

**UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS**

Henry Pizarro Viveros

**Aplicação de Algoritmo de Controle Preditivo Neural
NNMPC em Mancal Híbrido Ativo**

São Carlos

2018

Henry Pizarro Viveros

**Aplicação de Algoritmo de Controle Preditivo Neural
NNMPC em Mancal Híbrido Ativo**

Tese apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, para obtenção do título de Doutor em Ciências - Programa de Pós-Graduação em Engenharia Mecânica.

Área de concentração: Dinâmica das Máquinas e Sistemas

Orientador: Prof. Assoc. Rodrigo Nicoletti

**ESTE EXEMPLAR TRATA-SE DA VERSÃO
CORRIGIDA. A VERSÃO ORIGINAL
ENCONTRA-SE DISPONÍVEL JUNTO
AO DEPARTAMENTO DE ENGENHARIA
MECÂNICA DA EESC-USP.**

**São Carlos
2018**

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes e
Seção Técnica de Informática, EESC/USP com os dados fornecidos pelo(a) autor(a).

P695a Pizarro-Viveros, Henry
Aplicação de algoritmo de controle preditivo neural
NNMPC em mancal híbrido ativo / Henry Pizarro-Viveros;
orientador Rodrigo Nicoletti. São Carlos, 2018.

Tese (Doutorado) - Programa de Pós-Graduação em
Engenharia Mecânica e Área de Concentração em Dinâmica
das Máquinas e Sistemas -- Escola de Engenharia de São
Carlos da Universidade de São Paulo, 2018.

1. controle preditivo. 2. redes neurais. 3.
identificação de sistemas. 4. mancal ativo. 5. mancal
híbrido. I. Título.

Bibliotecário responsável pela estrutura de catalogação da publicação:

Eduardo Graziosi Silva - CRB - 8/8907

FOLHA DE JULGAMENTO

Candidato: Bacharel **HENRY PIZARRO VIVEROS**.

Título da tese: "Aplicação de algoritmo de controle preditivo neural NNMPC em mancal híbrido ativo"

Data da defesa: 22/02/2018

Comissão Julgadora:

Resultado:

Prof. Associado **Rodrigo Nicoletti (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

Aprovado

Profa. Dra. **Maíra Martins da Silva**
(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Dr. **Adelmir Aparecido Cavallini Junior**
(Universidade Federal de Uberlândia/UFU)

APROVADO

Prof. Dr. **Helio Fiori de Castro**
(Universidade Estadual de Campinas/UNICAMP)

APROVADO

Prof. Dr. **Flávio Yukio Watanabe**
(Universidade Federal de São Carlos/UFSCar)

APROVADO

Coordenador do Programa de Pós-Graduação em Engenharia Mecânica:
Prof. Associado **Gherhardt Ribatski**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Luis Fernando Costa Alberto**

Este trabalho é dedicado ao esforço e ao apoio incansável da minha Mãe Filomena. As minhas irmãs Yuri, Lizbeth e Jeniffer. Aos meus anjos do céu, Juana e Cesar. A minha querida família, minha amada Ceci e meus filhos, Johana, Camilo e Nataly.

AGRADECIMENTOS

A Deus! Pela oportunidade maravilhosa de compartilhar junto à minha família a experiência mais linda das nossas vidas no Brasil.

À minha esposa Ceci, pelo amor, carinho e principalmente por ser o maior suporte nos momentos difíceis, me mostrando a sua fortaleza quando nós mais precisávamos "*esta conquista también es tuya mi amor!!*". Aos meus filhos, Johana, Camilo e Nataly pela grata companhia, pela compreensão e pelos abraços que me estimularam para a culminação deste trabalho.

Aos meus amigos em São Carlos, importante suporte que recarregaram as minhas energias sempre: Marília, Vanessa, Gian Franco, Esteban, Avatar, aos Chinos, Daniel Biscoito, Saky, Paulo, Dante, Lito, Carlitos, Ana Cecília, Rosamel, Paty e Norbil, Jaime e Pilar, Soledad e Edwin, Chucho e Carolina, Marcia e Felipe, Luis Enrique e Irma, Fiorela e Charlie, Marcelo Sorigotti e Sandra. E a todas as meninas e meninos que frequentavam a minha casa para desfrutar dos costumes da nossa querida terra.

