. Mas foi a revolução industrial no século XVIII, com o desenvolvimento de processos industriais, que deu o impulso ao desenvolvimento das técnicas de controle. Um dos problemas comuns na época era o controle da velocidade de teares. Watt desenvolveu um sistema de controle usando o chamado pêndulo de Watt como sensor de velocidade. Isto permitia o controle em malha fechada da velocidade controlado a injeção de vapor em máquinas a vapor. Eventualmente, tais sistemas apresentavam um comportamento instável, o que levou a uma pesquisa teórica da razão deste comportamento.

Em 1868, Maxwell publicou um artigo analisando o comportamento dinâmico dos sistemas de controle. A abordagem usada foi a modelagem do sistema por equações diferenciais sendo que Maxwell demonstrou que para determinadas faixas de valores dos parâmetros as soluções das equações eram instáveis. Na mesma época, Routh e Hurwitz desenvolveram técnicas que permitiam determinar diretamente a estabilidade do sistema sem a necessidade da solução das equações. Um marco no desenvolvimento da teoria de controle foi a publicação de um trabalho pelo matemático russo A. Lyapunov em 1897. Este trabalho foi traduzido para o francês em 1907 e em inglês em 1947. Pouco divulgado no ocidente, o trabalho de Lyapunov continuou a ser desenvolvido na então União Soviética, o que permitiu aos pesquisadores soviéticos grandes avanços especialmente na teoria de sistemas não-lineares e uma liderança na área que se manteve até os anos 1950.

Na década de 1920, engenheiros dos laboratórios Bell trabalhavam com o problema de comunicação a longa distancia nos Estados Unidos. O problema de reforço de sinais através de amplificadores levou ao desenvolvimento de técnicas no domínio da frequência. Nyquist e Bode, assim como vários outros associados a estas técnicas, eram engenheiros dos laboratórios Bell, eventualmente tais técnicas foram usadas para o projeto de sistemas de controle.

Em 1939, nos Estados Unidos, o Instituto Tecnológico de Massachusetts (MIT) foi um centro de desenvolvimento de técnicas em sistemas de controle. Outros desenvolvimentos se seguiram, inclusive com o aparecimento da técnica do lugar das raízes, criada por Evans em 1947. A teoria de controle ao final dos anos 1950 já

consistia de um corpo de conhecimento consolidado, com forte ênfase em técnicas baseadas no uso de métodos de controle de frequências e com muitas aplicações industriais. No entanto a demanda por novas técnicas, especialmente no florescente setor aeroespacial impulsionou o desenvolvimento do chamado controle moderno. O controle moderno retomou muitas das ideias de Lyapunov, usando técnicas no domínio do tempo. O caso de sistemas multivariáveis (com várias entradas e varias saídas) pode ser facilmente tratado com técnicas modernas. O nome de R. Kalman aparece com destaque entre os criadores do controle moderno. Atualmente a teoria de controle é bastante extensa, mas a relação entre vários aspectos foi melhor estabelecida. Assim, técnicas da frequência para sistemas multivariáveis foram desenvolvidas e a relação entre o domínio do tempo e da frequência melhor compreendidas. Mas os termos controle clássico e controle moderno ainda são usados.

2.5 SISTEMAS DE CONTROLE EM MALHA ABERTA E MALHA FECHADA

Podemos dizer que existe uma grande divisão entre os sistemas de controle, são os chamados sistemas de controle em malha fechada e sistemas de controle em malha aberta.

Em um sistema de controle em malha aberta pode-se utilizar controladores e circuitos de acionamento em série com o processo a ser controlado, de modo que a entrada do processo a ser tal que sua saída se comporte como desejada. A característica fundamental desse tipo de estrutura de controle é que a ação de controle independe da saída. De modo funcional o controle em malha aberta consiste em aplicar um sinal de controle pré-determinado, esperando-se que ao final de um determinado tempo a variável controlada atinja um determinado valor ou apresente um determinado comportamento. Neste tipo de sistema de controle não são utilizadas informações sobre evolução do processo para determinar o sinal de controle a ser aplicado em um determinado instante. Mais especificamente, o sinal de controle não é calculado a partir de uma medição do sinal de saída. Para o controle de sistema mecânicos em malha aberta se faz necessário o conhecimento prévio das características do atuador e sua interação com a planta. No acionamento de mesa de coordenadas, por exemplo, pode-se fazer o uso de motores de passo, para este tipo de aplicação é conhecida a posição da

mesa através da quantidade de pulsos enviados aos circuitos de acionamento. A Figura 2.3 é mostrado o diagrama básico de um sistema de malha aberta.

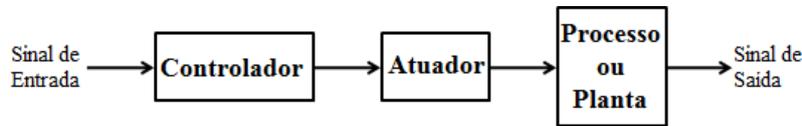


Figura 2.3 – Sistema de Controle em Malha Alberta (SCMA)

No controle em malha fechada, informações sobre como a saída de controle está evoluindo são utilizadas para determinar o sinal de controle que deve ser aplicado ao processo em um instante específico. Isto é feito a partir de uma **realimentação** da saída para a entrada. Em geral, a fim de tornar o sistema mais preciso e de fazer com que ele reaja a perturbações externas, o sinal de saída é comparado com um sinal de referência e o desvio entre estes dois sinais é utilizado para determinar o sinal de controle que deve efetivamente ser aplicado ao processo. Assim, o sinal de controle é determinado de forma a corrigir este desvio entre a saída e o sinal de referência. O dispositivo que utiliza o sinal de erro para determinar ou calcular o sinal de controle a ser aplicado à planta é chamado de **controlador** ou **compensador**. Um sistema de controle em malha fechada (SCMF) pode ser chamado de servomecanismo. Esse era originalmente empregado para denotar uma classe de sistemas de controle para os quais a referência era constante. Atualmente o termo servomecanismo é usado em sentido amplo, significando Sistema de Controle em Malha Fechada (SCMF). No entanto, usa-se ainda a expressão problema de servomecanismo em conexão com o objetivo de seguir uma referência constante e problema de rastreamento, em conexão com o objetivo de seguir uma referência que varia com o tempo. Na Figura 2.4 é mostrado o diagrama básico de um sistema de controle malha fechada, destacando os principais componentes desse tipo de configuração.

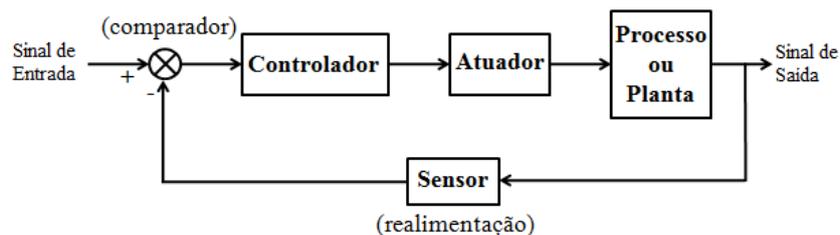


Figura 2.4 – Sistema de Controle em Malha Fechada (SCMF)

Pela figura mostrada pode-se definir os principais componentes que fazem parte de um sistema de controle em malha fechada, são eles:

- **Sinal de Entrada:** local onde é inserida a referência, ou seja, é o valor desejado que se espera que a variável controlada atinja;
- **Controlador:** dispositivo que manipula o sinal de erro e gera um sinal de controle para o atuador;
- **Atuador:** recebe o sinal do controlador e modifica a variável manipulada para obter a correção necessária da variável controlada;
- **Planta ou Processo:** dispositivo ou fenômeno que se deseja operar com alguma finalidade;
- **Sinal de Saída:** local onde pode-se fazer a leitura da evolução da variável controlada;
- **Sensor:** dispositivo responsável pela medição e conversão da variável controlada para fins de comparação e obtenção do erro de saída.
- **Comparador:** dispositivo que gera um sinal de erro para o controlador fazendo a diferença entre o valor desejado e o valor obtido na saída do processo.

No capítulo 3 faz-se o uso desses conceitos fundamentais para explicar o funcionamento da planta em estudo.

2.6 CONTROLE CLÁSSICO E MODERNO

Para o controle de servomecanismo pode-se encontrar diversas técnicas de projeto de controladores, entre elas destacam-se as técnicas clássicas tais como Ziegler-Nichols, projeto avanço ou atraso de fase. Assim como, pode-se destacar (SHANIAN e HASSUL, 1993; CHEN, 1995; PHILLIPS, 1997; DORF, 2001; OGATA, 2003) que foram as primeiras técnicas em projetos de controle de sistemas. Recentemente, BRAGA (2006), apresentou projetos de controladores para uma mesa de coordenadas XY usando técnicas de alocação de pólos.

Com o grande desenvolvimento dos dispositivos eletrônicos e computadores passou a existir a possibilidade de projetar controladores com técnicas modernas

baseadas em espaço de estados, dando origem a projetos de controladores mais robustos em relação aos projetados com técnicas clássicas (HEMERLY, 1996; ASTROM, 1995, CHEN, 1995; OGATA, 2003; DORF, 2001). Dentro dessa moderna filosofia de controle, os projetos de controladores que mais se destacam são aqueles concebidos com técnicas LQR, LQG e H^∞ . No enfoque clássico, o objetivo do projeto de um controlador é impor os pólos dominantes de malha fechada de modo que o sistema possua uma determinada frequência de ressonância e um determinado amortecimento. No caso do controle no espaço de estados, projeta-se o controlador a partir da especificação de todos os pólos do sistema de malha fechada, e não apenas os pólos dominantes (MENEZES, 2007).

Recentemente as técnicas de controle adaptativo, redes neurais, lógica fuzzy, algoritmos genéticos, bem como controladores que utilizam fusões dessas técnicas, denominados controladores híbridos, têm sido bastante exploradas no sentido de melhorar a capacidade de desempenho e de estabilidade de sistemas, obtendo-se desta forma controladores com características mais robustas.

2.7 CONTROLE ADAPTATIVO

Segundo ASTROM e WITTENMARK (1995), um controlador adaptativo é um controlador com parâmetros ajustáveis e um mecanismo de ajuste destes parâmetros. A razão principal para introdução do controle adaptativo é a obtenção de um controlador que possa se adaptar às mudanças na dinâmica do processo. Foi observado que controladores lineares de ganho constante trabalham bem em um ponto de operação do sistema, não possuindo a mesma característica em outros pontos de operação.

De acordo com ISERMANN (1992) o termo controlador adaptativo foi usado pela primeira vez na década de 1940. Durante este período e nas décadas seguintes foram projetados controladores adaptativos para aviões. Nas décadas de 1960 e 1970 surgiu as teorias de projeto utilizando estado de espaço, que representou uma significativa contribuição à teoria de controle adaptativo, o qual sofreu um enorme impacto com o desenvolvimento das técnicas de controle digital.

Os mais conhecidos sistemas de controle adaptativo são: Controle de ganho escalonado, MRAC (Controle por Modelo de Referência) e STR (Reguladores Auto-Sintonizáveis).

COSTA & OLIVEIRA (2002) desenvolveram um controlador de ganho escalonado para o controle de uma planta não linear. Nesse trabalho, o sistema é conduzido de um ponto de operação a outro através de uma trajetória segmentada em setores não lineares. Como solução foi proposto um algoritmo para chavear controladores robustos durante a ativação do controlador. A Figura 2.5 apresenta um diagrama de blocos genérico de um sistema de controle de ganho escalonado.

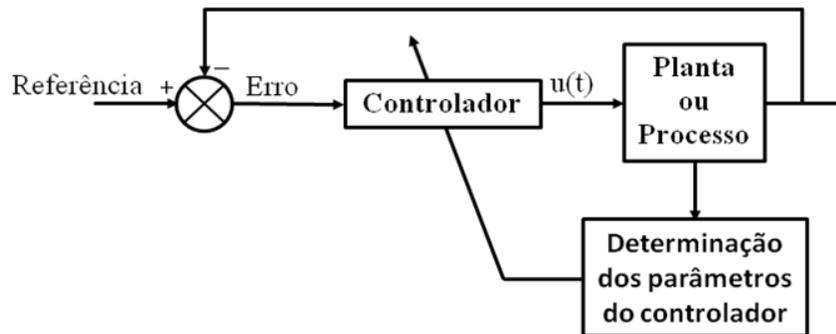


Figura 2.5- Diagrama de blocos do sistema de controle de ganho escalonado

MARIANO (2005) apresentou o controle de um eixo posicionador utilizando um STR (Self Tunning Regulator) com a estimação dos parâmetros do sistema sendo fornecido pelo algoritmo MQR (Mínimos Quadrados Recursivos).

MONTENEGRO (2007) propôs em seu trabalho o controle de temperatura de ar em um túnel psicrométrico, aplicando diferentes técnicas de controle adaptativo, com destaque para o MVC (Controle de Mínima Variância), o GPC (Controlador Preditivo Generalizado) e Ganho Escalonado.

PATETE et al.(2008) mostraram o uso de um controlador adaptativo auto-ajustável de variância mínima generalizada (GMV) em um sistema SISO sujeito a um distúrbio caracterizado como um ruído branco. Neste trabalho o problema de controle de sistemas de fase mínima ou não mínima com modelos auto-regressivos de parâmetros constantes e desconhecidos foi considerado.

JAMES (2009), em recente pesquisa, apresentou um controle adaptativo aplicado em um robô manipulador de dois graus de liberdade planar.

SOUZA (2010) desenvolveu um controle adaptativo aplicado em dois elos de um robô manipulador eletropneumático de três graus de liberdade cartesiano.

2.8 CONTROLE FUZZY

A lógica fuzzy, também conhecida como lógica nebulosa, foi desenvolvida por Lofti A. Zadeh, originalmente um engenheiro e cientista de sistemas, durante a década de 1960. O artigo publicado pelo autor em 1965 pela Universidade da Califórnia, em Berkeley, revolucionou o assunto com a criação de sistemas Nebulosos (CAMARGOS, 2002).

Em 1974 o Prof. Mamdani, do Queen Mary College, Universidade de Londres, após inúmeras tentativas frustradas em controlar uma máquina a vapor com tipos distintos de controladores (...) somente conseguiu fazê-lo através da aplicação do raciocínio nebuloso”. Ainda na primeira metade da década de 1980, a lógica nebulosa atinge outras aplicações, como o controlador nebuloso de operação de fornos de cimento, plantas nucleares, refinarias, processos biológicos e químicos, trocador de calor, máquina diesel e tratamento de água (CAMARGOS, 2002).

O período em que desperta maior atenção está localizado entre os anos de 1986 e 1987, quando da inauguração do sistema de Metrô Sendai, em Tóquio, cujo controle automático de partida e chegada dos trens era baseado na lógica fuzzy. COX (1999), afirma que o sistema de operação automática de trens desenvolvidos pela Hitachi funcionava melhor do que qualquer operador humano: “o metrô, de fato, está com um histórico de pontualidade melhor, usa menos energia e é mais suave do que quando era operado por um homem”. Imediatamente após a bem sucedida inauguração do metrô automatizado, centenas de produtos com controladores baseados na lógica fuzzy começaram a ser disponibilizados no Japão, várias empresas especializadas em ferramentas de lógica fuzzy apareceram e outras grandes empresas de fabricação de chips e companhias de controle também entraram no mercado (CAMARGOS, 2002).

Originalmente, com o trabalho de ZADEH (1965), a lógica fuzzy encontrou aplicabilidade imediata no campo de controladores de processos industriais. Controladores baseados na lógica fuzzy são chamados de controladores fuzzy.

Controladores nebulosos tratam igualmente sistemas lineares e não lineares, além de não requererem o modelamento matemático do processo a ser controlado, que é, sem dúvida, o grande atrativo dos Sistemas Nebulosos. Sistemas baseados na lógica fuzzy têm mostrado grande utilidade em uma variedade de operações de controle industrial e em tarefas de reconhecimento de padrões que se estendem desde reconhecimento de texto manuscrito, até a avaliação de crédito financeiro. Existe

também um interesse crescente em se utilizar a Lógica Nebulosa em sistemas especialistas para torná-los mais flexíveis (CAMARGOS, 2002).

O controle executado pela lógica Fuzzy imita um comportamento baseado em regras ao invés de um controle explicitamente restrito a modelos matemáticos como equações diferenciais. O objetivo da lógica Fuzzy é gerar uma saída lógica a partir de um conjunto de entradas não precisas, com ruídos ou até mesmo faltantes. Esse tipo de controle tem por essência gerar valores de saídas sem a necessidade de entradas precisas e apresenta as seguintes características em relação a outras técnicas de controle:

- Robusta porque não requer entradas precisas;
- Controle de sistemas não-lineares sem modelo matemático;
- Solução mais rápida e barata em alguns casos;
- Fácil implementação em microprocessadores.

Atualmente, há uma forte tendência na interação entre lógica fuzzy e redes neurais, dando origem às estruturas neuro-fuzzy, adequadas para geração automática de bases de regras e de funções de pertinência (TANSCHKEIT, 1998).

Diversas aplicações dos sistemas fuzzy e neuro-fuzzy são encontradas na literatura (YAGER & FILEV, 1994; JANG e ROGER, 1992; WONG et al., 1999). A seguir, são apresentadas algumas pesquisas que utilizaram esses sistemas de controle, principalmente, fuzzy.

BORDON (2004) apresentou um controlador do tipo fuzzy de arquitetura simplificada para o acionamento de um motor de indução trifásico, com frequência de operação controlada e limitação de corrente.

LIMA (2007) apresentou um estudo teórico e experimental de um sistema de controle fuzzy. Este sistema de controle mantinha o potencial matricial da água no solo na faixa do tensiômetro de campo em níveis compatíveis com os requisitos de irrigação por meio de dotações hídricas variáveis de acordo com a velocidade de um conjunto motor-bomba.

BEZERRA (2009) apresentou um sistema fuzzy para o controle piezométrico de sistemas de distribuição de água, por meio do uso simultâneo de válvulas de controle e conversores de frequência acoplados a conjuntos motor-bomba, visando à economia de água e energia elétrica

Recentemente, JULIO (2010) desenvolveu um controlador fuzzy aplicado a um sistema de controle de posição acionado por motores de indução trifásicos.

2.9 REDES NEURAIS ARTIFICIAIS

Uma rede neural artificial (RNA) é um processador paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso (HAYKIN, 1999). Pode-se entender como conhecimento experimental a aplicação de ZUBEN (1993) que usou uma rede neural para controle de uma máquina de indução. Seu objetivo foi desenvolver técnicas não-lineares de identificação de sistemas dinâmicos e estimação de parâmetros utilizando redes neurais artificiais e posterior aplicação ao problema de controle de máquina de indução para operação em velocidade variável.

A estrutura das redes neurais foi desenvolvida a partir de modelos conhecidos de sistemas nervosos biológicos e do próprio cérebro humano. As unidades de processamento simples, denominadas neurônios artificiais, correspondem aos nós de rede e são modelos simplificados dos neurônios biológicos. Tais modelos foram obtidos a partir da análise da geração e propagação de impulsos elétricos pela membrana celular dos neurônios (HODGKIN e HUXLEY, 1952).

Os neurônios utilizados nos modelos de redes neurais artificiais realizam funções simples, como coletar os sinais existentes em suas entradas, agregá-los de acordo com sua função de entrada e produzir uma saída por intermédio de sua função de saída (função de ativação) inerente. O modelo de neurônio mais simples e que engloba as principais características de uma rede neural biológica, paralelismo e alta conectividade, foi proposto por MCCULLOCH e PITTS em 1943 (Figura 2.6). Este modelo realiza a soma algébrica ponderada das entradas de um neurônios que, em seguida, serve como entrada para função de ativação, determinada a saída da rede (HAYKIN, 1999).

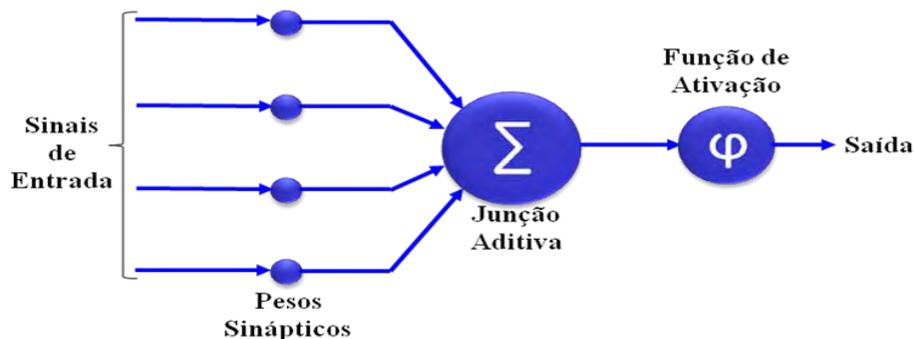


Figura 2.6 – Modelo do Neurônio de McCulloch e Pitts

Uma RNA é classificada pelo algoritmo de aprendizagem utilizado, pelo tipo ou função do neurônio presente e por sua arquitetura. O algoritmo de aprendizagem específica e a metodologia de ajuste dos parâmetros internos da rede neural para se obter o desempenho desejado. A função de ativação determina o comportamento individual interno a cada neurônio. Se todos os neurônios têm o mesmo comportamento, ou seja, tem a mesma função de ativação, a rede é dita homogênea, caso contrário a rede é chamada heterogênea. Com relação a arquitetura, existem algumas que merecem destaque, tais como as redes neurais em camadas, as redes recorrentes e as redes de estrutura reticulada, cada qual mais adaptada a determinadas categorias de problemas (PIRES, 2009).

As redes neurais em camadas, como próprio nome já diz, são estruturadas em camadas, cada uma contendo certo número de neurônios, sendo que os neurônios de uma camada têm suas entradas conectadas às saídas da camada anterior e suas saídas conectadas às entradas dos neurônios da camada posterior. A rede neural é dita totalmente conectada quando todos os neurônios da camada são conectados a todos os outros neurônios da camada adjacente posterior. Se, contudo, alguma conexão não existe, a rede é dita parcialmente conectada (HAYKIN, 1999). O algoritmo de treinamento propaga a informação da camada da entrada para camada de saída, e depois realiza o caminho inverso para atualização dos pesos sinápticos. Dentre as redes deste tipo destacam-se as redes *Perceptron* e Função de Base Radial. Tais redes são geralmente aplicadas à aproximação de funções, reconhecimento de padrões, identificação e controle.

Uma aplicação de redes neurais de múltiplas camadas fazendo o uso do algoritmo de retropropagação para atualização dos pesos sinápticos foi desenvolvido por MENEZES (2007) que apresentou o projeto de um controlador neural adaptativo para mesa de coordenadas, sua proposta foi acionar uma mesa de coordenadas X-Y que utilizasse informações de referência de posição no formato de vetores. Nesse projeto, a estratégia proposta é diferenciada dos conhecidos controladores de trajetória por não possuírem controladores independentes para cada eixo. A mesa de coordenadas X-Y acionada por motores de corrente contínua, usada para validação, é uma estrutura de dois graus de liberdade considerada como um manipulador de eixos desacoplados.

Redes recorrentes são redes que possuem realimentação, ou seja, a saída da rede (ou mesmo de qualquer um de seus neurônios) é utilizada como entrada para a própria rede. Tais redes são utilizadas para modelar sistemas dinâmicos não-lineares,

sendo em geral adequadas para tarefas como modelamento de dados de entrada-saída, memória associativa e previsão de séries temporais (PIRES, 2009).

Ainda pode-se citar o trabalho de ZUBEN (1993) que utilizou uma rede neural recorrente como observador de fluxo do rotor de um motor de indução trifásico. As propriedades das redes neurais recorrentes citadas pelo autor que justificou a utilização desse tipo de rede neural em seu trabalho são as seguintes:

- capacidade de representação de comportamento dinâmicos discretos;
- capacidade de representação de sistemas multivariáveis;
- capacidade de representação de sistemas lineares e não-lineares;
- capacidade de adaptação a variações de comportamento dinâmico.

Por fim, as redes de estrutura *lattice* ou reticulada são constituídas por neurônios dispostos em vizinhanças geralmente unidimensionais ou bidimensionais, capazes de detectar características comuns nas entradas e agrupá-las segundo estas características. Estas redes realizam um modelamento entre um espaço n -dimensional (a dimensão do problema original). De forma simplificada, para cada entrada fornecida, o algoritmo de aprendizagem determina o neurônio mais próximo a ela, aproximando este neurônio e seus vizinhos da entrada em questão. Após certo número de iterações, os neurônios tendem a se agrupar-se em torno das entradas fornecidas, sendo possível distinguir conjuntos de dados com características semelhantes. As redes de Kohonen destacam-se dentro deste tipo de rede neural, e são freqüentemente empregadas em aplicações de agrupamentos (*clustering*) (PIRES, 2009).

RIUL (2000) desenvolveu uma pesquisa com controladores neurais e híbridos aplicados em uma carga acionada por um atuador hidráulico.

ARCOS CAMARGO (2002) apresentou um controle da trajetória de um robô manipulador tipo SCARA dentro de um volume de trabalho que é definido pelas equações cinemáticas. A determinação da trajetória dentro do volume de trabalho é obtida através do uso de redes neurais artificiais do tipo *perceptron* de múltiplas camadas que simulam os movimentos do manipulador entre dois pontos quaisquer dentro deste volume. As posições angulares dos segmentos são responsáveis pela geração dos movimentos do manipulador.

São inúmeras as aplicações de redes neurais em problemas de engenharia e ciências aplicadas. No setor automotivo e aeroespacial encontram-se aplicações de redes

neurais artificiais para auxiliar no mapeamento de processos que envolvem estimativas de variáveis de controle e parâmetros de projeto. Como alguns destes exemplos, em CHO *et al.* (2006) foram propostos esquemas de modelagem e estratégias de controle para veículos aéreos não-tripulados. Já em RICHTER (2009) foi projetada uma arquitetura neural visando sensoriamento virtual de oxigênio em veículos bicompostíveis. Em VICENTE *et al.* (2007) foi proposto um controlador neural de marcha lenta para motores de combustão interna. Outra aplicação interessante do ramo automotivo foi formulada em ORTEGA e SILVA (2008), em que as redes neurais artificiais são responsáveis pela otimização de projetos de brake-lights automotivos construídos por diodos emissores de luz (LEDs).