À Escola de Engenharia de São Carlos da Universidade de São Paulo - EESC/USP. Aos Professores do Departamento de Engenharia Mecânica, Paulo Varoto, Marcelo Trindade, Adriano Siqueira, Glauco Caurin, Maíra da Silva, Leopoldo de Oliveira, Gherhardt Ribastki e Rodrigo Nicoletti. Aos funcionários da Pós-graduação e do Laboratório de Dinâmica (LabDin): Ana Paula Bardelotte, Iara Alice de Oliveira, José Francisco de Moraes (Xina), Diego Antonietti, Sérgio Ferreira e o Leandro Pedrassolli. Minha eterna gratidão para Cristina M. P. Fonseca pelo apoio oferecido a todo momento. Aos meus amigos do LabDin, pelas horas de futebol, divertidas conversas e os litros de cafezinho: Jaime Mosquera, Fabio de Melo, Iran Filgueira, Rafael Avanço, Kleber Rodrigues, Willians Godoy, Ricardo Nozaki, Ricardo Alvarez, Augusto Shigueoka, Jelder Quiñones, Gerson Trujillo, Sérgio Rangel e Andres.

Um agradecimento especial ao Prof. Maciej Ławryńczuk do Instituto de Engenharia de Computação e Controle da Universidade Tecnológica de Varsóvia da Polônia (*Institute of Control and Computation Engineering - Warsaw University of Technology - WUT*), que contribuiu significativamente no desenvolvimento desta tese com sugestões e materiais importantes.

Um eterno agradecimento ao meu orientador, Prof. Assoc. Rodrigo Nicoletti, por acreditar em mim, pela amizade, pelos ensinamentos, pela formação que recebi e principalmente pela ajuda e compreensão que teve para a culminação da minha tese de doutorado. Tentarei incansavelmente me espelhar no professor!

Minha eterna gratidão à cidade de São Carlos-SP, pelos maravilhosos anos que morei lá junto com a minha família, desfrutando da hospitalidade e as inúmeras amizades. Nós te amamos Sanca!

Ao Programa Estudante-Convênio de Pós-Graduação (PEC-PG) da CAPES pelo suporte financeiro que foram fundamentais no desenvolvimento e culminação deste trabalho.

RESUMO

PIZARRO-VIVEROS, H. **Aplicação de Algoritmo de Controle Preditivo Neural NNMPC em Mancal Híbrido Ativo**. 2018. 103p. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2018.

As inúmeras aplicações industriais mostram a grande importância de máquinas rotativas nas diversas etapas do sistema produtivo e também as sérias consequências econômicas por eventuais mau funcionamento. O mancal é o elemento principal que define as características dinâmicas de máquinas rotativas e são projetados para trabalhar em determinada faixa de operação que em situações imprevistas pode não ser as mais apropriadas. Através do controle ativo é possível alterar as características dinâmicas do mancal e reduzir possíveis instabilidades do sistema melhorando a faixa de operação. Nesse intuito, é proposto o algoritmo de controle preditivo neural (*Neural Network Model Predictive Control-NNMPC*) que precisa de uma identificação neural da planta para prever as saídas futuras do sistema e assim resolver o problema de otimização quadrática para calcular os sinais de controle ótimos. Assim, será controlado o deslocamento do rotor sob uma trajetória de referência. O primeiro algoritmo estudado foi o NNMPC-SISO. O processo de identificação neural do sistema foi realizado a partir de dados numéricos do sistema obtidos das equações não-lineares representadas em Simulink para uma velocidade de rotação fixa de 30 Hz (1800 rpm). O segundo algoritmo estudado foi o NNMPC-MIMO. Para a identificação multivariável da planta, utilizaram-se dados experimentais obtidos da bancada de testes para diferentes amplitudes de excitação a uma velocidade de rotação fixa de 20 Hz (1200 rpm). Esta identificação foi mediante uma rede neural NARX MIMO que utilizou as entradas de excitação u_1 e u_2 e novas entradas adaptadas as formas das equações não-lineares do sistema. Os resultados do algoritmo NNMPC-SISO mostraram que para a identificação o número de neurônios necessários foi de 10 e o algoritmo de treinamento foi o Levenberg-Marquardt. O controle do deslocamento do rotor sob a trajetória de referência foi aceitável mesmo em condições de perturbação externa ou velocidades de rotação não consideradas no treinamento da rede neural (20 e 40 Hz). Os resultados do algoritmo NNMPC-MIMO para a identificação multivariável mostraram que o incremento de entradas resultou numa melhoria significativa no processo de identificação porque conseguiu-se melhorar a generalização do conhecimento das características não-lineares da planta. Para tanto, foram necessários 20 neurônios e o algoritmo de treinamento Regularização Bayesiana. Já o controle foi capaz de manter o deslocamento do rotor na trajetória de referência em qualquer quadrante desejado mesmo considerando o distúrbio por desbalanceamento e o ruído.