Além dessas aplicações, as potencialidades das redes neurais artificiais permitem a resolução de outros tipos de problemas advindos das mais diferentes áreas do conhecimento. É o caso da medicina, em que se utilizam redes neurais artificiais para classificações e predições de câncer com base no perfil genético do indivíduo (KHAN *et al.*, 2001). Outra aplicação, apresentada em YAN *et al.* (2006), propõe um sistema de apoio à decisão também baseado no uso de redes neurais artificiais para diagnosticar doenças do coração.

2.10 ALGORITMOS GENÉTICOS

Segundo CAMPOS & SAITO (2004) os algoritmos genéticos são métodos de busca inspirados nos mecanismos de seleção natural (Teoria da Evolução) e da genética. Eles combinam um mecanismo de valorização dos “melhores” indivíduos, ou dos mais adaptados ao objetivo em questão, com uma estrutura para combinar e “reproduzir” aleatoriamente estes indivíduos, criando uma nova população. Assim, a cada geração, um conjunto de novos indivíduos é criado utilizando-se informações contidas na geração passada.

Ainda segundo CAMPOS & SAITO (2004), embora o algoritmo genético use um método heurístico e probabilístico para obter os novos elementos, ele não pode ser considerado uma simples busca aleatória, uma vez que explora inteligentemente as informações disponíveis de forma a buscar novas “criaturas” ou soluções capazes de melhorar ainda mais um critério de desempenho.

MENDES (1999) aplicou a técnica dos algoritmos meméticos (uma classe da metaheurística do tipo populacional que engloba outras já conhecidas, como algoritmos

genéticos híbridos, busca por espalhamento, entre outras) nos problemas de sequenciamento em máquinas.

VARGAS (2005) desenvolveu uma proposta de relé digital de frequência baseado em algoritmos genéticos.

COELHO & MARIANE (2006) desenvolveu um sistema híbrido neuro-evolutivo aplicado ao controle de um processo multivariável.

SOUZA (2008) apresentou a aplicação dos algoritmos genéticos na proteção e estimação de harmônicos em sistemas elétricos de potência.

2.11 CONTROLADORES HÍBRIDOS INTELIGENTES

Enquanto técnicas inteligentes têm produzidos resultados satisfatórios em tarefas particulares, certos problemas complexos não podem ser solucionados por uma única técnica inteligente. Cada técnica tem propriedades computacionais particulares (habilidade para aprender, explicação de decisões) que os tornam adequados para problemas particulares e não adequadas para outros. Por exemplo, enquanto as redes neurais são boas para explicar como elas alcançaram suas decisões. Sistemas baseados em lógica difusa ou fuzzy, que podem raciocinar com informação imprecisa, também têm vantagens e limitações. Eles são bons para explicar suas decisões, mas eles não podem adquirir automaticamente as regras que eles utilizam para tomar decisões. Estas limitações têm sido a principal causa para a criação dos sistemas híbridos inteligentes, onde duas ou mais técnicas são combinadas de maneira que superam as limitações das técnicas individuais.

Os sistemas híbridos inteligentes são relevantes quando domínios complexos e que apresentam problemas com componentes diferentes são considerados, os quais requerem diversos tipos de processamento (ou finalidades). A concepção de que as metodologias da inteligência computacional são complementares, mais que competitivas, gerou uma ampla diversidade de configurações de sistemas híbridos inteligentes. Vale citar, por exemplo, os sistemas neuro-nebulosos, nebuloso-evolutivos, neuro-evolutivos e neuro-nebuloso-evolutivos, com diversas aplicações em identificação e controle de processos, e outras áreas afins (KHOSLA & DILLON, 1997; SENG et al., 1999; BONISSONE et al., 1999; COELHO, 2001).

Esses sistemas são divididos em três classes que levam em conta fatores tais como funcionalidade, arquitetura de processamento e requerimento de comunicação. A seguir discutiremos as três principais classes de sistemas híbridos inteligentes.

2.11.1 Híbridos de Função-Reposição (Substituição)

Os híbridos de função-reposição trabalham com a composição funcional de uma técnica inteligente simples. Nesta classe híbrida, a função principal de uma dada técnica é substituída por outra técnica inteligente de processamento. A motivação para estes sistemas híbridos é a técnica da melhoria. A motivação para substituir estas funções principais poderia ser para aumentar a velocidade ou aumentar a confiança. Exemplos de funções principais incluem a unificação de padrões em um sistema especialista, mudança de pesos em uma rede neural e operações de crossover em um algoritmo genético.

MONTANA e DAVIS (1989) fornecem um exemplo de um híbrido de função-substituição. Eles substituem o mecanismo de mudança de peso backpropagation de uma rede neural com operadores de algoritmos genéticos. O algoritmo genético capta os pesos existentes de uma rede neural e então aplica operadores de mutação e crossover nos valores destes pesos para obter novos valores. Os pesos da rede são codificados em uma estrutura de lista (Figura 2.7). Os operadores de crossover e mutação são aplicados nestas listas que representam os pesos. A performance deste método genético de atualização de peso foi comparado com backpropagation (RUMELHART, 1986) em uma tarefa de reconhecimento de padrões sonar. O método híbrido supera backpropagation pois gasta muito menos interações para convergir para uma solução (MONTANA, 1989).

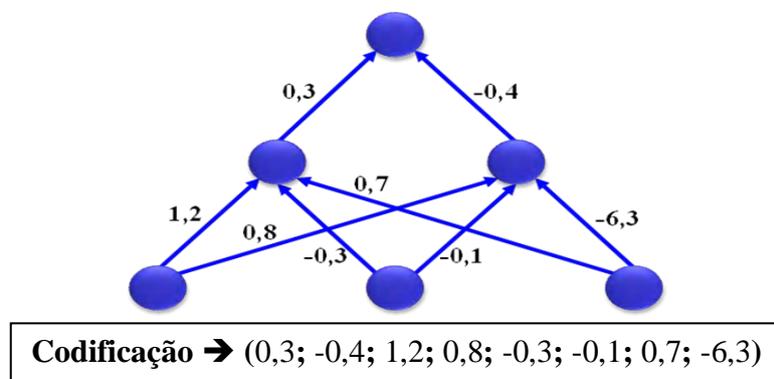


Figura 2.7 - Codificação do cromossomo de uma rede neural

Um outro bom exemplo de um híbrido de função-substituição é o trabalho de KARR (1991) que usa algoritmo genético para substituir a tarefa de definir manualmente as funções de pertinência difusa. A definição de uma função de pertinência é geralmente feita por um especialista no domínio, o qual utiliza seu julgamento subjetivo para especificar os formatos e valores das funções de pertinência. Tipicamente isto consome tempo e é suscetível a erro durante o desenvolvimento de sistemas difusos. KARR utiliza algoritmo genético para projetar funções de pertinência difusas em um sistema difuso para controlar o balanceamento de um carro. Há quatro variáveis de condição, cada uma tendo três variáveis linguísticas. O autor utiliza formatos triangulares na definição da função de pertinência difusa e o auxílio do algoritmo genético é para encontrar o ponto médio ótimo nestes triângulos, a Figura 2.8 mostra definições das funções de pertinência usadas na aplicação. Cadeias (strings) de bits são usadas para representar as possíveis posições dos pontos médios. Após ter utilizado apenas uma pequena porção do espaço de busca (aproximadamente 32.000 dos 232 pontos possíveis), o algoritmo genético foi capaz de aprender funções de pertinência que eram muito melhores no controle de balanceamento do que as funções de pertinência definida por KARR (1991).

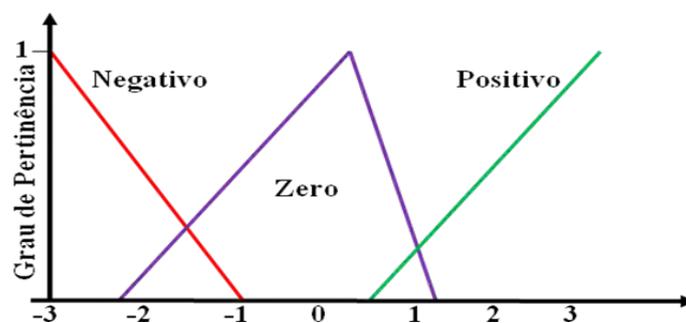


Figura 2.8 - Definições das funções de pertinência

2.11.2 Híbridos de Intercomunicações

Híbridos de intercomunicação são módulos inteligentes e independentes que trocam informações e realizam funções separadas para gerar soluções. Se um problema pode ser subdividido em tarefas de processamento distintas, então módulos independentes, inteligentes e diferentes podem ser utilizados para solucionar as partes

do problema nas quais eles são melhores. Estes módulos independentes que coletivamente solucionam uma dada tarefa são coordenados por um mecanismo de controle. Por exemplo, se uma tarefa particular tem sub-tarefas de reconhecimento de padrões, raciocínio serial e otimização, então uma rede neural, um sistema especialista e um algoritmo genético podem ser criados para realizar estas respectivas tarefas. Estes módulos independentes podem processar sub-tarefas tanto de uma maneira sequencial (onde o controle pode ser fornecido nas regras do sistema especialista) quanto em um modelo competitivo/cooperativo tal como “quadro negro” (onde o controle esta em um componente distinto de controle).

Um exemplo de um híbrido de intercomunicação é o sistema de SCHREINEMAKER e TOURETZKY (1990) para diagnóstico veterinário. Neste caso, um sistema especialista baseado em regras realiza inferências seriais, e chama redes neurais para encontrar padrões em dados como parte do diagnóstico. O sistema usa um conjunto particular de estruturas de dados OPS 5 chamada “Elemento de memória de trabalho” para comunicação entre a rede neural e sistemas especialistas. Se a rede neural faz um diagnóstico errado em um caso em particular, então o sistema especialista age como gerenciador do conhecimento permitindo ao especialista no domínio a inspecionar a má classificação e alterar os dados de treinamento associados se tais dados são considerados incorretos. Os autores sustentam que o sistema alcança uma classificação de 87%, a qual é comparável à performance de especialistas em veterinária.

Um outro exemplo deste tipo de híbrido de intercomunicação é citado em DUNKER (1992) que descreve um ambiente cooperativo para integração de redes neurais e sistemas baseados em conhecimento. O principal objetivo deste sistema é decompor tarefas de raciocínio bastante amplo em subproblemas gerenciáveis e processá-los através da arquitetura de quadro-negro. Os agentes do sistema de quadro-negro são muitos “resolvedores de problemas neurais”, cada um relativo a uma modelagem em particular do problema geral. Um “resolvedor de problemas neurais” consiste em uma rede neural e um mecanismo de controle baseado em sistemas especialistas. Cada um desses resolvedores de problemas neurais enviam e recebem mensagens para e de um quadro negro central. Se todas as condições para um resolvedor de problemas neurais são encontradas (checadas pelo mecanismo de controle baseado em sistemas especialistas), então, aquele agente particular baseado em rede neural será usado para processar dados. Uma vez que o processamento foi completado, ele irá passar as informações para o quadro negro indicando que a sub – tarefa esta

encerrada e irá exibir os resultados relevantes do processo. Um outro resolvidor de problemas neurais pode agora usar estes resultados para futuros processamentos. DUNKER planejou usar este sistema em bancos de dados para análise de oportunidades de investimento.

2.11.3 Híbridos Polimórficos

Híbridos polimórficos são sistemas que usam uma arquitetura simples de processamento para alcançar a funcionalidade de técnicas de processamento inteligente diferentes. A motivação para estes sistemas híbridos é a multifuncionalidade dentro de arquiteturas computacionais particulares. Estes sistemas podem imitar a funcionalidade ou emular diferentes técnicas de processamento. Isto pode ser visto como um sistema “camaleão” que pode alterar sua forma funcional. Exemplos de híbridos polimórficos são redes neurais que tentam realizar tarefas simbólicas tais como inferência passo a passo e também redes neurais cujas funções fazem busca genética.

Um comentário geral feito sobre o esquema de classificação é o número limitado de exemplos em uma categoria polimórfica. A maioria dos híbridos polimórficos são exemplos de redes neurais utilizadas para raciocínio simbólico embora eles sejam exemplos utilizando redes neurais para imitar procedimentos de busca genéticos (ACKLEY, 1985). É certo que muito mais exemplos de tais híbridos polimórficos serão desenvolvidos à medida que mais pesquisadores que estudam diferentes técnicas inteligentes comecem a compreender os paralelos entre as diferentes abordagens.

Estudos recentes têm sido apresentados visando o projeto de controladores multivariáveis (GARCES et al., 1998; ADUSUMILLI et al., 1998; ONO et al., 2000; KATEBI et al., 2000; VÁSQUEZ & MORILLA, 2002). As abordagens de controle PID usando metodologias inteligentes também têm sido alvo de estudos na tentativa da obtenção de eficiência, robustez e flexibilidade em projetos de controle avançado (SHANLEY, 1995; VANDOREN, 1998). Um exemplo dessa aplicação podemos encontrar no trabalho de COELHO e MARIANI (2006), que desenvolveu um sistema híbrido neuro-evolutivo aplicado ao controle de um processo multivariável, onde seu objetivo é apresentar uma nova abordagem para o projeto de um controlador PID (proporcional, integral e derivativo) multivariável baseado em uma rede neural e um

algoritmo genético. Outra Aplicação de controle utilizando sistemas híbridos inteligentes é apresentado por AOYAMA et al.(1999) que apresentou técnicas neuro-fuzzy para o controle de processos químicos industriais. Por fim, podemos citar o trabalho de FERNANDES et al. (2008) que consiste na aplicação de um sistema neuro-genético como alternativa aos métodos tradicionais para a identificação de fontes de harmônicas caracterizadas por cargas não-lineares comumente encontradas em sistemas elétricos residenciais e/ou comerciais. A identificação destas fontes de harmônicas se faz necessária para que altos níveis de emissão das correntes harmônicas possam ser mitigados.

2.12 COMENTÁRIOS E CONCLUSÕES

A revisão bibliográfica deste capítulo apresentou um histórico sobre máquinas-ferramentas e seu princípio de funcionamento utilizando Controle Numérico Computadorizado (CNC). Em seguida, foi mostrado um histórico e a evolução dos métodos de controle. Nessa etapa também foi apresentada algumas características dos sistemas de controle em malha aberta e fechada, bem como dos controles clássicos, modernos, adaptativos e inteligentes, como aqueles baseados em lógica fuzzy, redes neurais, algoritmos genéticos e híbridos inteligentes.

No que diz respeito ao controle de posição de máquinas ferramentas acionadas por motores de indução trifásicos que tem seu controle baseado em redes neurais artificiais, verificou-se, no decorrer da revisão bibliográfica, que ainda é reduzida a aplicação de tal método em relação aos controles de posição utilizando controladores clássicos e modernos. Sendo assim, a implementação de controladores baseados em redes neurais artificiais proporciona a realização de diversas pesquisas sobre sua aplicação.

CAPÍTULO III

DESCRIÇÃO DO FUNCIONAMENTO DA MESA DE COORDENADAS — MONTAGEM E INSTRUMENTAÇÃO

3.1 INTRODUÇÃO

Neste capítulo apresenta-se a descrição do funcionamento da mesa de coordenadas X-Y. Na seção 3.2 é apresentado o princípio de funcionamento do sistema mecânico, abordando as suas principais partes e descrevendo as características do seu movimento. Na subseção 3.2.1 é apresentado o software e a placa de aquisição de dados utilizados no projeto. Na subseção 3.2.2 é abordado tratamento do sinal de acionamento da planta, que tem início no programa computacional, passando pela placa de aquisição de dados, elementos de amplificação de potência e terminando nos elementos de atuação do sistema, que são os motores de indução trifásicos. Na subseção 3.2.3 contém a visão geral do circuito detector de posição do sistema, projetado em laboratório. Na subseção 3.2.4 é mostrado como foi realizado a instalação elétrica e a proteção da mesa, evitando possíveis danos ao sistema. Na seção 3.7 finaliza o capítulo com comentários e conclusões.

3.2 MESA DE COORDENADAS

O sistema de posicionamento que se deseja controlar possui aplicações nas mais diversas áreas, estejam elas inserida no setor primário, secundário ou terciário. Nesse trabalho foi utilizada uma mesa de coordenadas com dois eixos perpendiculares entre si e que se movimentam linearmente no plano horizontal. A base superior da mesa

(base X) possui um curso máximo de 200 mm e a base inferior (base Y) um curso de 100 mm.

Num sistema posicionador, para que se possa acioná-lo automaticamente, se faz necessária a interligação de componentes mecânicos, elétricos, eletrônicos. No que diz respeito a componentes mecânicos do sistema temos, como elemento de transmissão de movimento, fusos trapezoidais que possuem um passo de 4 mm por revolução, porcas, que transforma o movimento de rotação do fuso em movimento linear da mesa, e mancais de rolamento fixados nas extremidades da base superior e inferior da mesma. Além disso, para o acoplamento do motor ao eixo da mesa existe uma caixa de redução com relação de 10:1, ou seja, a cada dez voltas no eixo do motor temos uma volta no fuso, dessa forma, conseguiu-se diminuir a velocidade de rotação do sistema e aumentar o torque. A Figura 3.1 mostra o mecanismo de forma expandida possibilitando a observação da constituição física do equipamento.

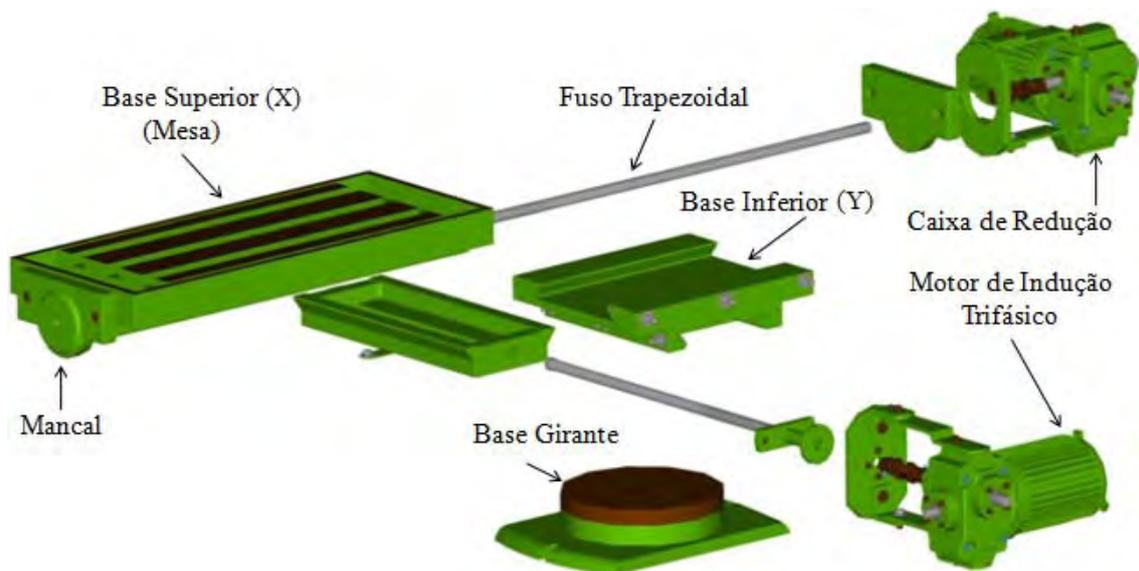


Figura 3.1 – Sistema de Posicionamento Expandido

3.2.1 Sistema de Aquisição de Dados

O projeto dos controladores, interface e aquisição dos dados é feita no ambiente de programação computacional LabVIEW®, instalado em um computador do tipo Core 2 Duo 2.4 GHz equipado com uma placa de aquisição de dados NI-DAQ USB

6009, fabricada pela National Instruments®. A NI-DAQ USB 6009 possui, 10 canais analógicos, sendo 8 de entrada e 2 de saída, 12 canais de entrada/saída digital e um contador de 32-bits. A Figura 3.2 mostra os equipamentos utilizados para o controle, interface e aquisição de dados.



Figura 3.2 – Equipamentos da Interface e aquisição de dados

3.2.2 Sistema de Acionamento

Pode-se dividir o sistema de acionamento da mesa de coordenadas X-Y em cinco blocos básicos. A Figura 3.3 mostra o diagrama de blocos, em malha aberta, do sistema de acionamento desenvolvido em laboratório.

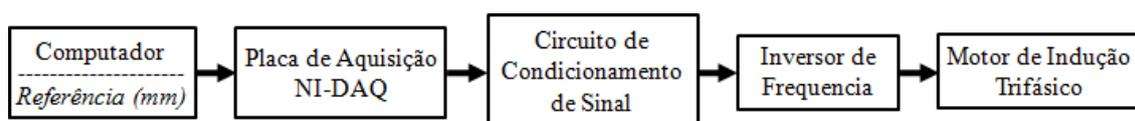


Figura 3.3 – Diagrama de blocos do sistema de acionamento em malha aberta

Sendo os controladores implementados no programa LabVIEW®, pode-se inserir o sinal de referência de posição para a mesa de coordenadas através da interface de comunicação com usuário. Depois do processamento da informação, a referência é convertida em um sinal de tensão e enviada pela comunicação USB aos pinos de saída da placa de aquisição de dados NI-DAQ. Para que o inversor de frequência possa fazer o acionamento de forma correta, ou seja, o controle da velocidade de rotação e sentido de giro, se faz necessário duas informações nas portas de saída da placa de

comunicação; uma digital, referente ao sentido de giro e um sinal analógico referente à velocidade de rotação. A comunicação do circuito de condicionamento de sinal e o inversor de frequência é realizada em duas etapas, uma para o sinal analógico e uma para o sinal digital. A comunicação analógica é feita de forma direta e a velocidade de rotação é variada de acordo com o nível de tensão na saída da placa, sendo sua variação de 0 a 5V que corresponde a uma variação de 0 a 60Hz na frequência da tensão de saída do inversor frequência. Na comunicação digital existe uma incompatibilidade entre o sinal de saída da placa (0 ou 5V) e o sinal de entrada do inversor de frequência (0 ou 10V). Para a solução do problema foi desenvolvido, em laboratório, um circuito simples de condicionamento de sinal, onde tem-se um transistor funcionando como chave. Dessa forma conseguiu-se controlar o sentido de giro do motor. A Figura 3.4 mostra o circuito de condicionamento de sinal do sinal digital.

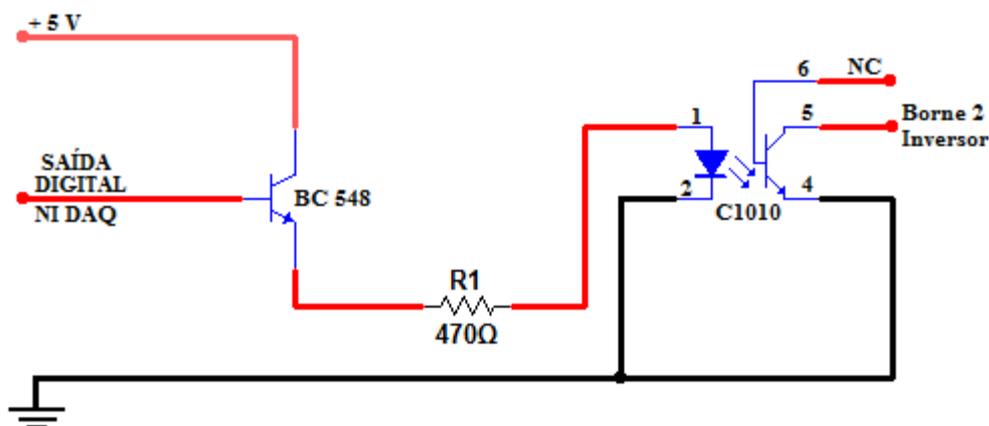


Figura 3.4 – Circuito de condicionamento de sinal digital

Os inversores de frequência são os equipamentos mais adequados para controlar a velocidade de rotação e o torque dos motores de indução (BORDON, 2004). Através dos inversores são fornecidas tensão e frequência variáveis a esses motores, controlando a relação entre tensão e frequência por meio da modulação por largura de pulso (PWM).

Os inversores foram utilizados para realizar a partida relativamente suave dos motores e, além disso, evitar solavancos que desgastam os componentes mecânicos do sistema, principalmente nos conjuntos redutores, programou-se um tempo de aceleração/desaceleração de 0,1 s em rampa. Isso permitiu um melhor controle, evitando

um posicionamento inadequado da base X ou Y, e a minimização de sobre-sinais. Quanto à frequência, parametrizou-se em 0 Hz a frequência mínima e 60 Hz a frequência máxima, a fim de obter um controle de posição rápido para esse tipo de configuração de sistema.

Com relação ao funcionamento do motor de indução trifásico, a aplicação da tensão alternada nos enrolamentos do estator, gera em um campo magnético rotativo em torno do eixo central do motor. A variação de fluxo desse campo magnético induz uma tensão nos enrolamentos do rotor, gerando correntes rotóricas. Essas correntes, sob a ação do campo magnético oriundo do estator, originam a força magnética geradora do torque no rotor, resultando no giro desse último.

A velocidade de rotação síncrona do campo magnético n_s , em (rpm), é dada pela Equação 3.1, onde: f é a frequência aplicada ao estator em (Hz) e p é o número de pólos. A relação entre a velocidade de rotação do campo girante e a velocidade de rotação do rotor n_r , em (rpm) chama-se escorregamento s , dado pela Equação 3.2 (CAMBOIM, 2008).

$$n_s = \frac{120 \cdot f}{p} \quad (3.1)$$

$$s = \frac{n_s - n_r}{n_s} \quad (3.2)$$

Como o número de pólos do motor é fixo, a velocidade de rotação desse tipo de máquina é variada na mesma proporção que se varia a sua frequência de alimentação. Isso é possível através da alimentação de tensão alternada de frequência ajustável pelo inversor de frequência a esses motores. A variabilidade da frequência de alimentação dos motores resulta na variação da velocidade de rotação do eixo do motor de indução e, conseqüentemente, na velocidade de movimentação das bases da mesa

3.2.3 Sistema de Medição

Para que fosse possível a detecção da posição do sistema de coordenadas foi usado, em cada eixo das bases superior e inferior, acopladores ópticos e discos, comumente chamado de encoder. Os discos responsáveis pela leitura de posição do

sistema foram confeccionados com material acrílico transparente e divididos em 32 partes iguais, sendo 16 opacas, 16 transparentes e cada disco com um par de sensores ópticos na borda. A figura 3.5 mostra um esquema básico da montagem dos encoders no eixo da base da mesa de coordenadas.

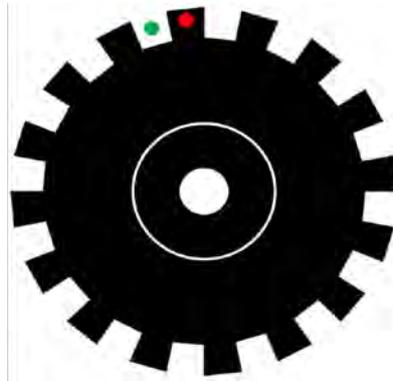


Figura 3.5 – Sensor de posição

Quando o disco gira, os acopladores óticos (sensores) geram sinais, teoricamente, quadrados, com nível alto em 5V e um sinal em nível baixo em 0V. Na prática os sinais de saída estão expostos a imperfeições devido aos transitórios. Dessa forma, se faz necessário o uso de um circuito de condicionamento de sinal, o Schmitt Trigger, com a finalidade de atenuar ruídos, assim como diminuir os tempos de subida e de descida e eliminar o multi-chaveamento que os ruídos ocasionam no limiar da comutação dos níveis do sinal (PRODANOV, 2001). Na Figura 3.6 é mostrado o circuito Schmitt Trigger utilizado na pesquisa.

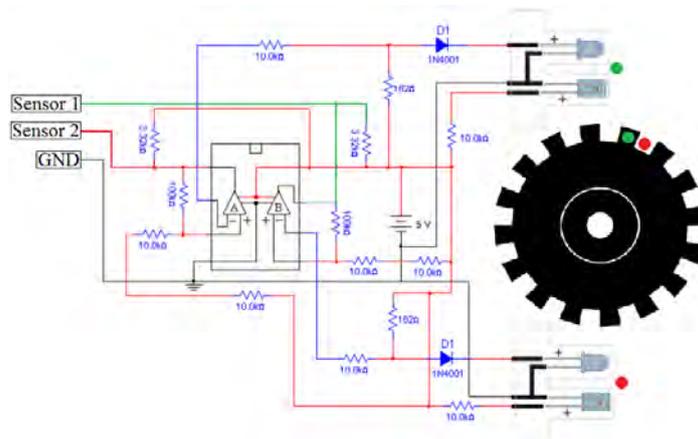


Figura 3.6 – Circuito Schmitt Trigger

Após o referido tratamento de sinal, a informação segue até os canais de entrada da placa de aquisição de dados NI-DAQ. São utilizadas quatro entradas digitais, duas que fazem a leitura proveniente do encoder da base X e duas à leitura do encoder da base Y.

O sinal, com quatro estados diferentes, obtido na interface do programa Labview® é lido em código Gray e em seguida convertido, através de um algoritmo, para codificação decimal. A Tabela 3.1 mostra a leitura e conversão no ambiente de programação.

Tabela 3.1 – Conversão Gray – Decimal

Sensor 1	Gray	Sensor 2	Algoritmo de Programação	Decimal
0		0	→	0
0		1	→	1
1		1	→	3
1		0	→	2

Dependendo do sentido de rotação do encoder, horário ou anti-horário, tem-se um incremento ou decremento da posição das bases X e Y da mesa de coordenadas, respectivamente. Na Figura 3.7 é ilustrada a conversão Gray-Decimal de 1/4 de revolução do encoder.

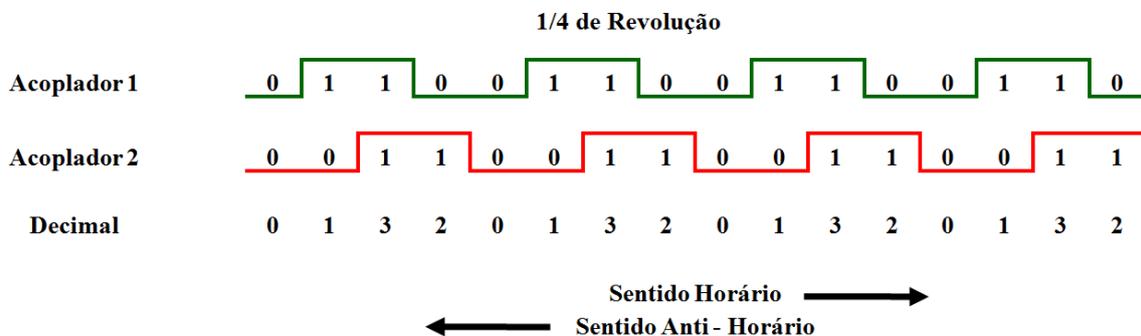


Figura 3.7 – Conversão Gray – Decimal para 1/4 de revolução do encoder

Um algoritmo para a contagem da quantidade de pulsos elétricos foi desenvolvido, por meio da atualização do número decimal processado a cada iteração do laço no programa no intervalo de 5 ms. Se o número decimal atual (lido no tempo atual) em relação ao decimal anterior (processado na iteração anterior) correspondesse ao sentido de revolução horário do encoder, o algoritmo contador efetuava um incremento unitário, caso correspondesse ao sentido anti-horário, o algoritmo decrementava em um unitário a contagem. Assim, os incrementos e decrementos foram acumulados no programa a cada amostragem, implicando em uma contagem em números inteiros, {..., -5, -4, -3, -2, -1, 0, 1, 2, 3, 4, 5, ...}. Na Figura 3.8, é mostrada a contabilização do contador em números inteiros a partir dos dados decimais, para a oitava parte de uma revolução do encoder.

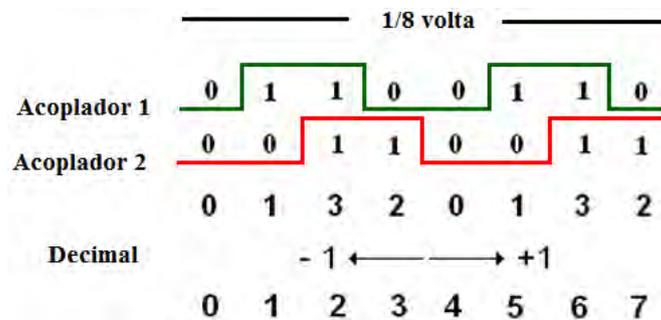


Figura 3.8 - Incremento e decremento dos números inteiros pelo contador.

No que diz respeito à resolução do sistema posicionador e conforme o que foi citado anteriormente observou-se que a cada dez voltas do eixo do motor tem-se uma volta no fuso, correspondendo a um deslocamento linear de 4 mm ou 0,0625 mm/pulso, já que observa-se 64 pulsos em cada revolução completa do encoder.

3.2.4 Sistema de Comando e Proteção

Sendo os dispositivos de comando e proteção indispensáveis em instalações elétricas foram implementados para tal fim alguns dispositivos no sistema posicionador, visando evitar a saída da mesa do seu curso máximo e, conseqüentemente, possíveis danos por choque mecânico na estrutura.

Sensores mecânicos de fim de curso (FC_1/FC_2 e FC_3/FC_4) foram inseridos nas extremidades do curso de cada uma das bases que desabilitam a ligação entre o inversor e o motor através do contadores (K1 e K2). Essa configuração de

comando foi adotada para que o funcionamento do inversor de frequência não seja interrompido, evitando possíveis paradas frequentes e, conseqüentemente, o mau uso do dispositivo. A Figura 3.9 mostra o diagrama de acionamento, comando e proteção do sistema.

A Figura 3.10 mostra o diagrama esquemático geral da disposição dos equipamentos da instrumentação para o controle e aquisição de dados do sistema de posicionamento estudado.

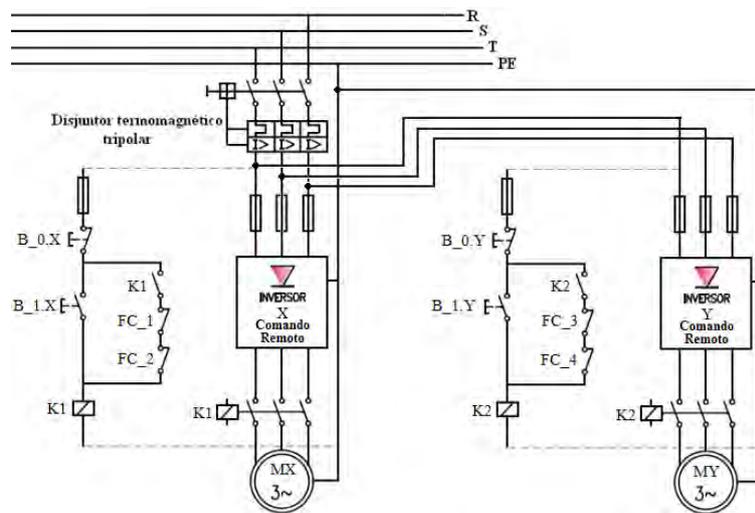


Figura 3.9 – Diagrama de acionamento, comando e proteção do sistema

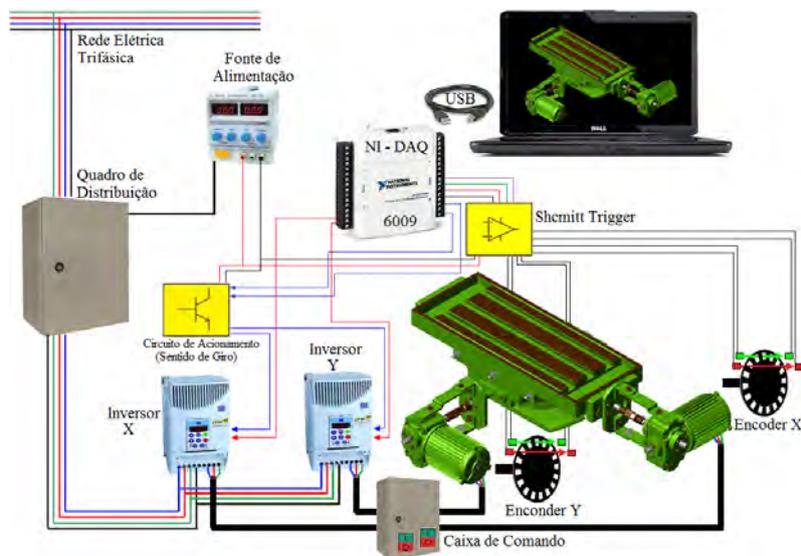


Figura 3.10 – Diagrama esquemático geral da disposição dos equipamentos do sistema de posicionamento

3.3 COMENTÁRIOS E CONCLUSÕES

Neste capítulo foi apresentada a montagem e instrumentação da mesa de coordenadas X-Y. Mostrou-se o funcionamento mecânico da mesa de coordenadas. Em seguida, foi apresentada a interface e aquisição de dados. Posteriormente foram apresentadas as características do acionamento e retropropagação. Por fim, foi apresentada instalação elétrica e proteção do sistema. Testes preliminares foram feitos e foi observada a possibilidade de variação de velocidade de rotação e sentido de giro através dos inversores de frequência apresentando desempenhos esperados.

CAPÍTULO IV

IDENTIFICAÇÃO DO SISTEMA E PROJETO DO CONTROLADOR NEURAL

4.1 INTRODUÇÃO

Neste capítulo é mostrada a implementação dos controladores neurais do sistema posicionador estudado. Na seção 4.2 é mostrado o processo de identificação. Na seção 4.3 é apresentado modelamento do controlador neural. A seção 4.4 apresenta o processo de implementação do controlador neural. Já a seção 4.5 mostra a descrição do algoritmo de retropropagação da rede neural e, por fim, na seção 4.6 a simulação do sistema e aquisição dos pesos sinápticos iniciais. Os comentários e conclusões se encontram no final do capítulo, na seção 4.7.

4.2 IDENTIFICAÇÃO, PROJETO E SIMULAÇÃO DO SISTEMA DE CONTROLE

Para que fosse possível obter os pesos sinápticos do controlador neural se faz necessário a identificação experimental do sistema e simulação.

A obtenção de um modelo matemático por meio de equações que regem a física do processo nem sempre é possível, devido ao tempo exigido, ou mesmo a falta de conhecimento sobre o sistema. Com o objetivo de solucionar este inconveniente, foram desenvolvidas técnicas de identificação para determinar o modelo matemático de sistemas, a partir do sinal de entrada e resposta dos mesmos, de forma que este modelo represente com boa aproximação do sistema real (AGUIRRE, 2004).

Na abordagem, baseada na experimentação, denominada de identificação de sistemas, as entradas e as saídas são submetidas a uma análise matemática a partir da qual se obtém a função de transferência do sistema.

Na identificação de sistemas, conhecida também como modelagem empírica são usados dados coletados diretamente dos sistemas (AGUIRRE, 2004).

Em um sistema eletromecânico de posição, acionado por um motor de corrente contínua, para se obter um modelo matemático utilizando a técnica de modelamento é necessário o conhecimento da resistência e da indutância do circuito de armadura, do coeficiente de atrito viscoso dos eixos ou mancais de sustentação e a constante de inércia do conjunto carga e motor.

Utilizando-se técnicas de identificação de sistemas, não é necessário o conhecimento dos parâmetros físicos citados do sistema, porque existem várias formas e técnicas para a obtenção de modelos matemáticos, entre elas, a modelagem caixa branca, modelagem caixa preta e a intermediária, denominada caixa cinza.

AGUIRRE (2004) apresenta uma distinção dos métodos de identificação de sistemas, classificando-os em:

1. Identificação caixa preta. - Neste caso, não se tem nenhuma informação sobre o sistema. Apenas os dados de entrada e de saída do sistema são usados durante a identificação. Neste tipo de identificação, não existe nenhuma relação óbvia entre a estrutura e seus parâmetros com aspectos físicos do sistema sendo identificado.

2. Identificação caixa branca. - Trata-se da modelagem do sistema, já citada. Neste caso, os dados de entrada e de saída do sistema, quando disponíveis são usados apenas para validar o modelo.

3. Identificação caixa cinza.- É um procedimento de identificação que não se enquadra nem no modelo caixa preta nem no modelo caixa branca. Neste caso, busca-se combinar as vantagens dos procedimentos de identificação de ambas as abordagens anteriores.

Neste caso usou-se a identificação Caixa Preta, para a obtenção da função de transferência do sistema tendo em vista que essa técnica é uma das mais utilizadas no processo de identificação.

4.2.1 Identificação experimental (caixa preta)

Para obtenção dos dados para a identificação do sistema, foi realizado um ensaio aplicando-se um sinal de excitação do tipo onda quadrada com amplitude e largura pré-determinada.

O sinal de tensão elétrica enviado ao inversor aciona o motor provocando um movimento angular em seu eixo. A resposta do sistema se traduz no deslocamento da mesa, e é captada pelo sensor de posição (encoder) e enviada ao computador, onde é armazenada em um arquivo de dados gerado pelo MATLAB, juntamente com a excitação provocada no motor.

A identificação é realizada a partir dos dados de entrada e de saída da planta, contidos em arquivo. Para obter a função de transferência do sistema utilizou-se o modelo BJ (Box Jenkins Model) disponível no programa computacional MATLAB denominado de caixa de ferramenta de identificação. O procedimento descrito acima foi realizado várias vezes, resultando em uma família de modelos. A partir desta família foi escolhido o modelo que apresentou a resposta mais aproximada do sistema real. Nas Figura 4.1 e 4.2 são mostrados o sinal de excitação, utilizado no ensaio, e o sinal de saída da base X da mesa.

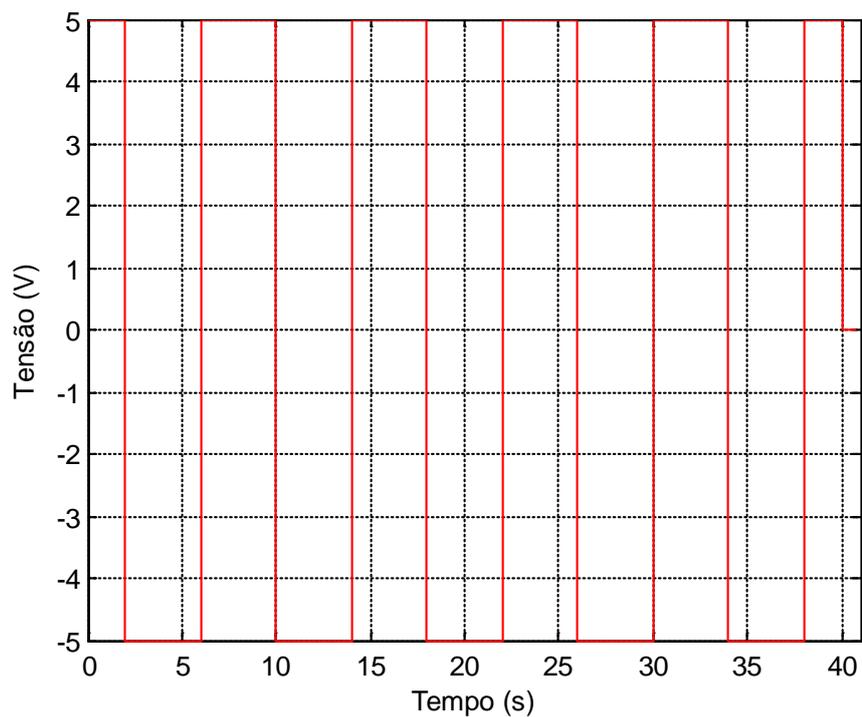


Figura 4.1 – Sinal de excitação da base X

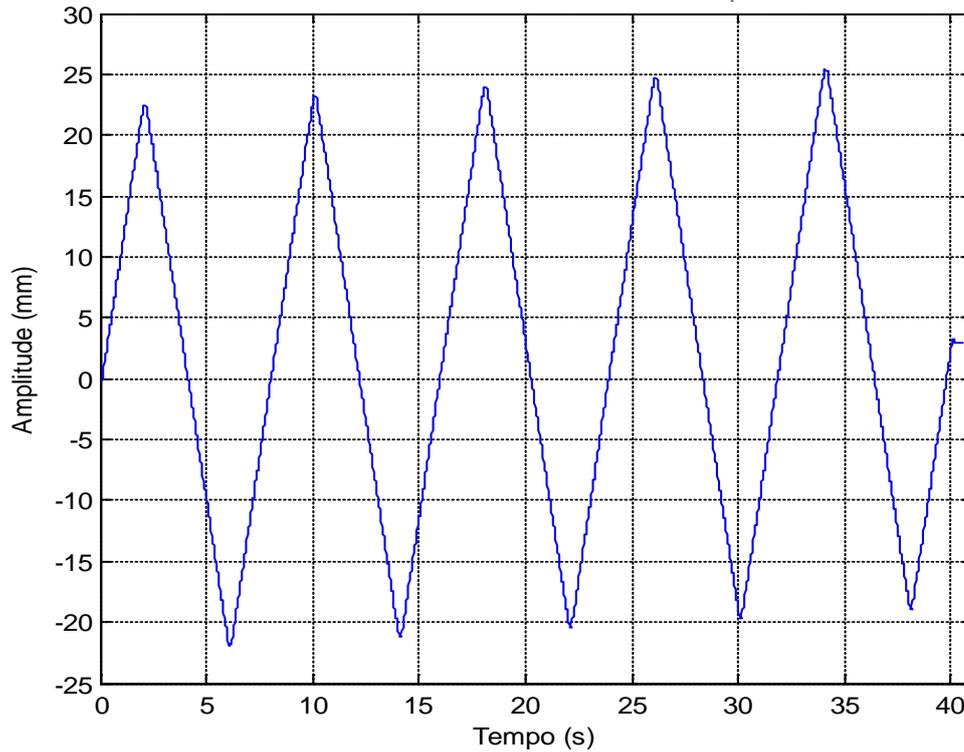


Figura 4.2 – Curva de resposta experimental para base X

Uma validação, do modelo escolhido, foi feita por meio da comparação entre a resposta simulada e a resposta experimental do sistema, sendo ambas submetidas ao mesmo sinal de excitação.

Na Equação 4.1 mostra-se o modelo na forma de função de transferência no modo discreto da mesa, obtida no processo de identificação, que será utilizada para se representar a função de transferência da mesa no programa de simulação do controlador neural.

$$\frac{Y(z)}{U(z)} = \frac{-0.0008869z^2 + 0.0008858z}{z^3 - 2.922z^2 + 2.845z - 0.9223} \quad (4.1)$$

As curvas de resposta simulada e experimental são mostradas na Figura 4.3.

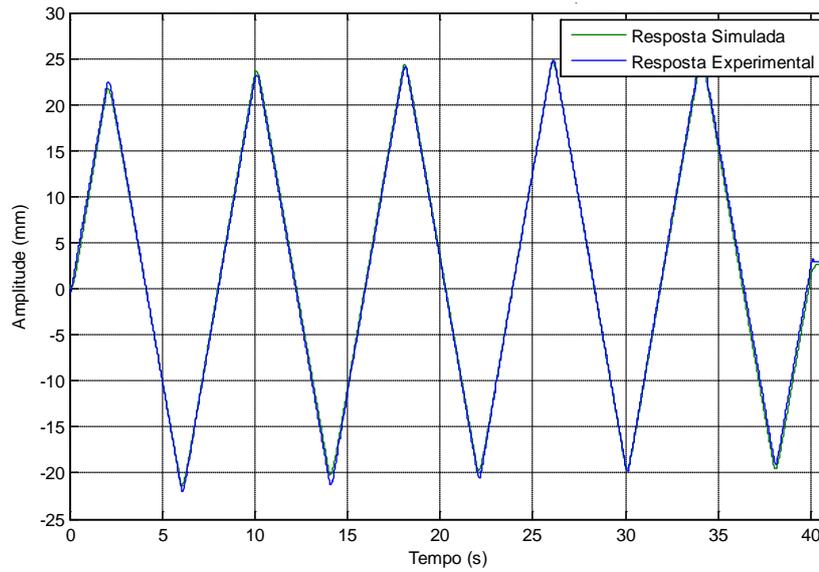


Figura 4.3 - Curvas de Resposta Experimental e Simulada do Sistema Para Base X

De modo análogo foi realizada a identificação do sistema para base inferior. Nas Figuras 4.4 e 4.5 são mostrados o sinal de excitação, utilizado no ensaio, e o sinal de saída da base superior do sistema. Da mesma forma para a base X do sistema uma validação, do modelo escolhido, foi feita através da comparação entre a resposta simulada e a resposta experimental do sistema, ambas submetidas ao mesmo sinal de excitação.

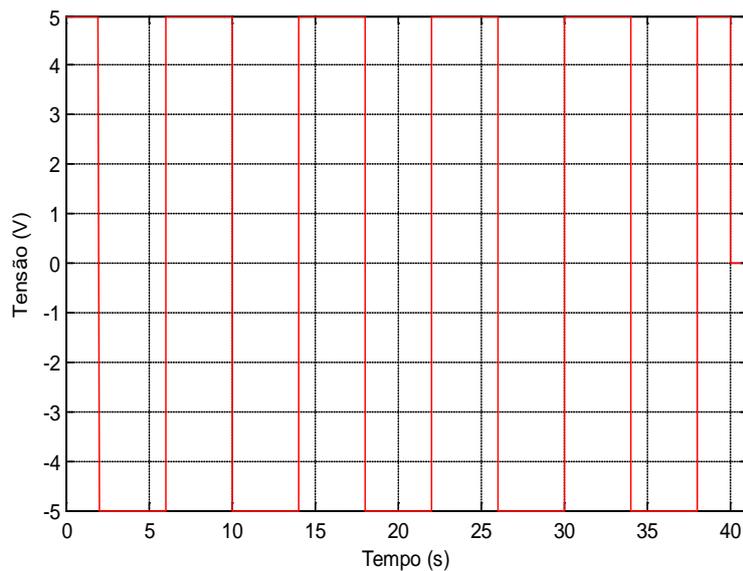


Figura 4.4 – Sinal de Excitação Para Base Y

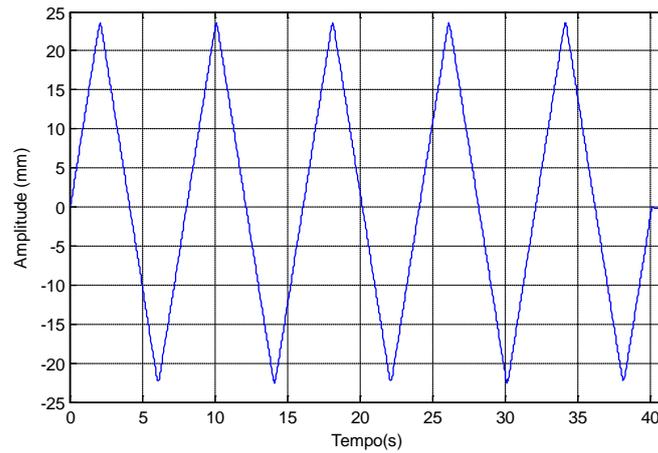


Figura 4.5 – Curva de resposta experimental para base Y

Na Equação 4.2 mostra-se o modelo na forma de função de transferência no modo discreto da mesa, obtida no processo de identificação, que será utilizada para representar a função de transferência da mesa no programa de simulação do controlador neural.

$$\frac{Y(z)}{U(z)} = \frac{-0.0008814z^2 + 0.001571z}{z^3 - 2.468z^2 + 1.994z - 0.5257} \quad (4.2)$$

As curvas simulada e experimental são mostradas na Figura 4.6.