Palavras-chave: Controle preditivo neural. Identificação sistemas não-lineares. Mancal híbrido ativo.

ABSTRACT

PIZARRO-VIVEROS, H. **Application of the Neural Network Model Predictive Control Algorithm to Active Hybrid Bearing**. 2018. 103p. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2018.

The numerous industrial applications show the great importance of rotary machines in the various stages of the production system and the serious economic consequences due to possible malfunctions. The bearing is the main element that defines the dynamic characteristics of the rotary machines and are design to work in a certain operating range. The active control changes the dynamic characteristics of the bearing and reduces possible instabilities of the system improving operating range. The neural network model predictive control algorithm (NNMPC) that uses of a neural network for identification of the nonlinear plant model. Hence, it calculates future control signals solving online for at each sampling instant a quadratic optimization equations based on the error between the nonlinear predictions and the reference trajectory in a horizon of prediction. The first algorithm studied was the SISO-NNMPC. The process identification using neural network carried out from numerical dataset. These values obtained from the nonlinear equations represented in Simulink model for a fixed rotation speed of 30 Hz (1800 rpm). The second algorithm studied was the MIMO-NNMPC. For the multivariable identification of the plant, we used experimental datasets. These values obtained from the test rig for different excitation amplitudes for a fixed rotation speed of 20 Hz (1200 rpm). The multivariable identification used a neural MIMO NARX model. Initially used two datasets (u1 and u2) and later that used nine new inputs with nonlinear equations forms of the plant. The non-linear identification of the SISO NARX results showed that needed 10 neurons were and the levenberg-marquardt training algorithm. The control of rotor displacement for reference trajectory was acceptable even in disturbance conditions or speeds of rotation not considered in the neural network training (20 and 40 Hz). The nonlinear multivariable identification of the MIMO NARX results showed that increment of nine new data sets significant improvement in the nonlinear identification process because improve generalization capability of the neural network MIMO NARX. The nonlinear multivariable identification results showed that necessary 20 neurons and Bayesian Regularization training algorithm. The control of rotor displacement was acceptable even in disturbance and noise condition.

Keywords: Model predictive control. Neural networks. Hydrodynamic-magnetic bearing.