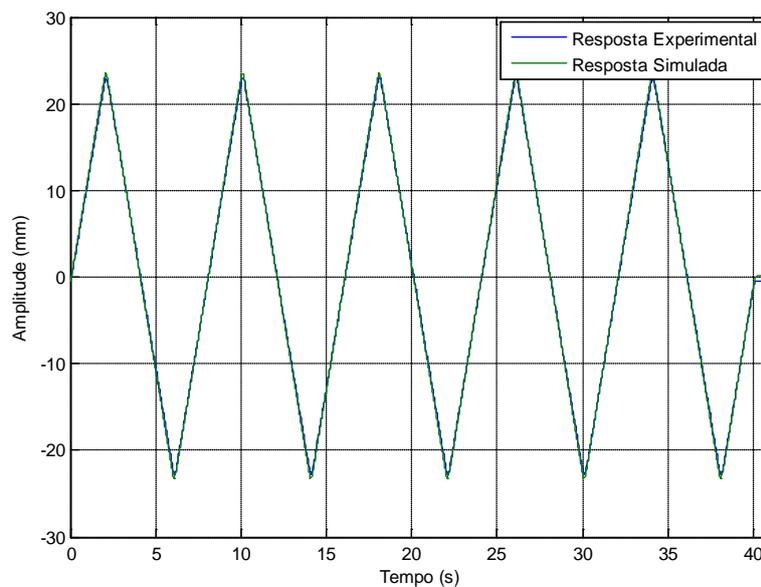


Figura 4.6 - Curvas de Resposta Experimental e Simulada do Sistema Para Base Y

4.2.2 Modelo do Controlador Neural

Tendo em vista que uma mesa de coordenadas X-Y pode ser considerada um sistema desacoplado, com dois graus de liberdade, ou seja, o movimento de uma base não causa interferência no movimento da outra, são utilizados neste trabalho dois controladores independentes, constando cada controlador de entradas e saídas individuais.

Para o projeto dos controladores foram utilizadas Redes Neurais de Multicamada (RNMC) do tipo direto. Sua arquitetura está disposta em três camadas, sendo uma camada de entrada contendo quatro neurônios, uma camada oculta com oito neurônios e uma camada de saída, contendo apenas um neurônio, a qual fornece o sinal de controle para os inversores de frequência. A Rede Neural foi testada com valores de 4, 8 e 12 neurônios nesta camada no controle de posição de forma independente. A arquitetura com 8 neurônios na camada intermediária apresentou o melhor resultado, cuja arquitetura da rede neural, a ser utilizada no experimento é mostrado na Figura 4.7.

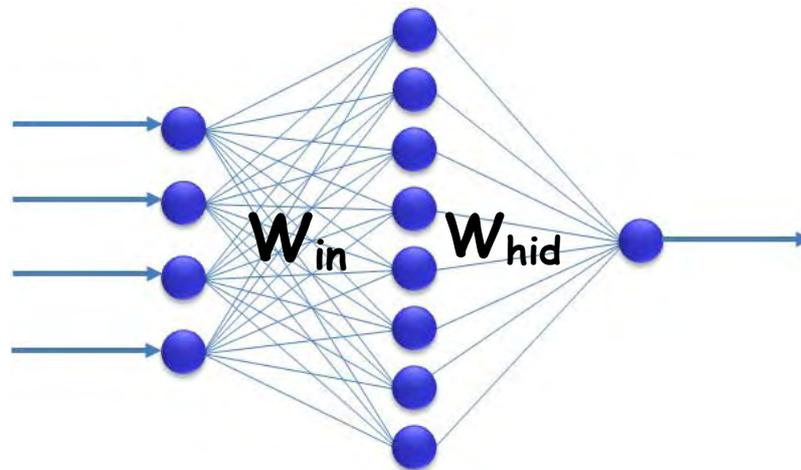


Figura 4.7 – Arquitetura Multicamada Utilizada no Controle do Sistema

Para esse tipo de organização da rede, os neurônios da camada de entrada têm a função apenas de ligação, sendo assim, as quatro ligações de entrada e os neurônios da camada intermediária ocorrem através de 32 pesos sinápticos, dessa forma é obtida uma matriz com 8 linhas e 4 colunas denominada W_{in} . Já as ligações entre os neurônios da camada intermediária e os neurônios da camada de saída ocorrem através de 8 pesos

sinápticos, dessa forma é obtida uma matriz de pesos contendo 8 linhas e 1 coluna, denominada W_{hid} . A matrizes W_{in} e W_{hid} são apresentadas nas equações 4.3 e 4.4:

$$W_{in} = \begin{pmatrix} W_{in11} & W_{in12} & W_{in13} & W_{in14} \\ W_{in21} & W_{in22} & W_{in23} & W_{in24} \\ W_{in31} & W_{in32} & W_{in33} & W_{in34} \\ W_{in41} & W_{in42} & W_{in43} & W_{in44} \\ W_{in51} & W_{in52} & W_{in53} & W_{in54} \\ W_{in61} & W_{in62} & W_{in63} & W_{in64} \\ W_{in71} & W_{in72} & W_{in73} & W_{in74} \\ W_{in81} & W_{in82} & W_{in83} & W_{in84} \end{pmatrix} \quad (4.3)$$

$$W_{hid} = \begin{pmatrix} W_{hid11} \\ W_{hid21} \\ W_{hid31} \\ W_{hid41} \\ W_{hid51} \\ W_{hid61} \\ W_{hid71} \\ W_{hid81} \end{pmatrix} \quad (4.4)$$

4.2.3 Implementação do Controlador Neural

O primeiro passo para implementação da rede neural é a definição dos sinais das entradas e das saídas, objetivando o controle de posição da mesa. Podem-se encontrar vários exemplos de determinação de sinais de entrada na literatura.

Pode-se encontrar um exemplo de determinação de sinais de entrada em MENEZES (2007), que implementou uma Rede Neural Multicamada trabalhando de modo vetorial em um sistema de posicionamento impondo na entrada quatro sinais; são eles:

1ª Entrada: Sinal de erro do posicionamento;

2ª e 3ª Entradas: Valores armazenados no instante de amostragem imediatamente anterior e com dois atrasos do sinal do erro, respectivamente;

4ª Entrada: ZERO.

Já em NASCIMENTO J. (2000), que apresenta um esquema de um controlador neural com quatro entradas, o sinal de referência como primeira entrada, como segunda e terceira entradas os valores armazenados no instante de amostragem imediatamente anterior e com dois atrasos, respectivamente, e mais três entradas relacionadas ao erro e aos valores armazenados do erro em dois intervalos de amostragem anteriores.

Neste trabalho escolheu-se fazer uma analogia com o controlador PD2 (Proporcional Derivativo Duplo). A Equação discreta do controlador PD2 é, de acordo com BUHLER (1982), dado por:

$$u(k) = k_p \cdot e(k) + k_d \cdot (e(k) - e(k-1)) + k_{d2} \cdot (e(k) - 2 \cdot e(k-1) + e(k-2)) \quad (4.5)$$

onde:

$u(k)$: valor da saída discreta do controlador

k_p : ganho proporcional do controlador

k_d : ganho aplicado a derivada do sinal de erro

k_{d2} : ganho aplicado a derivada segunda do sinal de erro

$e(k)$: erro no instante de amostragem k

$e(k-1)$: erro armazenado no instante anterior ao tempo k

$e(k-2)$: erro armazenado na amostragem anterior ao tempo $k-1$

Desse modo, os sinais da primeira camada, ou seja, os sinais da camada de entrada são mostrados na Equação (4.6)

$$in_{11} = e(k) ; in_{21} = e(k-1) ; in_{31} = e(k-2) ; in_{41} = zero \quad (4.6)$$

Formando assim uma matriz de entrada com 4 linhas e uma coluna, conforma a equação 4.7:

$$I_n = \begin{pmatrix} in_{11} \\ in_{21} \\ in_{31} \\ in_{41} \end{pmatrix} \quad (4.7)$$

A segunda camada (camada oculta) da RNMC tem 8 neurônios. Para estes neurônios, é definido o campo induzido V_{in} para cada neurônio, dado pela Equação (4.8), com a combinação linear da matriz de entradas I_n ponderadas pelos elementos da matriz de pesos W_{in} .

$$V_{in} = W_{in} \times I_n \quad (4.8)$$

O Campo induzido de cada neurônio oculto é aplicado em uma função do tipo Tangente Hiperbólica, chamada de Função de Ativação. A saída de cada função tangente hiperbólica é chamada de Sinal Funcional do neurônio oculto, dado pela Equação (4.9).

$$Y_{(i \times 1)} = \text{Tanh}(vin(i1)) = \frac{1 - e^{(-vin(i1))}}{1 + e^{(-vin(i1))}} \quad \text{onde: } i = 1, 2, \dots, 8; \quad (4.9)$$

Desse modo a matriz Y a dada pela equação 4.10:

$$Y = \begin{pmatrix} y_{11} \\ y_{21} \\ y_{31} \\ y_{41} \\ y_{51} \\ y_{61} \\ y_{71} \\ y_{81} \end{pmatrix} \quad \text{onde: } i = 1, 2, \dots, 8; \quad (4.10)$$

A terceira camada (camada de saída) consiste de 1 neurônio. Para este neurônio, define-se o Campo Induzido, dado pela Equação (4.11), como a combinação

linear das saídas dos sinais funcionais dos neurônios ocultos Y ponderados com os pesos sinápticos de W_{hid}^T .

$$vout = W_{hid}^T \times Y \quad (4.11)$$

A Função de Ativação de cada neurônio da camada de saída, do tipo Tangente Hiperbólica, dada pela Equação (4.12), fornece o sinal de saída $outs$, que é o sinal de controle para o motor ligado a essa rede. A Figura 4.8 mostra a rede neural com os detalhes do cálculo da propagação direta utilizada no trabalho

$$outs = \text{Tanh}(vout) = \frac{1 - e^{(-vout)}}{1 + e^{(-vout)}} \quad (4.12)$$

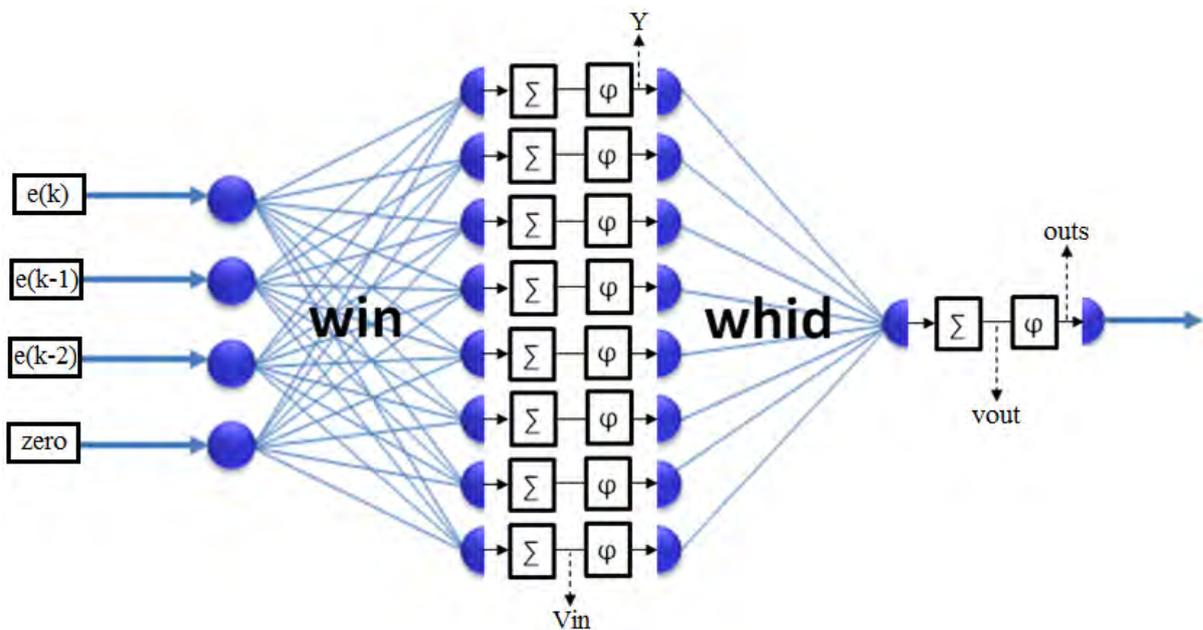


Figura 4.8 – Rede Neural detalhada

Nas Figuras 4.9 e 4.10 são mostrados os Controladores Neurais utilizados no acionamento independente para cada base.

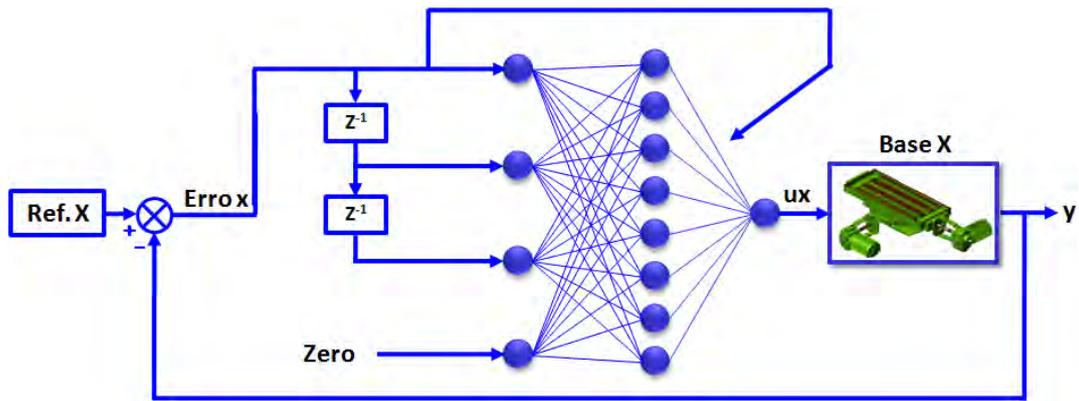


Figura 4.9 – Controlador Neural Para a Base X

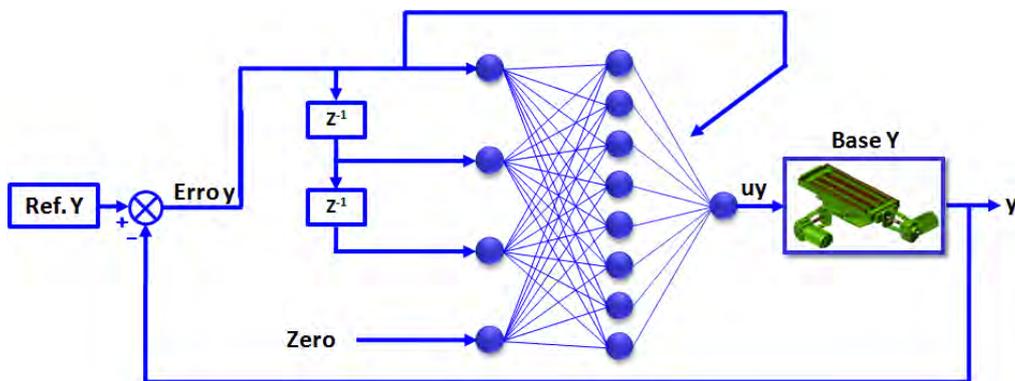


Figura 4.10 – Controlador Neural Para a Base Y

4.2.4 Algoritmo de Retropropagação da Rede Neural

De acordo com HAYKIN (2001), a utilização da Rede Neural de Multicamadas (RNMC), compreende dois passos: o primeiro é chamado de propagação para frente e o segundo é a retropropagação. Na propagação para frente, os pesos sinápticos são mantidos sem mudança. O fluxo de processamento vai dos neurônios de entrada para o neurônio de saída. Na retropropagação todos os pesos da rede são ajustados. A retropropagação é iniciada pelo gradiente local da camada de saída (∇_{out}), que é definido como o produto da derivada da função de ativação do neurônio de saída e do erro de posição (e) (diferença entre a posição do eixo do motor e a referência) com o Jacobiano J , e é dado por:

$$\nabla_{\text{out}} = e(k) \cdot J \cdot \frac{d(\tanh(v_{\text{out}}))}{dk} \quad (4.13)$$

Para o sistema em estudo pode-se considerar o Jacobiano J igual a um.

Com o Gradiente local dado pela Equação 4.13, são calculadas as variações dos pesos (w_{hid}), que ligam a camada de saída com a camada oculta, dadas pela Equação 4.14:

$$\Delta_{\text{hid}} = \eta \cdot \nabla_{\text{out}} \cdot Y_{\text{ix1}} \quad (4.14)$$

onde η é o fator de convergência do algoritmo, ou seja, a taxa de aprendizagem da rede neural.

Finalmente os pesos sinápticos (w_{hid}) são dados pela Equação 4.15:

$$W_{\text{hid}(8 \times 1)} = W_{\text{hid}(8 \times 1)} + \Delta_{\text{hid}} \quad (4.15)$$

A modificação dos pesos sinápticos entre a primeira camada e a camada oculta é iniciada com o cálculo dos gradientes locais de cada neurônio da camada oculta dado pela Equação 4.16:

$$\nabla_{\text{in}} = w_{\text{hid}}(k1) \cdot \nabla_{\text{out}} \cdot \frac{\partial(\tan g(Y))}{\partial y_{k1}} \quad \text{onde: } k = 1, 2, \dots, 8; \quad (4.16)$$

De acordo com o Gradiente local dado pela Equação 4.16, a variação dos pesos entre a camada de entrada e camada oculta (W_{in}) é calculada de acordo com a Equação 4.17:

$$\Delta_{\text{in}} = \eta \cdot \nabla_{\text{in}} \cdot \text{In}^T \quad (4.17)$$

Finalmente é calculada a modificação dos pesos sinápticos (w_{in}), que ligam cada neurônio de entrada com os neurônios da camada oculta, de acordo com a Equação (4.18).

$$W_{in} = W_{in} + \Delta_{in} \quad (4.18)$$

Após o processo de retropropagação, o processamento para frente é aplicado na RNMC fornecendo os sinais de controle para o posicionamento da mesa X-Y.

4.2.5 Simulação do sistema e aquisição dos pesos sinápticos

Para obter os pesos sinápticos iniciais a serem implementados no controlador neural, foi realizado um treinamento off-line das redes neurais artificiais utilizando as funções de transferência obtidas do processo de identificação mostrado na seção 4.2.

Para o treinamento off-line das redes neurais, foi utilizado um programa de simulação no ambiente LabVIEW®, que implementa o controle da mesa simulada através do processamento das equações (4.1) e (4.2), de acordo com os diagramas esquemáticos da Figura 4.9 e 4.10. Antes da execução do programa foram determinados aleatoriamente, no ambiente MATLAB®, os pesos sinápticos w_{hid} , que liga a camada de entrada com a camada oculta e os pesos sinápticos w_{in} , que ligam a camada oculta com a camada de saída das redes neurais que controlam a posição das mesas X e Y. O Algoritmo a seguir mostra o fluxo do processo implementado.

1º) Executar o programa de geração de pesos w_{hid} e w_{in} no ambiente MATLAB® .

2º) Executar o programa em ambiente LabVIEW® que simula o controle em malha fechada de posição das mesas X e Y com os controladores neurais adaptativos. Durante esta etapa são reajustados e armazenados os pesos w_{hid} e w_{in} a cada período de amostragem.

3º) Observar a forma de onda da variável de saída das mesas X e Y do programa de simulação. Caso não ocorram erros de regime permanente e se consigam a máxima redução dos sobre-sinais, encerrar o processo de simulação armazenando os pesos sinápticos w_{hid} e w_{in} . Caso contrário voltar ao passo 2 para novo treinamento dos pesos.

4.6.1 Resposta do sistema para simulação dos controladores neurais

Foram utilizados, nesta etapa de simulação, sinais de referência do tipo degrau nas bases X e Y, bem como acionamento do tipo acompanhamento de trajetória, ou seja, acionamentos com funções seno e cosseno para bases X e Y, respectivamente. Nas Figuras 4.11 e 4.12 são mostrados os resultados da simulação de referência ao degrau para a base X e a variável de controle do controlador neural, respectivamente.

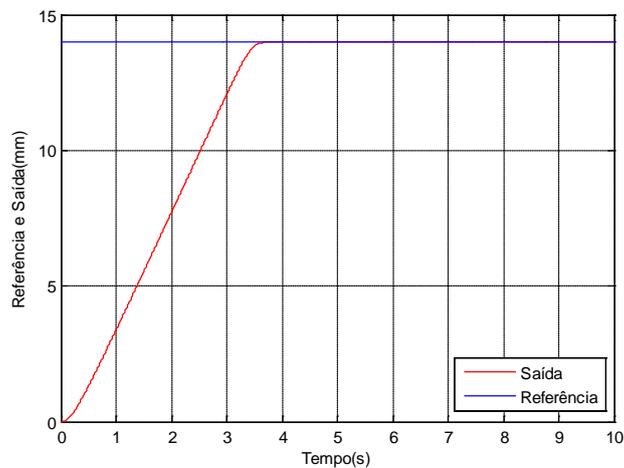


Figura 4.11 – Curva de resposta da base X para uma referência degrau de 14 mm

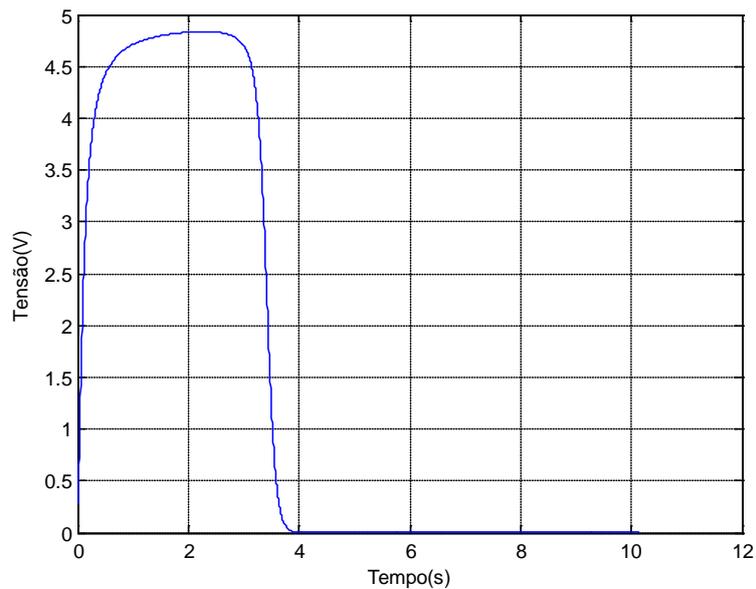


Figura 4.12 – Variável de controle para resposta da base X para referência ao degrau de 14 mm

Nas Figuras 4.13 e 4.14 são mostrados os resultados da simulação para uma referência ao degrau para a base Y e a variável de controle do controlador neural, respectivamente. Na Tabela 4.1 são mostrados os valores dos índices observados na simulação, para as duas bases.

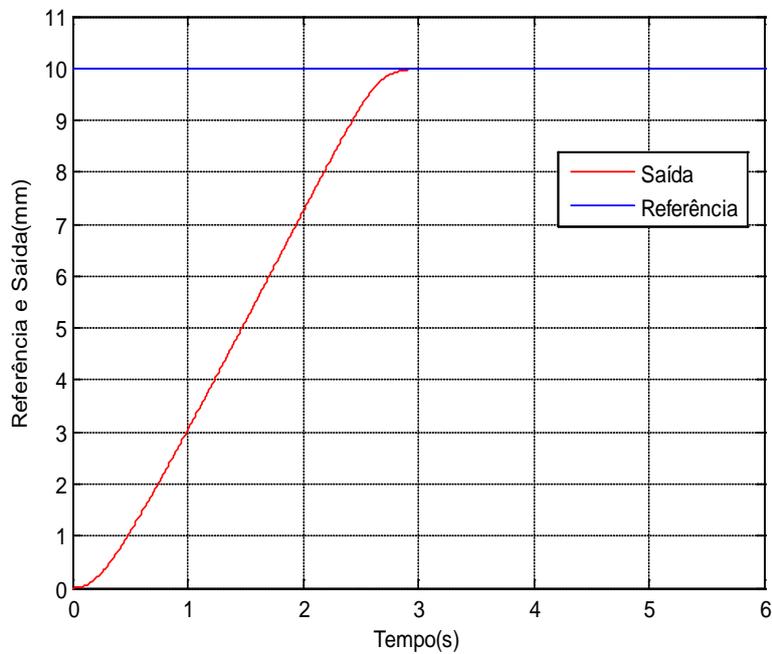


Figura 4.13 – Resposta da base Y para referência ao degrau de 10 mm

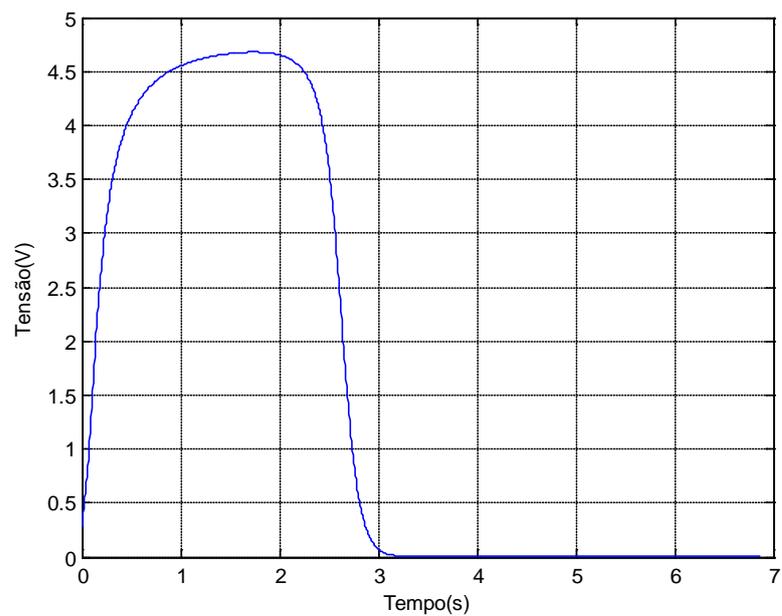


Figura 4.14 – Variável de controle para resposta da base Y para referência ao degrau de 10 mm

Tabela 4.1 – Valores observados na simulação para referência ao degrau

Valor Observado	Base X (14 mm)	Base Y (10 mm)
Ts(s)	3,4396	2,7002
UP (%)	0	0
ess (%)	0	0

Em seguida as bases X e Y foram acionadas de modo a fazer com que os atuadores do sistema sigam uma trajetória pré-determinada. Para a base X foi enviado um sinal de senoidal e para base Y foi enviado um sinal de cossenoidal, ambos com amplitude e período pré-determinado de 5 mm e 15 segundos, respectivamente. Nas Figuras 4.15 e 4.16 são mostradas as curvas de respostas simuladas para a base X e a variável de controle para um acionamento com um sinal de referência senoidal.