LISTA DE FIGURAS

Figura 1.1 – Mancal hidrodinâmico segmentado com atuadores eletromagnéticos (mancal híbrido ativo).	3
Figura 2.1 – Mancal Híbrido Ativo (MHA) com os quatro atuadores eletromagnéticos embarcados nas sapatas e com o eixo.	7
Figura 2.2 – Bancada experimental do MHA: (1) Eixo, (2) mancal de rolamento autocompensador, (3) mancal hidrodinâmico com atuadores embarcados, (4) motor elétrico, (5) junta universal, (6) mesa inercial, (7) sensor de proximidade, (8) mancal de excitação, (9) unidade hidráulica, (10) sistema trocador de calor.	9
Figura 2.3 – Versão atual do MHA com novos atuadores: (a) mancal híbrido com os quatro atuadores eletromagnéticos montados no interior; (b) atuador eletromagnético embarcado na sapata de formato “E”.	9
Figura 3.1 – Estrutura básica do controle MPC.	12
Figura 3.2 – Princípio do controle preditivo: (a) trajetória predita $\hat{y}(k+1 k), \dots, \hat{y}(k+N k)$ e a trajetória de referência $y^{ref}(k+1 k), \dots, y^{ref}(k+N k)$; (b) cálculo da trajetória futura de controle $u(k k), \dots, u(k+N_u-1 k)$, adaptado de Ławryńczuk (2014)	13
Figura 3.3 – Modelo de rede neural NARX SISO com 1 entrada (entrada controlada $u(k)$) e 1 saída recorrente ($y_{nn}(k+1)$).	20
Figura 3.4 – Modelo de rede neural NARX MISO com 2 entradas (uma entrada controlada $u(k)$ e uma entrada não controlada $h(k)$), e 1 saída recorrente ($y_{nn}(k+1)$). Onde: (a) camada de entrada; (b) camada neural escondida; (c) camada neural de saída.	20
Figura 3.5 – Modelo de rede neural NARX MIMO com 2 entradas (duas entradas controladas $u_1(k)$ e $u_2(k)$), e 2 saídas recorrentes ($y_{1nn}(k+1)$ e $y_{2nn}(k+1)$).	22
Figura 3.6 – Configuração de identificação em série-paralelo.	23
Figura 3.7 – Configuração de identificação em paralelo.	24
Figura 4.1 – Bloco de Controle Preditivo baseado em Redes Neurais (<i>NN Predictive Controller</i>).	27
Figura 4.2 – Janela do controlador preditivo com os parâmetros de controle.	28
Figura 4.3 – Janela de Identificação da planta para o controle preditivo.	28
Figura 4.4 – Janela de geração dos dados para treinamento da rede neural.	29
Figura 4.5 – Mancal híbrido de um grau de liberdade do eixo para modelo SISO.	30
Figura 4.6 – Sistema mancal híbrido modelo SISO desenvolvido em Simulink.	32
Figura 4.7 – Toolbox de controle preditivo neural aplicado ao mancal híbrido modelo SISO.	33

Figura 4.8 – Janela de identificação para o mancal híbrido modelo SISO: a) Arquitetura da rede neural, b) Dados de treinamento, c) Parâmetros de treinamento.	33
Figura 4.9 – Erro na rotina de normalização de dados do programa de identificação (<i>nni-dent.m</i> , versão Matlab 2015a) da janela <i>Plant Identification</i> do toolbox <i>NN Predictive Controller</i>	34
Figura 4.10–Modelo de rede neural NARX SISO: (a) entrada controla, (b) saída recorrente.	36
Figura 4.11–O princípio de normalização (Teorema de Tales) aplicado a faixa de -1 a 1.	39
Figura 4.12–Diagrama de blocos das fases de treinamento e operação (SILVA; SPATTI; FLAUZINO, 2010).	40
Figura 4.13–Relação do número de Sommerfeld com a rigidez e amortecimento equivalentes do sistema para mancal híbrido em modelo SISO.	42
Figura 4.14–Conjunto de dados de treinamento (entrada/saída).	42
Figura 4.15–Dados de teste (500 amostras) da rede neural NARX.	43
Figura 4.16–Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa sim distúrbio para 20 Hz de velocidade.	45
Figura 4.17–Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa sim distúrbio para 30 Hz de velocidade.	45
Figura 4.18–Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa sim distúrbio para 40 Hz de velocidade.	45
Figura 4.19–Sinal de controle NNMPC para modelo SISO das três velocidades simuladas (20, 30 e 40 Hz) do sistema rotor-mancal em condição ativa sim distúrbio.	46
Figura 4.20–Sinal de deslocamento das três velocidades simuladas (20, 30 e 40 Hz) do sistema rotor-mancal em condição ativa sim distúrbio.	46
Figura 4.21–Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa com distúrbio externo ($k = 162$) para 20 Hz de velocidade.	47
Figura 4.22–Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa com distúrbio externo ($k = 162$) para 30 Hz de velocidade.	47
Figura 4.23–Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa com distúrbio externo ($k = 162$) para 40 Hz de velocidade.	47
Figura 4.24–Sinal de controle NNMPC para modelo SISO das três velocidades simuladas (20, 30 e 40 Hz) do sistema rotor-mancal em condição ativa considerando o distúrbio.	48
Figura 4.25–Sinal de deslocamento das três velocidades simuladas (20, 30 e 40 Hz) do sistema rotor-mancal em condição ativa considerando o distúrbio.	48
Figura 5.1 – Sistema de coordenadas do mancal híbrido modelo MIMO e posição dos quatro atuadores eletromagnéticos instalados simetricamente.	49