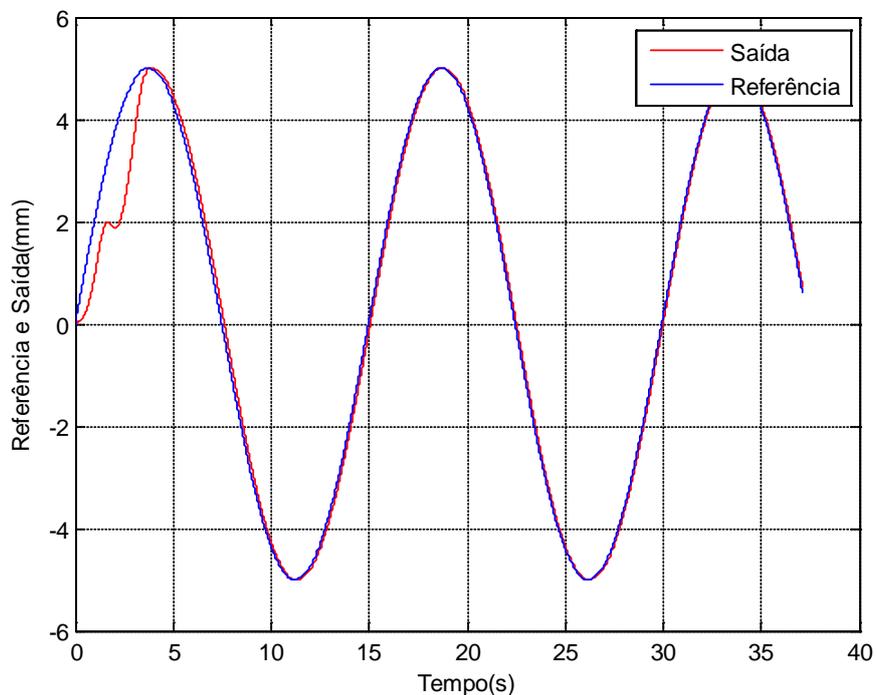


Figura 4.15 – Curva de Resposta da Base X ao Sinal de Excitação Senoidal para um período $T = 15$ s

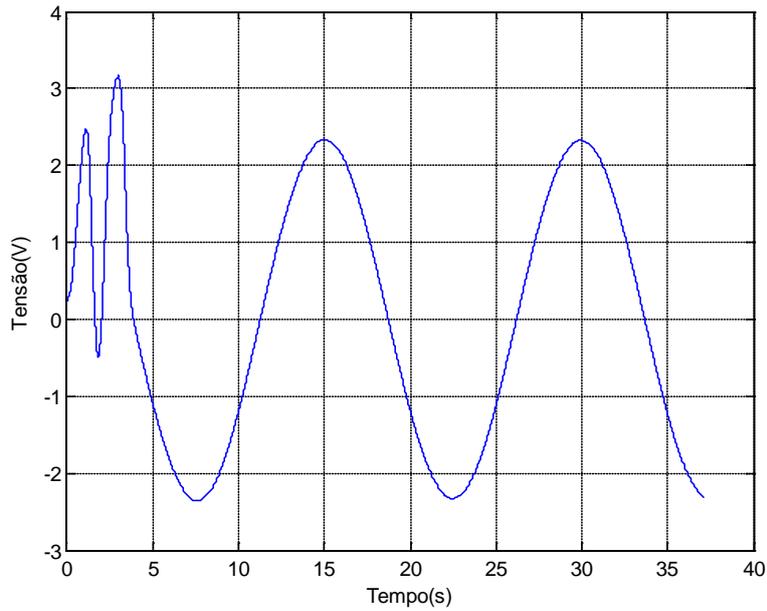


Figura 4.16 – Variável de controle para resposta da base X ao sinal de excitação senoidal

Nas Figuras 4.17 e 4.18 são mostradas as curvas de resposta simulada para a base Y e a variável de controle para um acionamento com um sinal de referência cossenoidal.

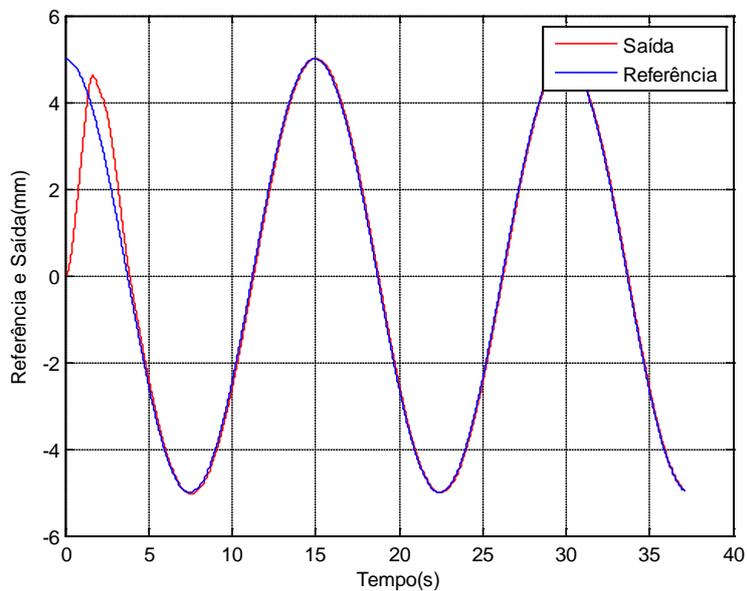


Figura 4.17 – Curva de resposta da base Y ao sinal de excitação cossenoidal para um período $T = 15$ s

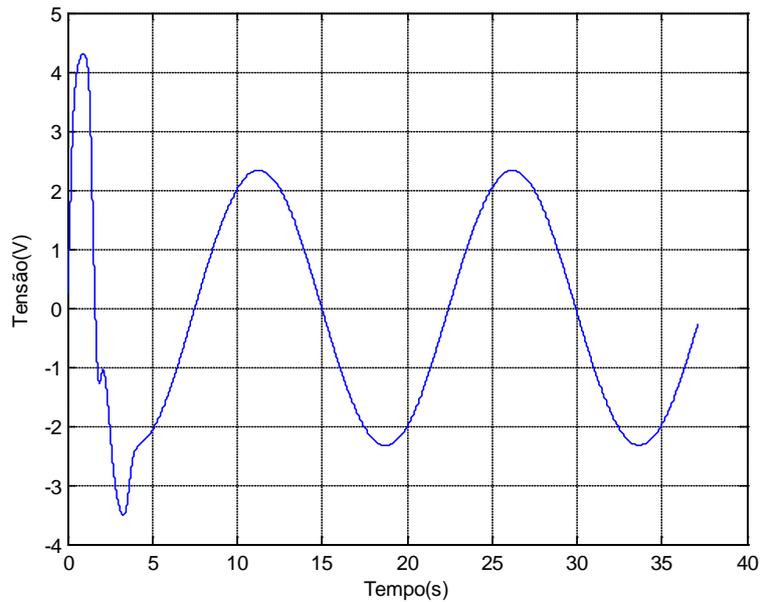


Figura 4.18 – Variável de Controle para Resposta da Base Y ao Sinal de Excitação Cossenoidal

Na Tabela 4.2 são mostrados os valores observados na simulação.

Tabela 4.2- Valores simulados do controle neural de posição para referências com funções circulares

Períodos dos sinais de referência	Erro máximo (%)	
	<i>Base X</i>	<i>Base Y</i>
Período 15 s	7	7
Obs: * Resultados para as Figuras 4.15 e 4.17		
** Erro máximo calculado após o regime permanente de trabalho		

A composição dos sinais senoidais das bases X e Y geram o círculo descrito no espaço de trabalho mostrado na Figura 4.19.

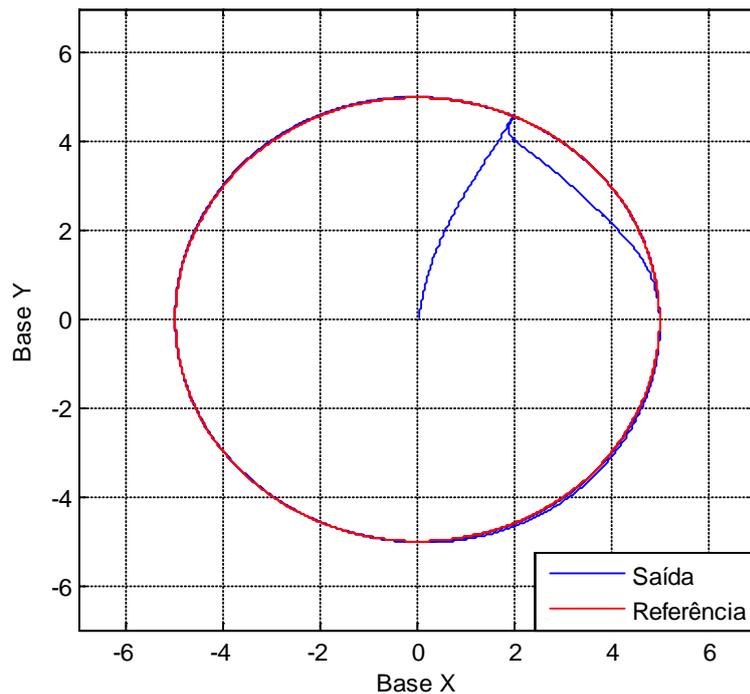


Figura 4.19 – Composição dos Sinais Senoidais para um período $T = 15$ s

4.7 COMENTÁRIOS E CONCLUSÕES

Neste capítulo apresentou-se o processo de identificação e o projeto do controlador neural para a mesa de coordenadas X-Y. O projeto da rede foi baseado em duas redes neurais multicamadas (RNMC). A utilização da rede neural de multicamadas tem como vantagem a capacidade de reajustar os pesos sinápticos a cada intervalo de amostragem e trabalha em modo adaptativo.

Após o processo de identificação do sistema, o modelamento dos controladores neurais e descrição do algoritmo de retropropagação foram feitas simulações e aquisição dos pesos sinápticos iniciais que comprovaram o bom desempenho do controlador neural para o acionamento para o sistema de posição proposto.

CAPÍTULO V

UTILIZAÇÃO DO CONTROLADOR NEURAL NO ACIONAMENTO DA MESA

5.1 INTRODUÇÃO

São mostrados, neste capítulo, os resultados experimentais obtidos no sistema de posicionamento. Na seção 5.2, são apresentadas algumas informações quanto ao funcionamento da mesa de coordenadas. Na seção 5.3, são analisados os gráficos e alguns valores extraídos a partir deles quanto às imposições de sinais do tipo degrau e degrau variável no acionamento do sistema, bem como perturbações para avaliação da robustez do sistema. Na seção 5.4, avaliam-se os desempenhos dos controladores nos seguimentos as trajetórias das curvas de referência senoidal, cossenoidal e da composição dessas duas últimas. O capítulo é encerrado com os comentários e conclusões na seção 5.5.

5.2 NOTAS SOBRE O SISTEMA

Nos gráficos a seguir, plotados através do programa MATLAB®, os valores das tensões de controle de 0 V a 5 V correspondem a deslocamentos para direita da base X e de avanço da base Y, enquanto que as tensões de controle de 0 V a -5 V resultam em deslocamentos das bases X e Y para esquerda e de retrocesso, respectivamente, com referência a um observador em frente à mesa.

Em todos os acionamentos iniciais do sistema, os movimentos das bases partiram de seus centros. O curso da base X da mesa foi de 200 mm e o da base Y foi 100 mm, conforme informado anteriormente.

5.3 ENSAIOS DE ACIONAMENTO DO SISTEMA

De acordo com RAMESH, R. et al (2005), os controladores em malha fechada podem trabalhar de duas formas. No primeiro caso trata-se do controle ponto a ponto, no qual tanto a trajetória da ferramenta de um ponto de origem ao ponto de referência quanto à velocidade de deslocamento não são importantes. A razão para isso é que a ferramenta não entra em contato com a área de trabalho. Nesse tipo de controle o que importa é a exatidão com que a ferramenta atinge o ponto de referência. O segundo tipo de controlador, em malha-fechada, é denominado sistema de controle de contorno, no qual o caminho traçado pela ferramenta é de fundamental importância, sendo por este motivo a variável controlada. Esse tipo de controle é muito utilizado em trabalhos de corte, lapidação, pintura, etc, RAMESH, R. et al (2005).

5.3.1 Ensaios de Acionamento com Excitações do Tipo Degrau

Com relação à base X, primeiramente foi realizado o acionamento, partindo do seu centro, por um degrau de referência com amplitude de 100 mm, resultando em um deslocamento para direita. No gráfico da Figura 5.1, encontram-se as curvas de resposta da base X e da referência. Na Figura 5.2, observa-se a evolução temporal da tensão de controle.

Em seguida foi realizado o acionamento, partindo do seu centro, por um degrau de referência com amplitude de -100 mm, resultando em um deslocamento para esquerda. No gráfico da Figura 5.3, encontram-se as curvas de resposta da base X e da referência. Na Figura 5.4, observa-se a evolução temporal da tensão de controle.

Analisando-se as Figuras 5.1 e 5.3, é possível obter os tempos de assentamento em segundos T_s (s), ultrapassagem percentual UP (%) e os erros percentual de regime permanente ess (%) das curvas de resposta às referências. Esses dados, correspondentes à base X, estão apresentados na Tabela 5.1.

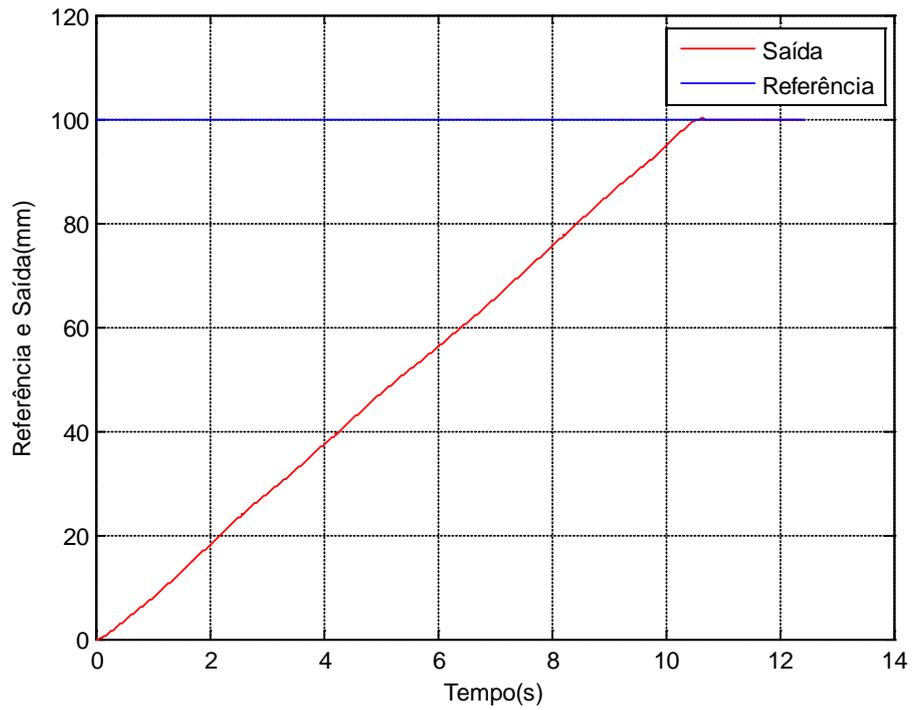


Figura 5.1 – Curvas de resposta e de referência ao Degrau de 100 mm da base X

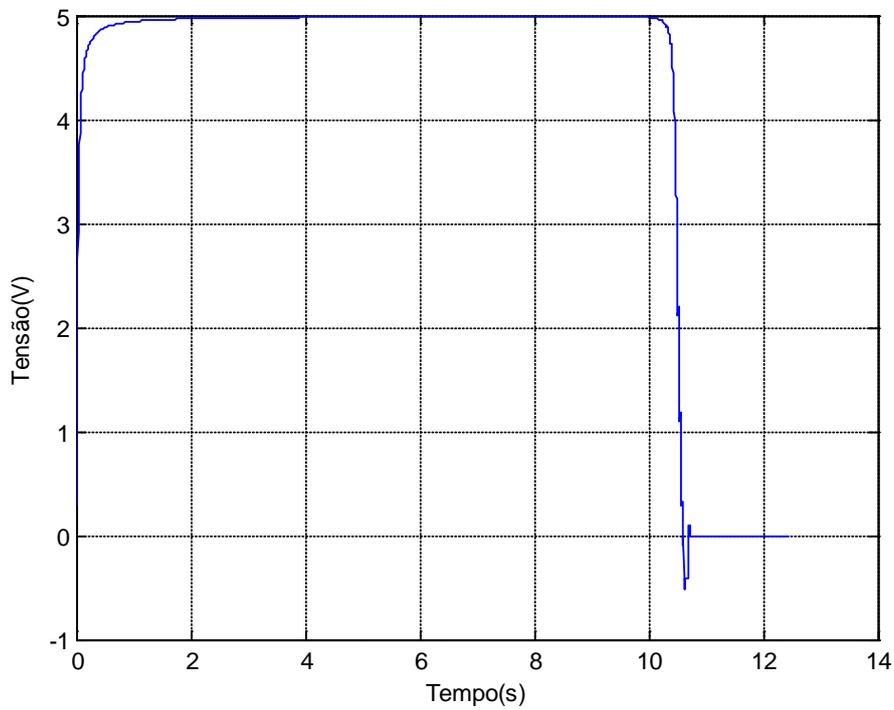


Figura 5.2 – Curva de resposta da variável de controle da base X para uma referência do tipo degrau de 100 mm

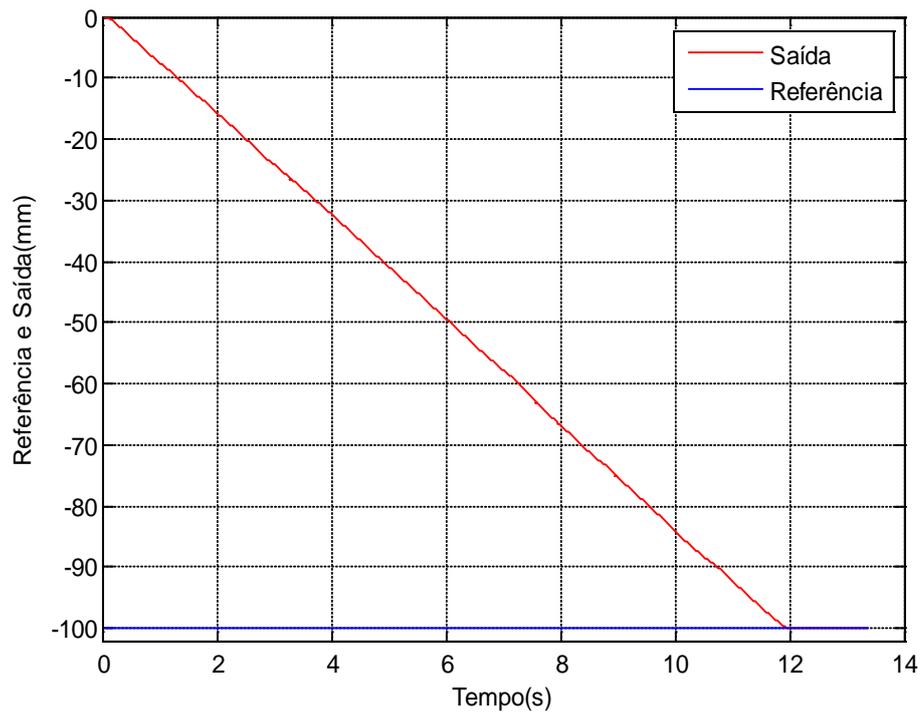


Figura 5.3 – Curvas de resposta e de referência ao degrau de -100 mm da base X

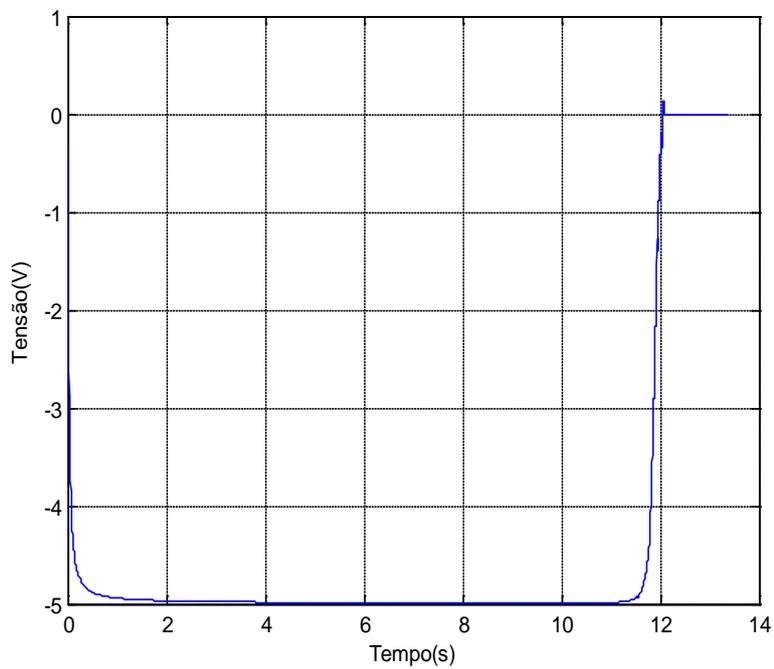


Figura 5.4 – Curva de Resposta da variável de controle da base X para uma Referência do tipo Degrau de -100 mm

Tabela 5.1 – Índices de desempenho experimentais extraídos das curvas de resposta da base X

Valor medido	Figura 5.1	Figura 5.3
	Sinal de Referência	Sinal de Referência
	100 mm	-100 mm
Ts (s)	10,335	11,685
UP (%)	0,0625	0
ess (%)	0	0

Analogamente a base X, a base Y foi acionada, partindo do seu centro, por um degrau de referência com amplitude de 70 mm, resultando em um deslocamento para direita. No gráfico da Figura 5.5, encontram-se as curvas de resposta da base Y e da referência. Na Figura 5.6, é mostrada a curva de resposta da variável de controle.

Da mesma forma para base Y, foi realizado o acionamento, partindo do seu centro, por um degrau de referência com amplitude de -70 mm, resultando em um deslocamento para esquerda. No gráfico da Figura 5.7, encontram-se as curvas de resposta da base Y e da referência. Na Figura 5.8, observa-se a evolução temporal da variável de controle.

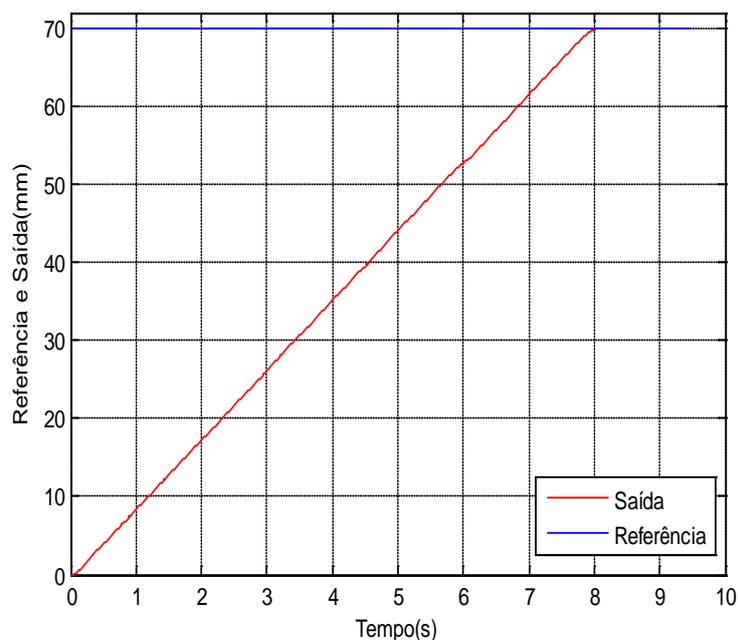


Figura 5.5 - Curvas de Resposta e de Referência ao Degrau de 70 mm da base Y

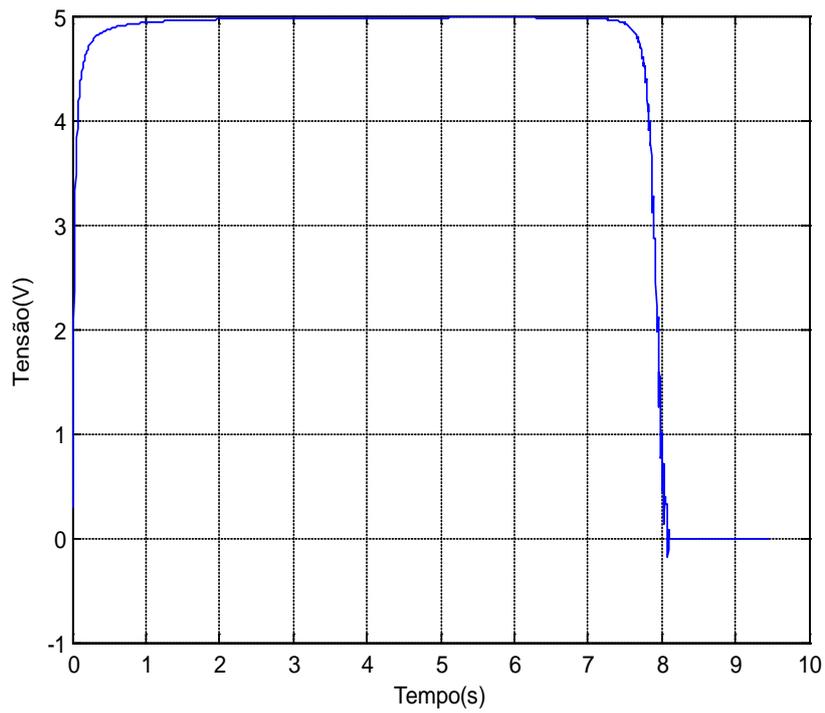


Figura 5.6 - Curva de Resposta da variável de controle da base X para uma Referência do tipo Degrau de 70 mm

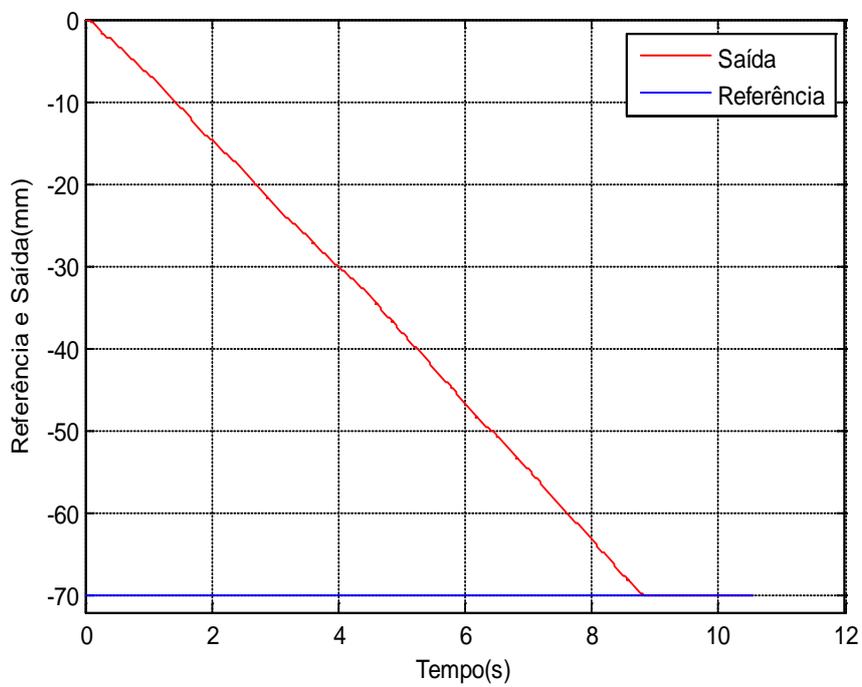


Figura 5.7 - Curvas de Resposta e de Referência ao Degrau de -70 mm da base Y

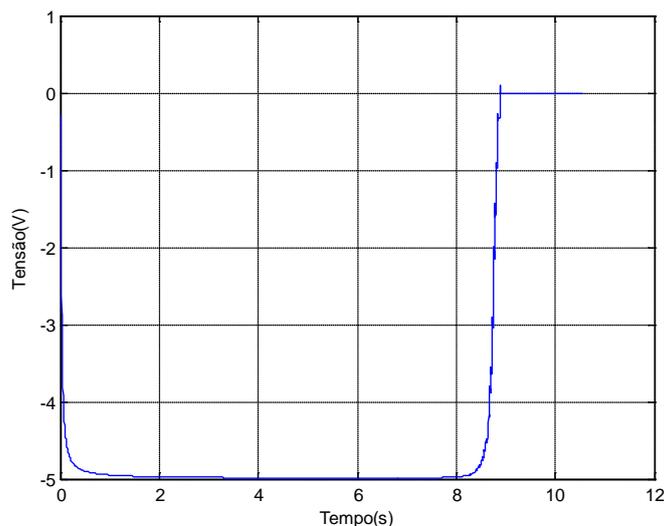


Figura 5.8 - Curva de Resposta da variável de controle da base X para uma Referência do tipo Degrau de -70 mm

Analisando as Figuras 5.5 e 5.7, é possível obter os tempos de assentamento T_s , ultrapassagem percentual %UP e os erros de regime permanente ess das curvas de resposta as referências. Esses dados, correspondentes à base Y, estão apresentados na Tabela 5.2.

Tabela 5.2 – Índices de desempenho experimentais extraídos das curvas de resposta da base Y

Valor medido	Figura 5.5	Figura 5.7
	Sinal de Referência	Sinal de Referência
	70 mm	-70 mm
T_s (s)	7, 808	8, 6504
UP (%)	0	0
ess (%)	0	0

Ainda foram realizados ensaios na base X com amplitudes de 10, -10, 20, -20, 30, -30, 40, -40, 50 e -50 mm. Na Tabela 5.3 pode-se observar os tempos de assentamento T_s (s), ultrapassagem percentual UP (%) e os erros de regime permanente ess (%) das curvas de resposta às referências supracitadas. Da mesma forma para base Y

pode-se observar, na Tabela 5.4, ensaios com amplitudes de 10, -10, 20, -20, 30, -30, 40, -40, 50 e -50 mm.

Tabela 5.3 – Índices de desempenho experimentais para degraus de amplitudes variadas extraídos das curvas de resposta da base Y

	Sinal de Referência	Sinal de Referência
Valor Medido	10 mm	-10 mm
T _s (s)	1,314	1,384
UP (%)	0,625	0,625
ess (%)	0	0
Valor Medido	20 mm	-20 mm
T _s (s)	2,788	2,488
UP (%)	0	0,3125
ess (%)	0	0
Valor Medido	30 mm	-30 mm
T _s (s)	3, 722	3,492
UP (%)	0	0
ess (%)	0	0
Valor Medido	40 mm	-40 mm
T _s (s)	4,375	4,785
UP (%)	0	0
ess (%)	0	0
Valor Medido	50 mm	-50 mm
T _s (s)	5,295	5,865
UP (%)	0	0
ess (%)	0	0

Tabela 5.4 – Índices de desempenho experimentais para degraus de amplitudes variadas extraídos das curvas de resposta da base Y

	Sinal de Referência	Sinal de Referência
Valor Medido	10 mm	-10 mm
Ts (s)	1,379	1,669
UP (%)	0,625	0,625
ess (%)	0	0
Valor Medido	20 mm	-20 mm
Ts (s)	2,408	3,048
UP (%)	0,3125	0,3125
ess (%)	0	0
Valor Medido	30 mm	-30 mm
Ts (s)	3,577	4,932
UP (%)	0	0
ess (%)	0	0
Valor Medido	40 mm	-40 mm
Ts (s)	4,601	6,286
UP (%)	0	0
ess (%)	0	0
Valor Medido	50 mm	-50 mm
Ts (s)	5,67	7,675
UP (%)	0	0
ess (%)	0	0

Com o intuito de verificar a eficiência dos controladores às perturbações, aplicou-se um degrau de referência com amplitude de 10 mm à base X. Logo após, foram aplicadas duas perturbações por meio da imposição de rotações ao eixo do motor

dessa base, através de um manípulo acoplado ao eixo do seu conjunto redutor. Para o referido degrau, forçou-se um deslocamento da base para direita até a posição 10,5 mm, e em seguida um deslocamento para esquerda até 9,625 mm. Após cada perturbação a base X retornou a posição inicial de 10 mm. Na Figura 5.9 é possível observar a curva. A Figura 5.10 mostra a variável de controle para esta situação.

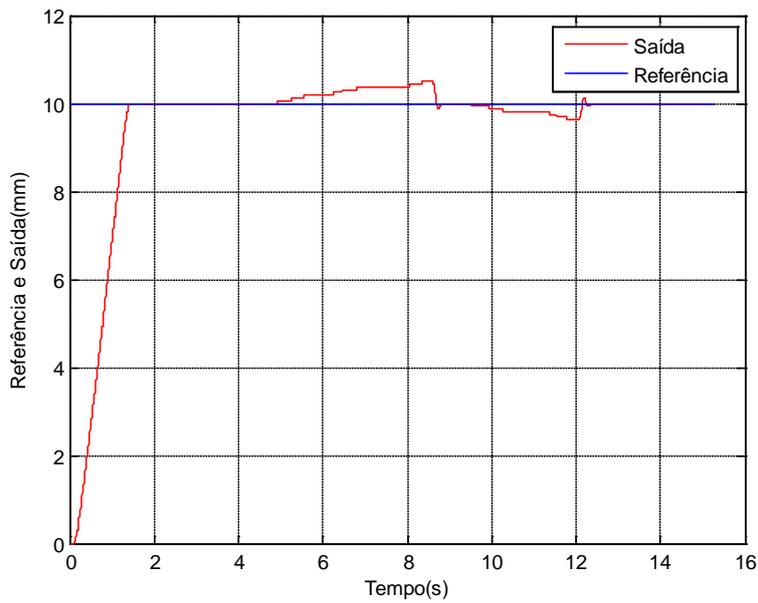


Figura 5.9 – Curva de Resposta e de Referência a Perturbações na base X

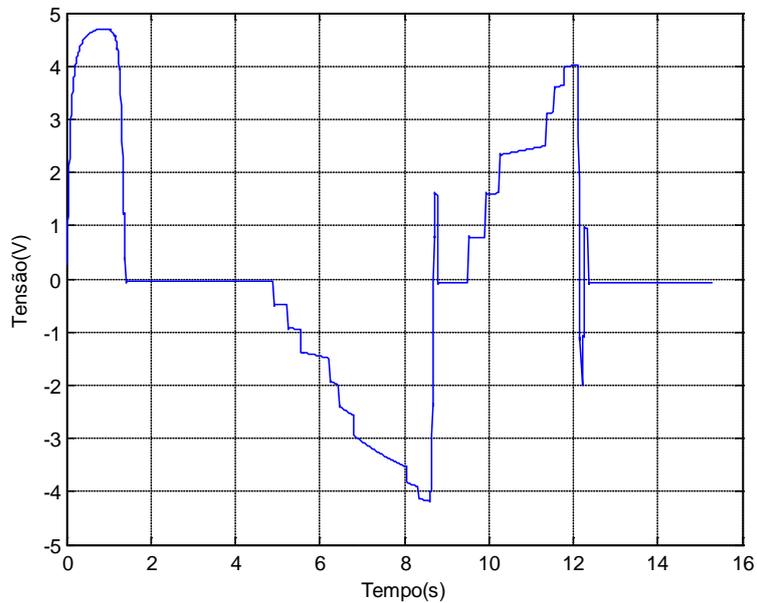


Figura 5.10 – Curva de resposta da variável de controle resultante das perturbações na base X

Da mesma forma foi verificado a eficiência do controle de sistema à perturbações para base Y. Dessa vez aplicou-se um degrau de referência de -10 mm a base Y e em seguida forçou-se um deslocamento da base para direita até a posição -10,4375 mm, e em seguida um deslocamento para esquerda até -9,4375 mm. Após cada perturbação a base Y retornou a posição inicial de -10 mm. Na Figura 5.11 é possível observar a curva de resposta às condições impostas. Na Figura 5.12 mostra a variável de controle para a situação descrita acima.

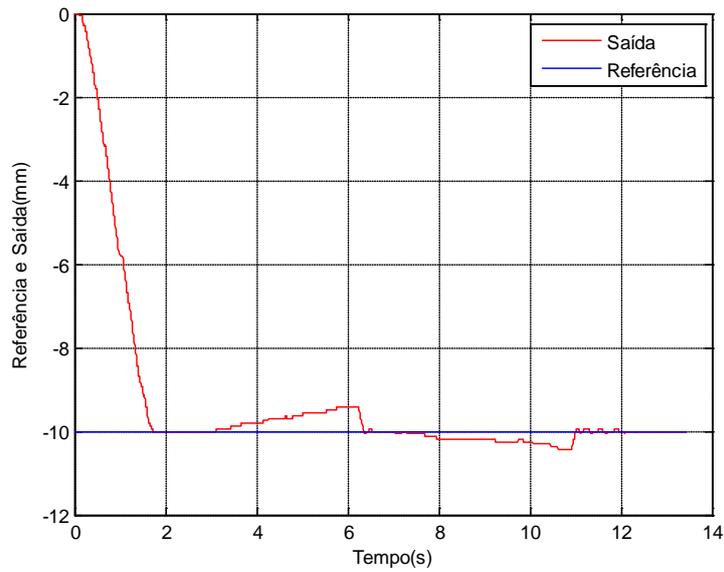


Figura 5.11 – Curva de Resposta e de Referência a Perturbações na base Y

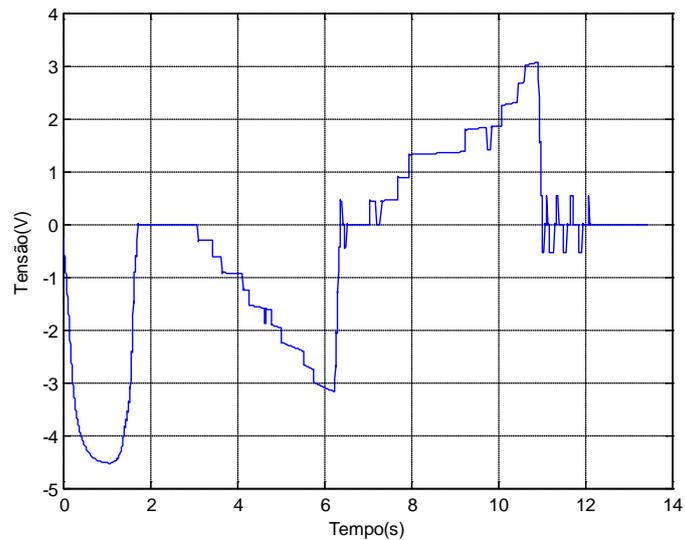


Figura 5.12 – Curva de resposta da variável de controle resultantes das Perturbações na base Y

Com o objetivo de verificar as respostas do sistema para referências distintas, ao longo dos cursos da mesa, foi aplicado uma sequência de degraus tanto na base X como na base Y. Degraus de referência com amplitudes variáveis de -10 mm, -20 mm, -30 mm, -40 mm, -50 mm e o retorno a posição inicial, foram impostos para base X. Para a base Y utilizou-se sinais de referência de 10 mm, 20 mm, 30 mm, 40 mm e 50 mm, retornando a sua posição inicial. Nas Figuras 5.13, 5.14, 5.15 e 5.16 encontram-se as curvas de resposta, da sequência de degraus de referência e da variável de controle, respectivamente, para base X e para a base Y, respectivamente.

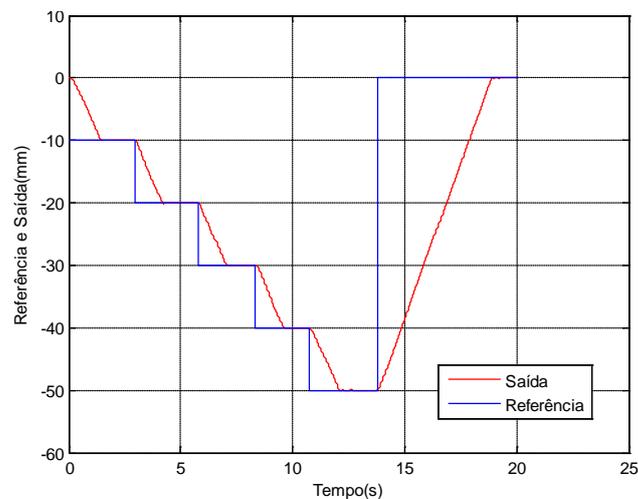


Figura 5.13 – Curvas de resposta e de referência degrau variável e retorno a posição inicial da base X

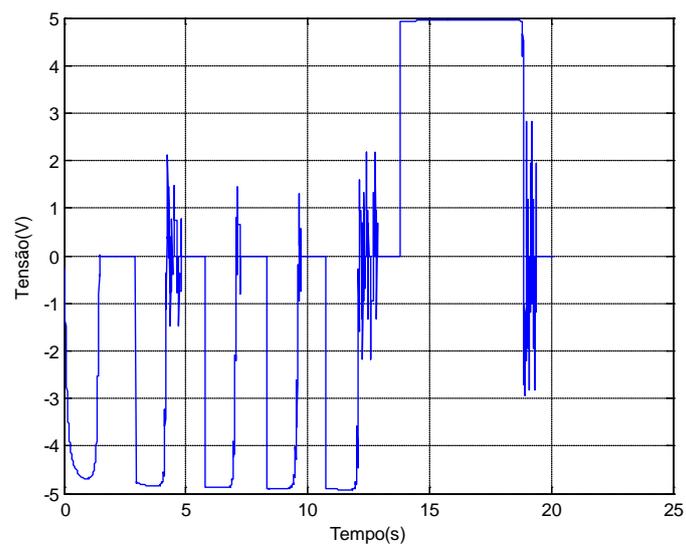


Figura 5.14 – Variável de controle para curva de resposta ao degrau variável e retorno a posição inicial da base X

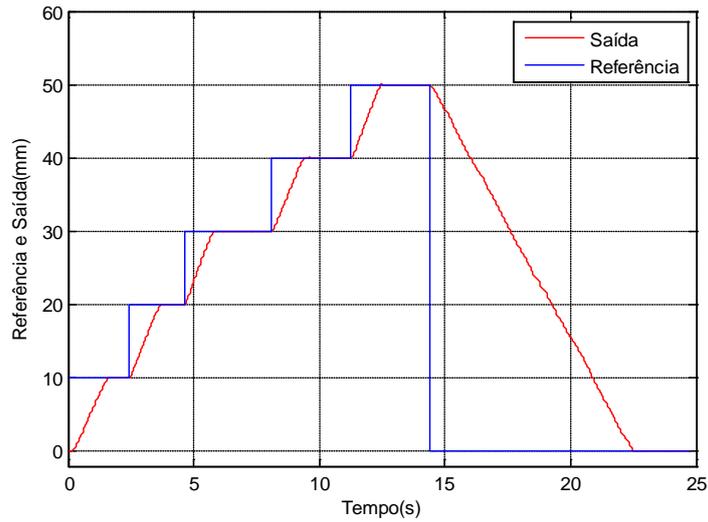


Figura 5.15 – Curvas de resposta e de referência degrau variável e retorno a posição inicial da base Y

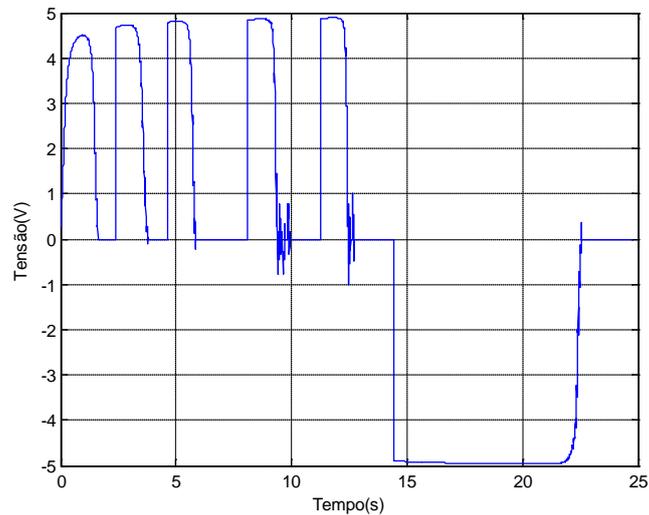


Figura 5.16 – Variável de controle para curvas de resposta ao degrau variável e retorno a posição inicial da base Y

A curva de resposta de posição do sistema apresentou erros de regime permanente nulos para as duas bases. Para base X a maior ultrapassagem foi de 1,245% e para base Y 0,625%.

5.3.2 Ensaios de Acionamento com Excitações do Tipo Seno e Cosseno

Com o objetivo de avaliar o controlador neural quanto ao acompanhamento de trajetórias, foram impostos acionamentos simultâneos da base X e Y com referências

senoidal e cossenoidal. Nesse caso, a mesa não sofreu interrupção no seu deslocamento ao atingir uma determinada posição, como no caso anterior, havendo, ao contrário, um movimento permanente, de acordo com a trajetória requerida.

No acionamento com as funções seno e cosseno, as referências de posição tiveram amplitudes de 15 mm para os períodos T de 160 s, 80 s, 40 s e 20s. Ambos os sinais de referência das bases tiveram seus valores compostos, transformando as suas resultantes de coordenadas retangulares para coordenadas polares, através do programa implementado no ambiente LabVIEW®, para a obtenção de uma referência em forma de uma circunferência, com diâmetro de 30 mm, centrada no ponto (0,0) mm do sistema.

A seguir, são apresentadas as curvas de resposta aos acompanhamentos de trajetória de cada base aos sinais senoidal e cossenoidal; assim como, o acompanhamento à composição dos sinais das bases, devido ao acionamento concomitante delas, o que gerou uma movimentação circular no espaço de trabalho da mesa.

Nas Figuras 5.17 e 5.18 são apresentados os sinais da curva de resposta e de referência para o acionamento da base X com uma função senoidal para um período de 160 segundos e a variável de controle, respectivamente.

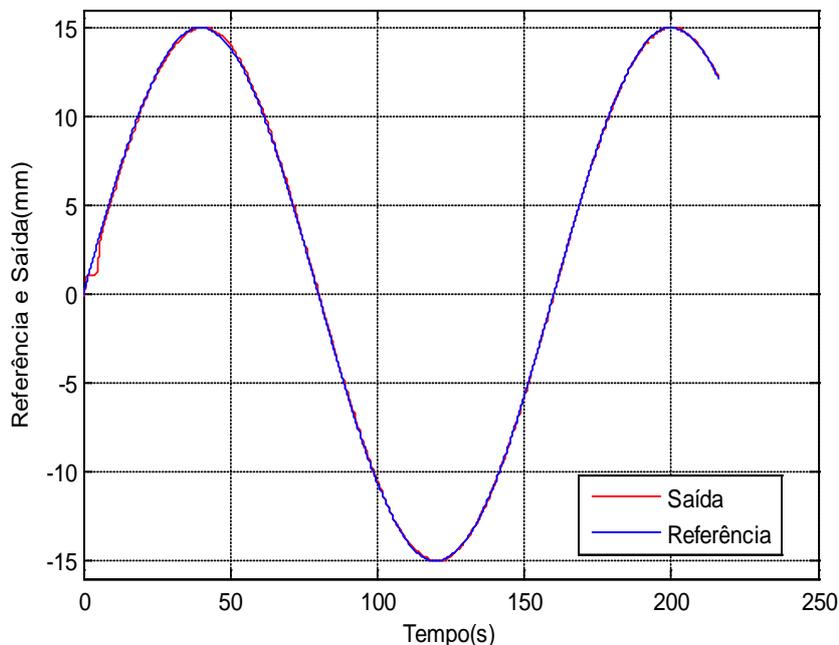


Figura 5.17 – Curvas de resposta e de referência senoidal da base X
(T = 160s)

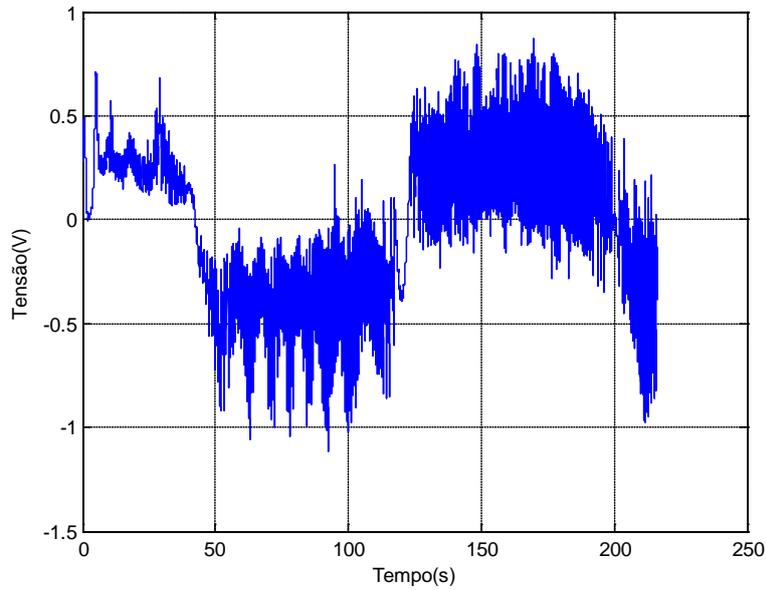


Figura 5.18 - Variável de controle para curva de resposta senoidal da base X
($T = 160$ s)

Na Figura 5.19 é apresentado os sinais da curva de resposta e de referência para o acionamento da base Y com uma função cossenoidal para um período de 160 segundos e na Figura 5.20 sua respectiva variável de controle.

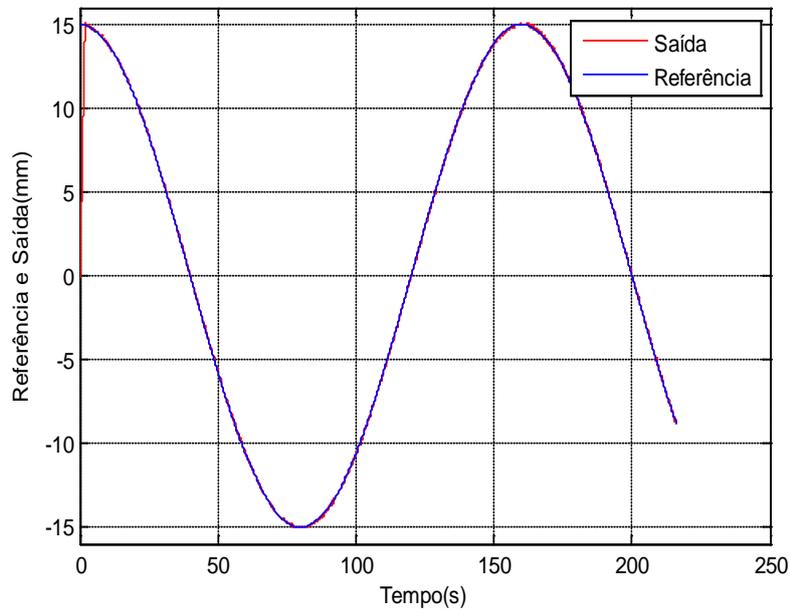


Figura 5.19 – Curvas de resposta e de referência cossenoidal da base Y
($T = 160$ s)

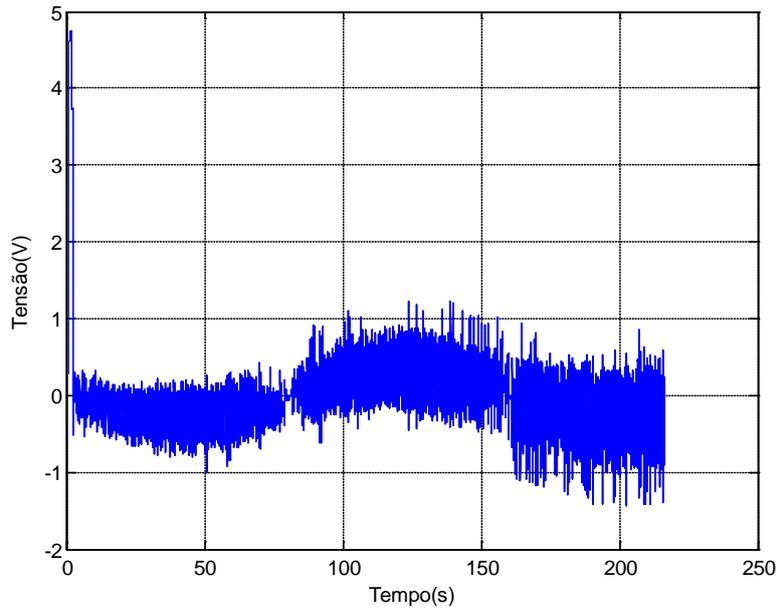


Figura 5.20 – Variável de controle para curva de resposta cossenoidal da base Y
($T = 160$ s)

Na Figura 5.21 é apresentado as curvas de resposta e de referência compostas pelas bases X e Y, para um período de 160 segundos.