Figura 5.2 – Modelo de rede neural NARX MIMO com 3 entradas ($u_1(k)$, $u_2(k)$ e $h(k)$) e 2 saídas ($y_{1nn}(k + 1)$ e $y_{2nn}(k + 1)$): (a) duas entradas controladas, (b) uma entrada não controlada (distúrbio medido), (c) duas saídas recorrentes (deslocamentos na direção dos eixos Y_1 e Z_1 respectivamente).	50
Figura 5.3 – Bancada de testes do sistema rotor-mancal híbrido com os pontos de excitação (\otimes) e de medição (\bullet).	52
Figura 5.4 – Sinal aleatório no domínio do tempo e da frequência, taxa de amostragem 1 kHz.	53
Figura 5.5 – Configuração de identificação em serie-paralelo para processo MIMO.	55
Figura 5.6 – Estratégia 1: dados obtidos das excitações nas direções Y_1 (u_1) e Z_1 (u_2) concatenados num único sinal para cada amplitude de excitação: (a) excitação para 2 V; (b) excitação para 3 V; (c) excitação para 4 V; (d) excitação para 5 V e ; (e) excitação para 6 V.	56
Figura 5.7 – Estratégia 2: combinação dos dados obtidos das amplitudes de excitações nas direções Y_1 (u_1) e Z_1 (u_2) para as tensões 3 V, 4 V, 5 V e 6 V.	57
Figura 5.8 – Rede neural NARX MIMO com as entradas modificadas para a estratégia 2.	60
Figura 5.9 – Melhor treinamento: Regularização Bayesiana para 10 neurônios na direção Y_1	62
Figura 5.10–Melhor treinamento: Regularização Bayesiana para 10 neurônios na direção Z_1	62
Figura 5.11–Correlação entre os valores medidos e os valores preditos do melhor treinamento.	62
Figura 5.12–Resultados do teste da rede neural NARX MIMO nas direções Y_1 e Z_1	63
Figura 5.13–Fase de operação da rede neural NARX MIMO na direção Y_1	64
Figura 5.14–Fase de operação da rede neural NARX MIMO na direção Z_1	64
Figura 5.15–Estrutura interna da rede neural NARX, adaptado de Hagan et al. (2014)	65
Figura 5.16–Sistema de coordenadas e posicionamento dos atuadores eletromagnéticos no MHA.	66
Figura 5.17–Coeficientes de rigidez e amortecimento equivalentes do sistema para mancal híbrido em modelo MIMO ($S = 0,01761$ e $\Omega = 20Hz$).	67
Figura 5.18–Sinal de controle mostrando o detalhe para o análise.	70
Figura 5.19–Resposta do sistema mostrando o detalhe para o análise.	70
Figura 5.20–Condição 1: (a) Sinal de controle, (b) Resposta do sistema na direção Y_1	71
Figura 5.21–Condição 1: (a) Sinal de controle, (b) Resposta do sistema na direção Z_1	71
Figura 5.22–Condição 2: (a) Sinal de controle, (b) Resposta do sistema na direção Y_1	71
Figura 5.23–Condição 2: (a) Sinal de controle, (b) Resposta do sistema na direção Z_1	72
Figura 5.24–Condição 3: (a) Sinal de controle, (b) Resposta do sistema na direção Y_1	72
Figura 5.25–Condição 3: (a) Sinal de controle, (b) Resposta do sistema na direção Z_1	72
Figura 5.26–Condição 4: (a) Sinal de controle, (b) Resposta do sistema na direção Y_1	73