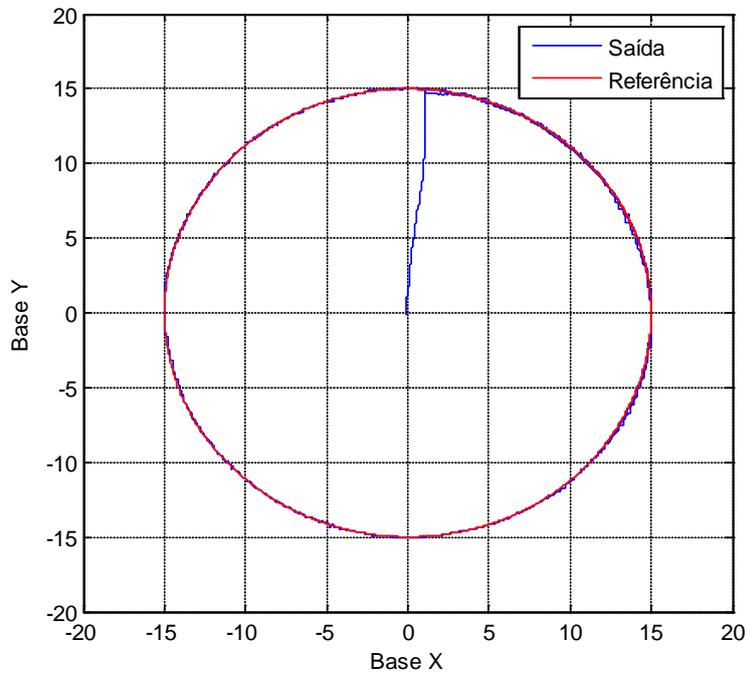


Figura 5.21 – Curvas de resposta e de referência, compostas pelas bases X e Y
($T = 160$ s)

Para um período de 80 segundos são mostrados nas Figuras 5.22 e 5.23 os sinais da curva de resposta e de referência para o acionamento da base X com uma função senoidal e a variável de controle, respectivamente.

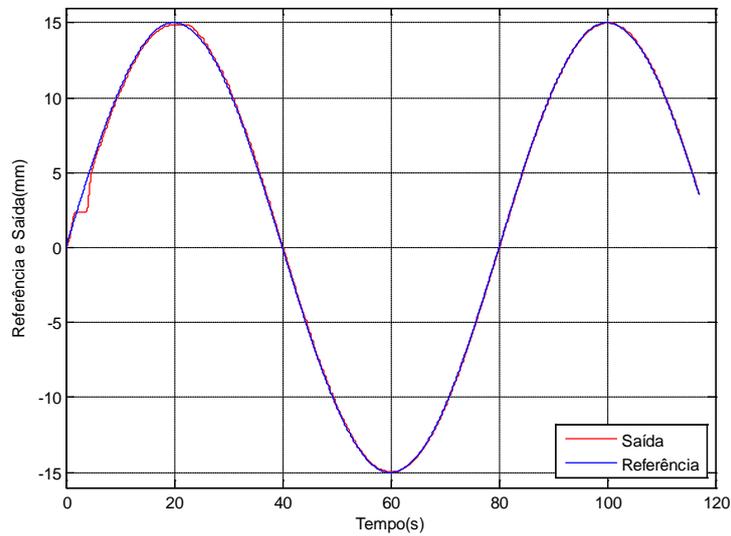


Figura 5.22 – Curvas de resposta e de referência senoidal da base X
($T = 80s$)

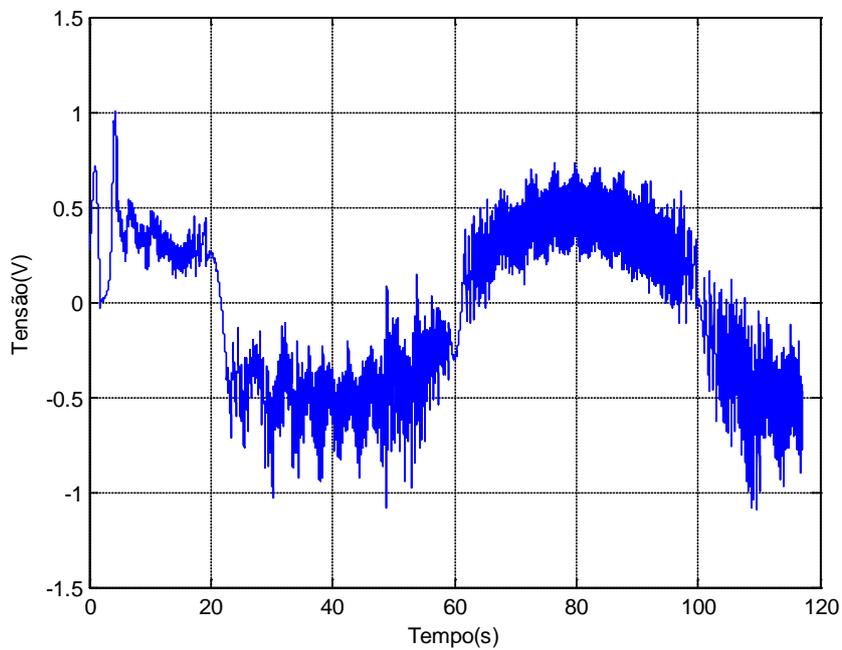


Figura 5.23 – Variável de controle para curva de resposta senoidal da base X
($T = 80s$)

Na Figura 5.24 são apresentados os sinais da curva de resposta e de referência para o acionamento da base Y com uma função senoidal para um período de 80 segundos e na Figura 5.25 sua respectiva variável de controle.

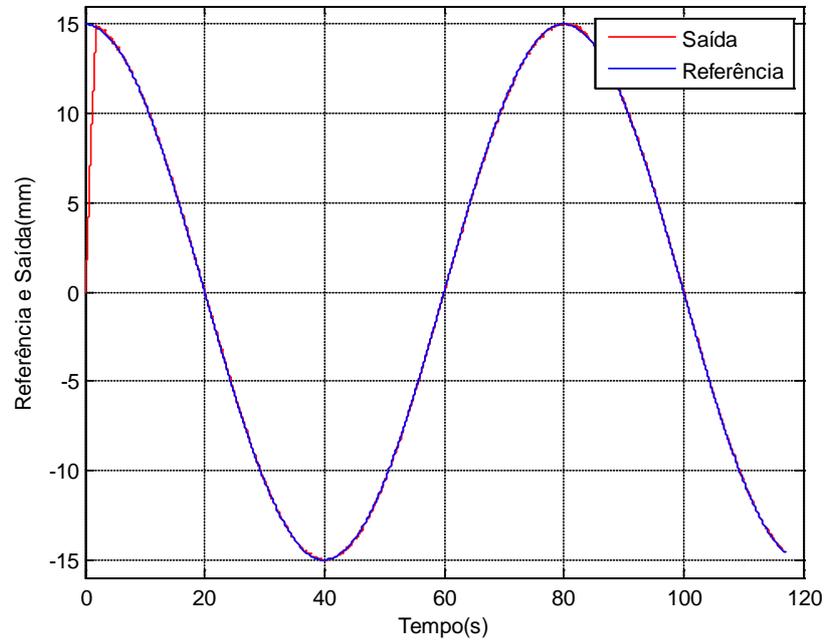


Figura 5.24 – Curvas de resposta e de referência cossenoidal da base Y
($T = 80s$)

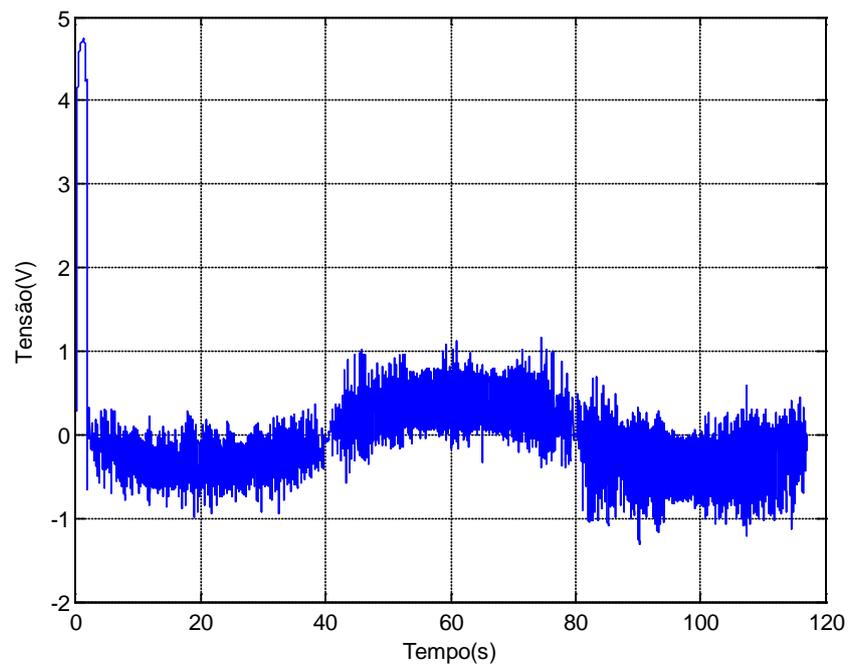


Figura 5.25 – Variável de controle para curva de resposta cossenoidal da base Y
($T = 80s$)

Na Figura 5.26 é apresentado as curvas de resposta e de referência compostas pela base X e Y para um período de 80 segundos.

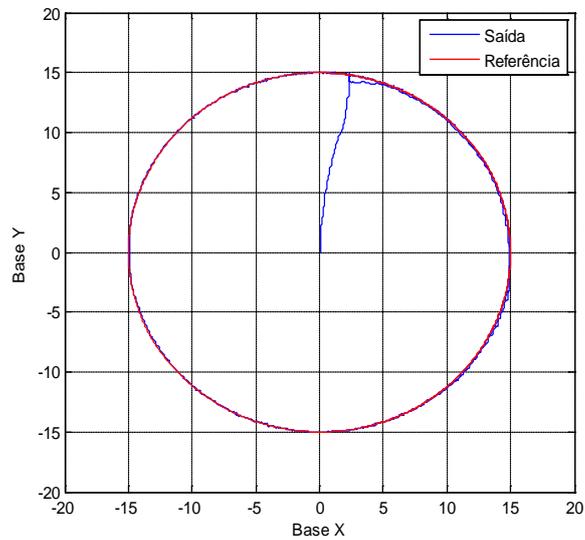


Figura 5.26 – Curvas de resposta e de referência, compostas pelas bases X e Y
($T = 80$ s)

Ainda foram realizados ensaios com amplitude de 15 mm para um período de 40 segundos. Nas Figuras 5.27 e 5.28 pode-se observar os sinais da curva de resposta e de referência para o acionamento da base X com uma função senoidal e sua respectiva variável de controle.

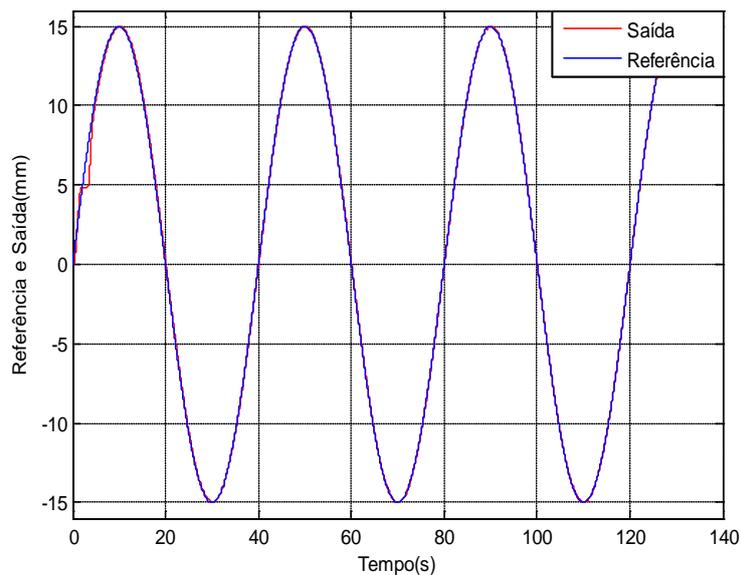


Figura 5.27 - Curvas de resposta e de referência senoidal da base X
($T = 40$ s)

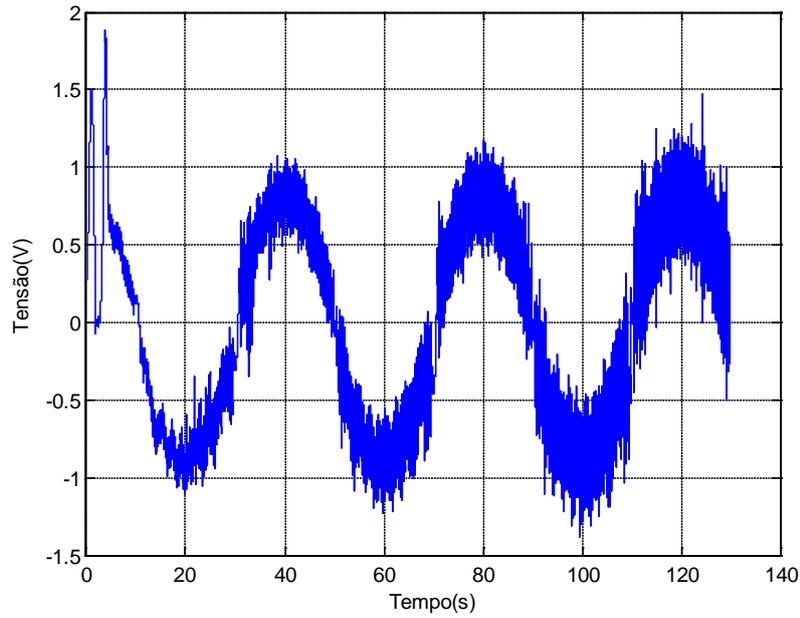


Figura 5.28 - Variável de controle para curva de resposta senoidal da base X
($T = 40$ s)

Nas Figuras 5.29 e 5.30 pode-se observar os sinais da curva de resposta e de referência para o acionamento da base Y com uma função cossenoidal e sua respectiva variável de controle para um período de 40 segundos.

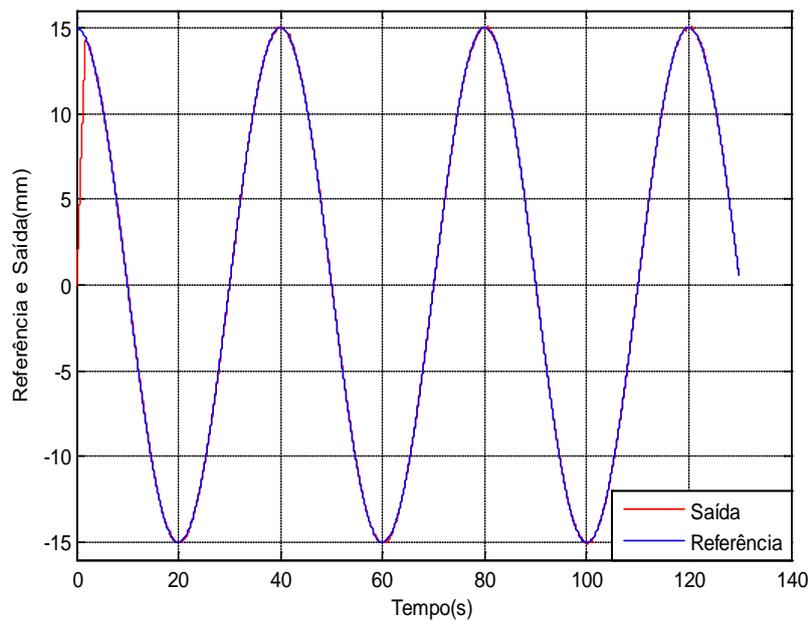


Figura 5.29 - Variável de controle para curva de resposta senoidal da base Y
($T = 40$ s)

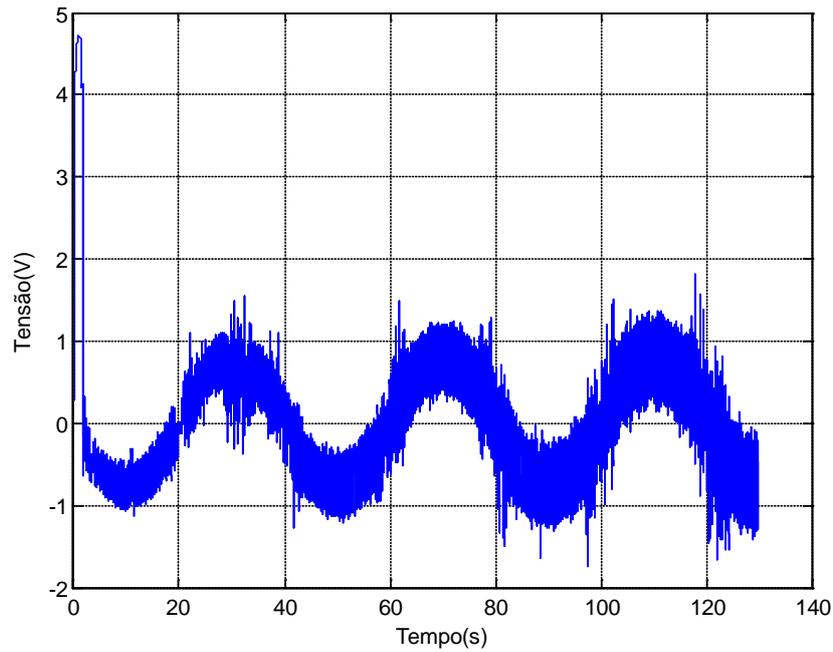


Figura 5.30 - Variável de controle para curva de resposta cossenoidal da base Y
($T = 40s$)

Na Figura 5.31 é apresentado as curvas de resposta e de referência compostas pela base X e Y. Por fim, o sistema foi acionado com uma amplitude de 15 mm para um período de 40 segundos.

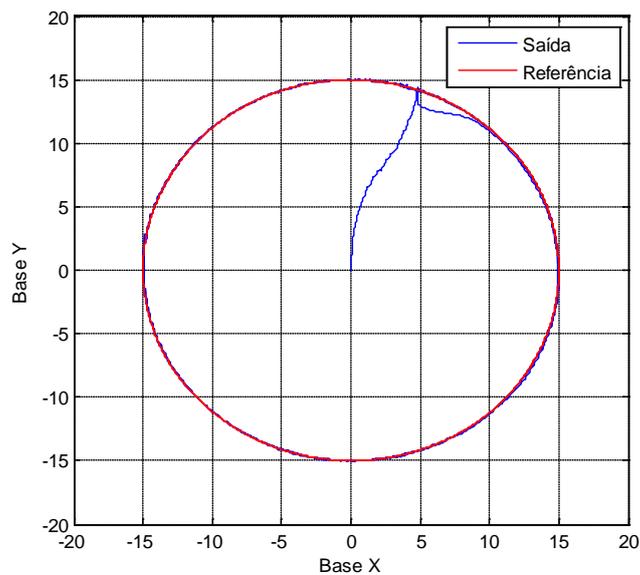


Figura 5.31 – Curvas de resposta e de referência, compostas pelas bases X e Y
($T = 40 s$)

Por fim, o sistema foi acionado com uma amplitude de 15 mm para um período de 20 segundos. Nas Figuras 5.32, 5.33, 5.34, 5.35 e 5.36, os sinais da curva de resposta e de referência para o acionamento da base X com uma função senoidal e sua respectiva variável de controle, os sinais da curva de resposta e de referência para o acionamento da base Y com uma função cossenoidal e sua respectiva variável de controle, e as curvas de resposta e de referência compostas pela base X e Y para um período de 20 segundos.

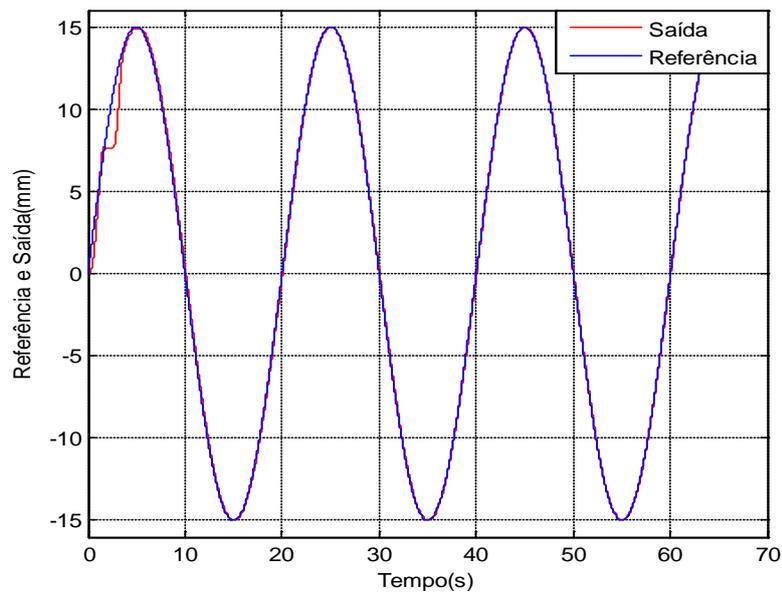


Figura 5.32 - Curvas de resposta e de referência senoidal da base X
($T = 20$ s)

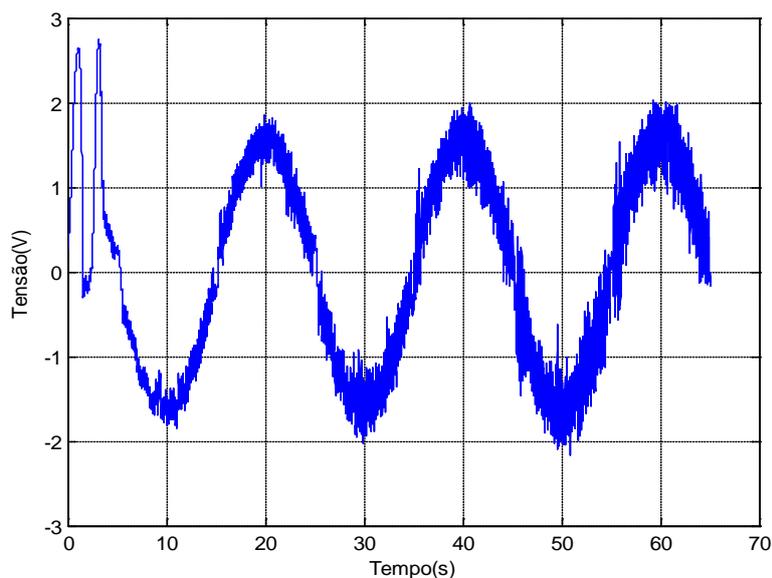


Figura 5.33 - Variável de controle para curva de resposta senoidal da base X
($T = 20$ s)

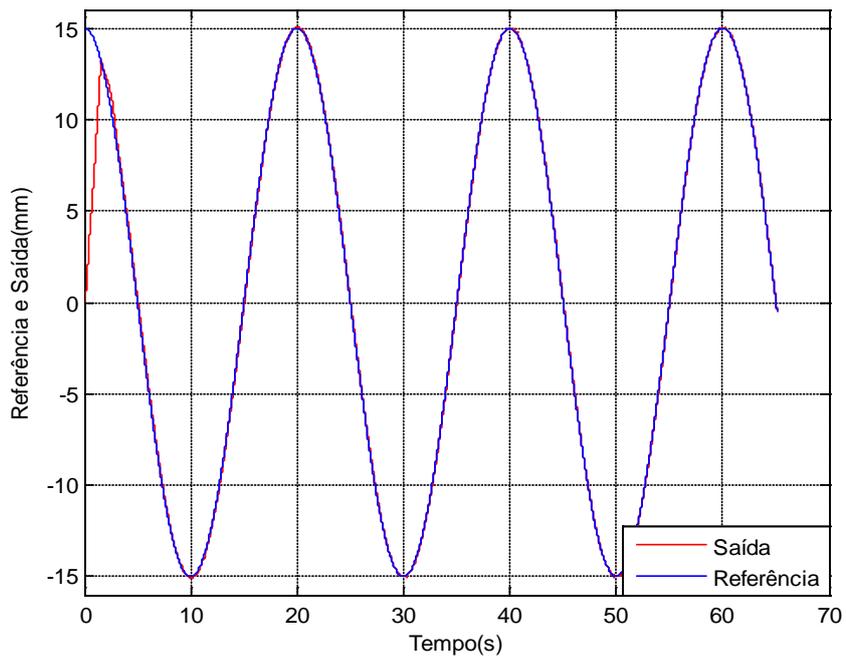


Figura 5.34 – Curvas de resposta e de referência cossenoidal da base Y
($T = 20$ s)

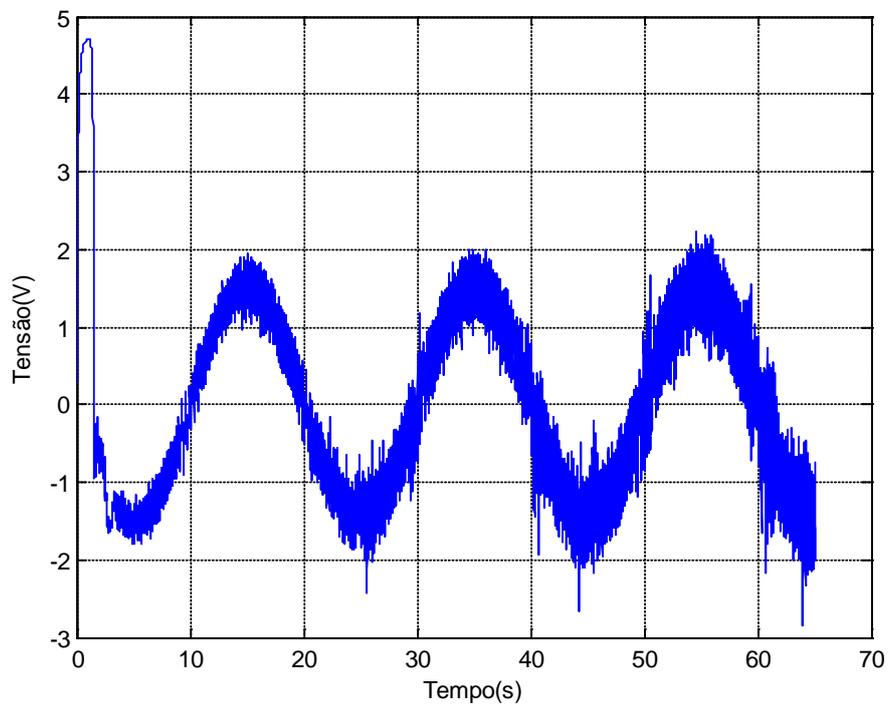


Figura 5.35 - Variável de controle para curva de resposta cossenoidal da base Y
($T = 20$ s)

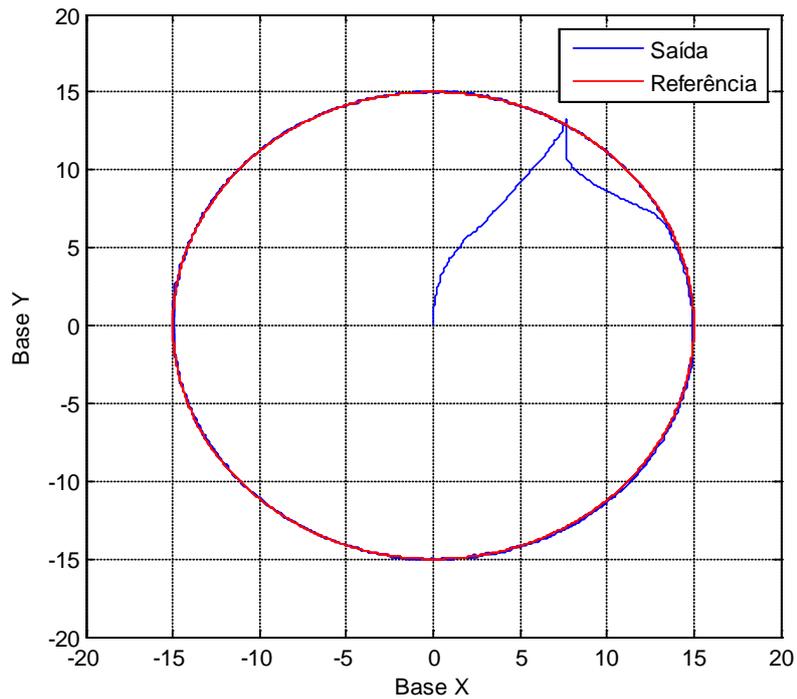


Figura 5.36 - Curvas de resposta e de referência, compostas pelas bases X e Y (T = 20 s)

Na Tabela 5.5 são mostrados os valores de erros máximos encontrados nos acionamentos da mesa de coordenadas X-Y com o controle neural.

Tabela 5.5- Valores experimentais do controle neural de posição para referências com funções circulares

Períodos dos sinais de referência	Erro máximo (%)	
	Base X	Base Y
Período 160 s	1,5	1,3
Período 80 s	1,9	2,1
Período 40 s	3,5	3,8
Período 20 s	4,2	4,5

Obs: * Resultados para as Figuras 5.17, 5.19, 5.22, 5.24, 5.27, 5.29, 5.32 e 5.34.
 ** Erro máximo calculado após o regime permanente de trabalho

A partir de período menor ou igual a 20 s, as curvas de saída senoidal e cossenoidal apresentaram erros percentuais maiores que 5% e, conseqüentemente, distorções na composição desses sinais de saída. Nas Figuras 5.37, 5.38 e 5.39 são apresentados os acionamentos com referência senoidal para base X e cossenoidal para base Y, bem como as curvas de resposta e de referência compostas pela base X e Y para um período de 5 segundos e amplitude de 10 mm.

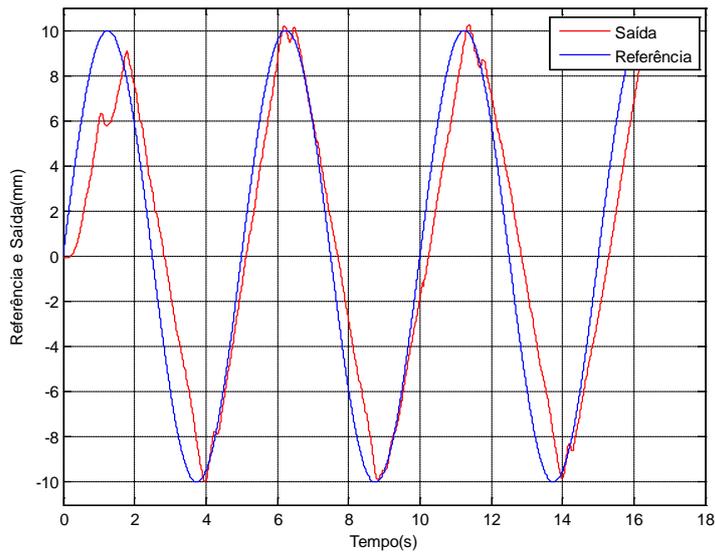


Figura 5.37 - Curvas de resposta e de referência senoidal da base X
($T = 5$ s)

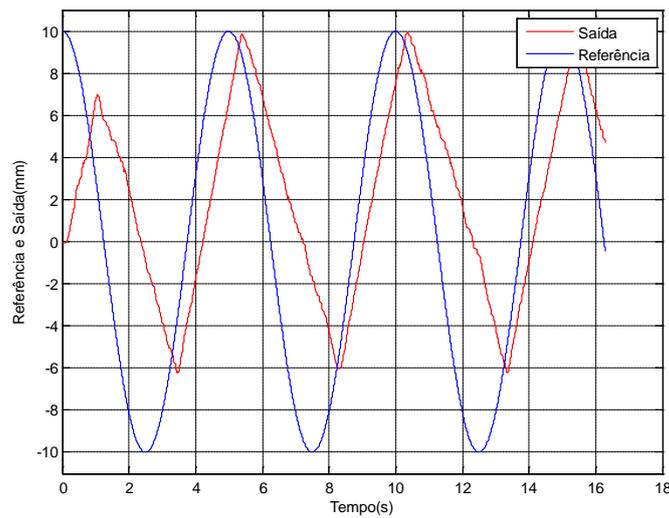


Figura 5.38 - Curvas de resposta e de referência cossenoidal da base Y
($T = 5$ s)

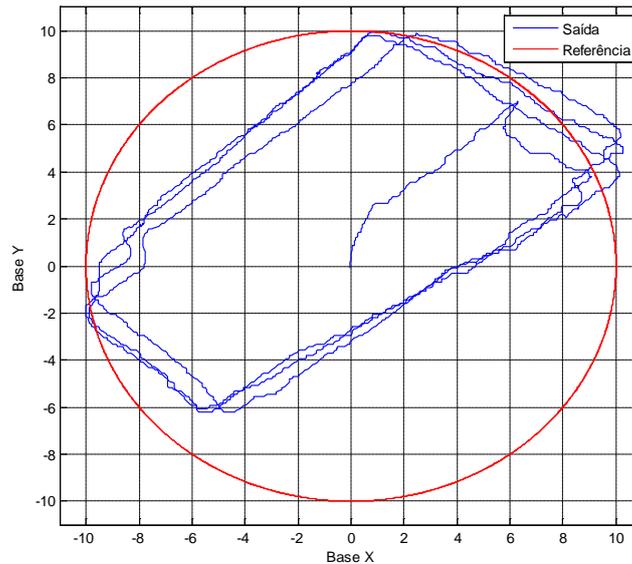


Figura 5.39 – Curvas de resposta e de referência, compostas pelas bases X e Y
($T = 5$ s)

5.4 COMENTÁRIOS E CONCLUSÕES

Neste capítulo, foram apresentados os resultados experimentais obtidos no controladores neurais do sistema.

Na análise das curvas de resposta ao degrau de referência, foram verificados desempenhos satisfatórios dos controladores neurais. Não houve erros de regime permanente, o único sobre-sinal ocorrido foi de 1,245%, entre as diversas determinações de controle de posicionamento por um sinal degrau variável, e o máximo tempo de assentamento foi de 11,685 s para um degrau de -100 mm para base X.

Nos ensaios de acompanhamento de trajetórias dos sinais de referência senoidal, cossenoidal e da composição desses dois sinais apresentaram resultados esperados nos períodos de 160 s, 80 s, 40 s e 20 s, principalmente para $T=160$ s. Para períodos maiores que esse último, os acompanhamentos de trajetória apresentam desempenhos cada vez melhores, devido às menores frequências das formas de onda. Em contrapartida, a partir de período menor ou igual a 20 s, as curvas de saída senoidal e cossenoidal apresentaram erros percentuais maiores que 5% e, conseqüentemente, distorções na composição desses sinais de saída.

CAPÍTULO VI

COMENTÁRIOS E CONCLUSÕES FINAIS

6.1 COMENTÁRIOS E CONCLUSÕES

Neste trabalho foi apresentada uma estratégia de acionamento de uma mesa de coordenadas, com dois graus de liberdade, acionada por motores de indução trifásicos. O controle foi exercido por controlador implementado em um ambiente computacional que integra programas LabVIEW® e MATLAB® instalados em um microcomputador do tipo PC . Para a determinação das posições de ambos os eixos da mesa foram confeccionados circuitos detectores de posição conhecidos pela denominação de encoders. Através da pesquisa bibliográfica efetuada é possível se observar que as máquinas ferramentas, na qual se enquadra a mesa de coordenadas são acionadas por dois tipos principais de controladores, o controle ponto a ponto, no qual tanto o caminho da ferramenta de um ponto de origem ao ponto de referência quanto à velocidade de deslocamento não são importantes e sistema de controle de contorno, no qual o caminho traçado pela ferramenta é de fundamental importância, sendo por este motivo a variável controlada, RAMESH, R. et al (2005).

No caso do acionamento em controle de posição, os resultados obtidos nas simulações e experimentalmente com o controlador neural não apresentaram erro de regime permanente e uma ultrapassagem percentual máxima de 1,245%. O controlador mostrou-se eficiente também no controle de posição na ocorrência de perturbações, retornando ao valor de referência com erro de regime permanente nulo.

Para o caso de acompanhamento de trajetórias de referências do tipo senoidais e cossenoidais, todas com uma amplitude de 15 mm e períodos variando entre 160 e 20

segundos, observou-se um desempenho esperado, com um erro máximo de 4,5% para um período de 20 segundos.

Quanto ao acompanhamento de trajetória para curvas de referência senoidais, cossenoidais e da composição desses dois sinais, o sistema também apresentou um desempenho esperado. Nos três períodos analisados, a presença de ruídos nas saídas se deveu a limitação da resolução dos detectores de posição. O melhor seguimento à trajetória ocorreu para $T=150$ s, devido a uma menor frequência dos sinais de referência.

Observa-se também que a rede neural multicamadas, com aprendizado realizado através da técnica de retropropagação do erro, atendeu aos objetivos propostos para um sistema de posicionamento acionado por motores de indução trifásicos.

6.2 PROPOSTAS PARA TRABALHOS FUTUROS

Propõem-se os seguintes trabalhos como continuação desta pesquisa:

- Desenvolver controladores neuro-fuzzy para controle do sistema de posicionamento;
- Desenvolver controladores neuro-genéticos para controle do sistema de posicionamento;
- Utilizar o método de controle vetorial, cuja atuação seria na saída resultante do funcionamento simultâneo das bases da mesa;
- Implementar o controle de posição por estimativa de posicionamento, sem o uso de detector de posição.

REFERÊNCIAS BIBLIOGRÁFICAS

- ACKLEY, D.H., HINTON, G.E., SEJNOWSKI, t.J., (1985). *A learning algorithm for boltzmann machines*, Cognitive Sci., vol 9, pp. 147 – 169.
- ADUSUMILLI, S.; RIVERA, D.E.; DASH, S.; TSAKALIS, K. (1998). *Integrated MIMO identification and robust PID controller design through loop shaping*, *Proceedings of the American Control Conference*, Vol. 2, Philadelphia, USA, pp. 1230-1234.
- AGUIRRE, L. A., 2000, *Introdução à Identificação de Sistemas: Técnicas Lineares e não-Lineares Aplicadas a Sistemas Reais*. 2ª Edição Belo Horizonte, MG UFMG.
- AJJANAGADDE, V.; SHASTRI, L., (1991). *Rules and Variables in neural nets*, *Neural Computation*, vol. 3, nº 1, pp. 121 – 134.
- ARCOS CAMARGO, M. A., 2002, *Planejamento de Trajetórias de um Manipulador Robótico Usando Redes Neurais Artificiais*. Dissertação de Mestrado, UNICAMP, Campinas, SP, Brasil.
- ASTROM, K. J. & WITTENMARK, B. , 1995. *Adaptive Control*. 2ª Edição USA, Editora Addison Wesley.
- BEZERRA, S. T. M., 2009, *Sistema Fuzzy para Controle Piezométrico de Sistemas de Distribuição de Água Visando à Economia de Água e Energia*. Tese de D.Sc., UFPB, João Pessoa, PB, Brasil.
- BONISSONE, P. P.; CHEN, Y.-T.; GOEBLE, K.; KHEDKAR, P. S. (1999). *Hybrid soft computing systems: industrial and commercial applications*, *Proceedings of the IEEE*, Vol. 87, No. 9, pp. 1641-1667.
- BORDON, M.E.,(2004).”*Controlador Nebuloso de Arquitetura Simplificada. Estudo de Caso: Acionamento de Motor de Indução Trifásico*”.Tese de Doutorado, Universidade Estadual de Campinas, Brasil.
- BRAGA, C. S., 2006, *Projetos de Controladores para uma Mesa de Coordenadas XY*

- usando Técnicas de Alocação de Pólos*. Dissertação de M.Sc., UFPB, João Pessoa, PB, Brasil.
- BUHLER, HANSRUEDI, 1982, *Réglages échantillonnés*, 1ª. Edição. Lausanne e Suisse Presses Polytechniques romandes.
- CAMARGOS, Fernando Laudares, 2002, “*Lógica Nebulosa: uma abordagem filosófica e aplicada*”, Artigo Publicado pela Universidade Federal de Santa Catarina (UFSC), Brasil.
- CAMBOIM, W. L. L., 2008, *Aplicações de Técnicas de Controle Fuzzy para Sistemas de Abastecimento de Água*. Dissertação de M.Sc., UFPB, João Pessoa, PB, Brasil.
- CAMPOS, M. M., SAITO, K., 2004, *Sistemas Inteligentes em Controle e Automação de Processos*, Rio de Janeiro, RJ, Brasil, Editora Ciência Moderna.
- CARVALHO, J. S. F., 2009, *Controle Adaptativo Aplicado em um Robô Manipulador de Dois Graus de Liberdade Planar*. Tese de D. Sc., UFPB, João Pessoa, PB, Brasil.
- CHEN , C. T. , 1995, *Analog and Digital Control System Desing - Transfer – Function , State - Space & Algebric Methods* - Oxford University Press, Inc. New York, USA.
- CHO, J., PRINCIPE, J. C., ERDOGMUS, D., MOTTER M. A., 2006, *Modeling and Inverse Controller Design for an Unmanned Aerial Vehicle Based on the Self-organizing Map*. IEEE Transactions on Neural Net-works, vol. 17, nº. 2, pp. 445-460.
- COELHO, L. S. (2001). *Metodologias de inteligência artificial aplicadas ao projeto de sistemas de controle e automação industrial*. Anais do ISA Show Brasil, São Paulo, SP.
- COELHO, L. S., & MARIANI V. C., 2006, *Sistema Híbrido Neuro-Evolutivo Aplicado ao Controle de um Processo Multivariável*. Revista Controle & Automação/Vol. 17, nº 1.
- COSTA, F.; OLIVEIRA, V. A. , 2002 , “ *Gain Scheduled Controllers for Dynamics System Using Sector Nonlinearities*”. Automatica.
- COX, E., 1999. “*The Fuzzy Systems Handbook*”. Chappqua, New York: AP Professional. Second Edition.
- DORF, R. C., 2001, *Sistemas de Controle Moderno*. São Paulo, SP. Brasil. Livraria LTC
- DUNKER, J., SCHERER, A.; SCHLAGETER, G., (1992). *Integrating Neural*

- Networks Into Distributed Knowledge Based Systems*, Proc of 12th conf. On AI, Expert Systems and Natural Language, Avignos, France.
- GARCES, F.; K. WARWICK; CRADDOCK, R. (1998). *Multiple PID mapping using neural networks in a MIMO steam generator system*, Control'98, International Conference on UKACC, Swansea, UK, Vol. 1, pp. 503-508.
- HAYKIN, S. (1999). *Neural Networks – A Comprehensive Foundation*, 2^a ed., Prentice-Hall, New York.
- HAYKIN, S., 2001, *Redes Neurais, Princípios e Prática*, Tradução de Paulo Martins Engel. 2^a Edição, Porto Alegre, RS - Brasil. Ed. Bookman.
- HEMERLY, E. M., 1996, *Controle Por Computador de Sistemas Dinâmicos*. S. Paulo, Brasil Ed.Edgard Blucher LTDA.
- HODGKIN, A. L. e HUXLEY, L. F. (1952). *A quantitative description of membrane current and its applications to conduction and excitation in nerve*. Journal of Physiology, vol. 117, pp. 500-544.
- ISERMANN, R., & LACHMANN, K, 1992, *Adaptive Control System*. Prentice Hall International.
- JÚLIO, E. F. X., 2010, *Controlador Fuzzy Aplicado a um Sistema de Controle Acionado por Motores de Indução Trifásicos*. Dissertação de M. Sc., UFPB, João Pessoa, PB, Brasil.
- KARR, C., (1991). *Design of na Adaptative Fuzzy Logic Controller Using a Genetic Algorithm*, Proceedings of Fourth Genetic Algorithms Conference, pp. 450 – 457.
- KHAN, J., WEI, J. S., RINGNÉR, M., SAAL, L. H., LADANYI, M., WESTERMANN, F., BERTHOLD, F., SCHWAB, M., ANTONESCU, C.R., PETERSON, C., MELTZER, P.S, 2001, *Classification and Diagnostic Prediction of Cancers Using Gene Expression Profiling and Artificial Neural Networks*. Nature Medicine, vol. 7, nº. 6, pp. 673 – 679
- KHOSLA, R.; DILLON, T. (1997). *Engineering intelligent hybrid multi-agent systems*, Kluwer Academic Publishers: Boston.
- KOVÁCS, Z. L ,1996, *Redes Neurais Artificiais: fundamentos e Aplicações*, São Paulo, Brasil, Editora Acadêmica.
- LIMA, F.M.C.,(2007).”*Desenvolvimento de um Sistema de Controle Fuzzy de Potencial Matricial da Água no Solo visando à Otimização de Processo de Irrigação*”.Tese de Doutorado. UFPB, Brasil.

- MARIANO, V. 2005 , *Controle Adaptativo de Eixo Posicionador de Máquina - Ferramenta pelo método de Lyapunov*. Tese de Doutorado. UFPB, Brasil.
- MCCULLOCH, W. S. e PITTS, W. (1943). *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics, vol. 5, pp. 115-133.
- MENDES, A. S., 2009, *Algoritmos Meméticos Aplicados aos Problemas de Sequenciamento em Máquinas*. Tese de Mestrado, FEEC/UNICAMP, Campinas, SP, Brasil.
- MENEZES FILHO, J. B., 2007, *Controlador Neural Adaptativo para Mesa de Coordenadas*. Tese de D.Sc., UFPB, João Pessoa, PB, Brasil.
- MONTANA, D.; DAVIS, I.,(1989). *Training Feedforward neural networks using genetic algorithms*. Proceedings of 11th International Joint Conference on Artificial Intelligence, pp. 762 – 767.
- MONTENEGRO, P. H. M., 2007 , *Controle de Temperatura de ar em um Túnel Psicométrico por meio de técnicas adaptativas*. Tese de Doutorado. UFPB, Brasil.
- NASCIMENTO J, C. L., YONEYAMA, T. 2000 , *Inteligência Artificial em Controle e Automação*. São Paulo, Brasil. Editora Edgard Blucher.
- OGATA, K., 2003 , *Engenharia de Controle Moderno*. Tradução de Bernardo Severo São Paulo Brasil Editora LTC.
- ONO, H.; SONODA, T.; MAEKAWA, A. (2000). *Automatic tuning of PID controllers for MIMO processes*, IFAC Workshop of Digital Control: Past, Present and Future of PID Control, Terrassa, Spain, pp. 79-84.
- ORTEGA, A. V., SILVA, I. N., 2008, *Neural Network Model for Designing Automotive Devices Using SMD LED*. International Journal of Automotive Technology), vol. 9, nº. 2, pp. 203-210.
- PARASKEVOPOULOS, P.N., 1995, *Digital Control Systems*. First Edition, Prentice Hall, USA.
- PATETE, A., FURUTA, K., TOMIZUKA, M., 2008, “*Self-Tuning Control Based on Generalized Minimum Variance Criterion for Auto-Regressive Models*”, Automatica, v. 44, n. 8, pp. 1970-1975.
- PHILLIPS C. L., & HARBOR, R. D., 1997 , *Sistemas de Controle e Realimentação*. São Paulo, Brasil, Makron Books do Brasil .

- PIRES, M. G., 2009, *Abordagem Neuro-Genética Para Mapeamento de Problemas de Conexão em Otimização Combinatória*. Tese de Doutorado, EESC/USP, São Carlos, SP, Brasil.
- R.RAMESH, M.A.MANNAN,A.N.POO, 2005, . “*Tracking and contour error Control in CNC Servo Systems*”. International Journal of Machine Tools and Manufacture pp 301– 326.
- RICHTER, T., 2009, *Arquitetura de Sistema Inteligente Para Sensoriamento Virtual de Oxigênio em Veículos Bicombustíveis*. Dissertação de Mestrado, EESC/USP, São Carlos, SP, Brasil.
- RIUL, J. A., 2000 , *Controladores Neurais e Híbrido Aplicados em uma Carga acionada por um Atuador Hidráulico*. Tese de Doutorado. UFPB, Brasil.
- RUMELHART, D.; McCLELLAND, J., (1986). *Parallel distributed processing – explorations in the microstructure of cognition*, ed. David E. Rumelhart and James I. McClelland, MIT Press Cambridge, MASS, vol 1.
- SCHREINEMAKERS, J.F.; TOURETZKY, D.,(1990). *Interfacing a neural network with a rule based reasoner for diagnosis mastitis*, Proceedings of International Joint Conference of Neural Networks, Washington, pp. 487 – 490.
- SENG, T. L.; KHALID, M. B.; YUSOF, R. (1999). *Tuning of a neuro-fuzzy controller by genetic algorithm*, IEEE Transactions on Systems, Man, and Cybernetics. Part B: Cybernetics, Vol. 29, No. 2, pp. 226-236.
- SHAHIAN,B. HASSUL,M., 1993 , *Control System Design*. USA,Prentice Hall, USA.
- SOUZA, O. B., 2010, *Controle Adaptativo Aplicado em Dois Elos de um Robô Manipulador Eletropneumático de Três Graus de Liberdade Cartesiano*. Dissertação de M. Sc., UFPB, João Pessoa, PB, Brasil.
- SOUZA, S. A., 2008, *Algoritmos Genéticos Aplicados à Proteção e Estimação de Harmônicos em Sistemas Elétricos de Potência*. Tese de Doutorado, EESC/USP, São Carlos, SP, Brasil.
- VARGAS, E. T., 2005, *Uma Proposta de Relé Digital de Frequência Baseado em Algoritmos Genéticos*. Dissertação de Mestrado, EESC/USP, São Carlos, SP, Brasil.
- VICENTE, B. G. L. Z., CEZARE, M. J., SILVA, I. N., 2007, *Controlador Neural de Marcha Lenta Para Motores de Combustão Interna*. Anais do VIII Simpósio Brasileiro de Automação Inteligente, Florianópolis, CD-ROM (paper N°. 30909).

- ZUBEN, F. J. V., 1993, *Redes Neurais Aplicadas Ao Controle de Máquina de Indução*, Tese de Doutorado. UNICAMP, Brasil.
- YAN, H., JIANG, Y., ZHENG, J., PENG, C., LI, Q., 2006, *A Multilayer Perceptron-based Medical Decision Support System for Heart Disease Diagnosis*. *Expert Systems with Applications*, vol. 30, nº. 2, pp. 272-281.
- ZADEH, L. A., 1973, “*Outline of a New Approach to the Analysis of Complex Systems and Decision Process*”, *IEEE Trans. on Systems, Man and Cybernetics*, v. 3, pp. 28-44.
- ZADEH, L. A., 1965. *Fuzzy sets*. *Information and Control*, 8:338–353.