Figura 5.27–Condição 4: (a) Sinal de controle, (b) Resposta do sistema na direção Z_1 . . .	73
Figura 5.28–Condição 1 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Y_1 . 74	
Figura 5.29–Condição 1 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Z_1	74
Figura 5.30–Condição 2 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Y_1 . 74	
Figura 5.31–Condição 2 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Z_1	75
Figura 5.32–Condição 3 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Y_1 . 75	
Figura 5.33–Condição 3 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Z_1	75
Figura 5.34–Condição 4 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Y_1 . 76	
Figura 5.35–Condição 4 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Z_1	76
Figura 5.36–Sinal de distúrbio aleatório de amplitude máxima $\pm 10\mu m$	77
Figura 5.37–Distúrbio aleatório $\pm 10\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Y_1	77
Figura 5.38–Distúrbio aleatório $\pm 10\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Z_1	77
Figura 5.39–Sinal de distúrbio aleatório de amplitude máxima $\pm 30\mu m$	78
Figura 5.40–Distúrbio aleatório $\pm 30\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Y_1	78
Figura 5.41–Distúrbio aleatório $\pm 30\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Z_1	78
Figura 5.42–Sinal de distúrbio aleatório de amplitude máxima $\pm 60\mu m$	79
Figura 5.43–Distúrbio aleatório $\pm 60\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Y_1	79
Figura 5.44–Distúrbio aleatório $\pm 60\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Z_1	79
Figura A.1 – Mancal híbrido de um grau de liberdade (modelo SISO).	91
Figura B.1 – Sistema rotor-mancal híbrido com excitação em u_1 na direção Y_1	93
Figura B.2 – Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Y_1 (2V) e medição em ambas direções (Y_1 e Z_1). 93	
Figura B.3 – Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Y_1 (3V) e medição em ambas direções (Y_1 e Z_1). 94	
Figura B.4 – Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Y_1 (4V) e medição em ambas direções (Y_1 e Z_1). 94	
Figura B.5 – Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Y_1 (5V) e medição em ambas direções (Y_1 e Z_1). 95	

Figura B.6 – Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Y_1 (6V) e medição em ambas direções (Y_1 e Z_1).	95
Figura B.7 – Sistema rotor-mancal híbrido com excitação em u_1 na direção Z_1	96
Figura B.8 – Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Z_1 (2V) e medição em ambas direções (Y_1 e Z_1).	96
Figura B.9 – Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Z_1 (3V) e medição em ambas direções (Y_1 e Z_1).	97
Figura B.10 – Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Z_1 (4V) e medição em ambas direções (Y_1 e Z_1).	97
Figura B.11 – Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Z_1 (5V) e medição em ambas direções (Y_1 e Z_1).	98
Figura B.12 – Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Z_1 (6V) e medição em ambas direções (Y_1 e Z_1).	98
Figura C.1 – Melhor treinamento: Regularização Bayesiana com 15 neurônios (2V).	99
Figura C.2 – Melhor teste: Regularização Bayesiana com 15 neurônios (2V).	99
Figura C.3 – Melhor treinamento: Regularização Bayesiana com 20 neurônios (3V).	100
Figura C.4 – Melhor teste: Regularização Bayesiana com 20 neurônios (3V).	100
Figura C.5 – Melhor treinamento: Levenberg-Marquardt com 10 neurônios (4V).	101
Figura C.6 – Melhor teste: Levenberg-Marquardt com 10 neurônios (4V).	101
Figura C.7 – Melhor treinamento: Regularização Bayesiana com 20 neurônios (5V).	102
Figura C.8 – Melhor teste: Regularização Bayesiana com 20 neurônios (5V).	102
Figura C.9 – Melhor treinamento: Regularização Bayesiana com 20 neurônios (6V).	103
Figura C.10 – Melhor teste: Regularização Bayesiana com 20 neurônios (6V).	103

LISTA DE TABELAS

Tabela 4.1 – Parâmetros de ajuste do atuador eletromagnético (encontrados experimentalmente).	37
Tabela 4.2 – Dados geométricos e de operação utilizados na análise do mancal híbrido. . .	41
Tabela 4.3 – Dados da rede neural NARX SISO.	43
Tabela 5.1 – Resumo dos melhores resultados da fase de treinamento e do teste para a estratégia 1 analisando as cinco entradas propostas (2 V, 3 V, 4 V, 5 V e 6 V).	59
Tabela 5.2 – Entradas novas modificadas da rede neural NARX MIMO.	60
Tabela 5.3 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (amplitude de excitação 3 V, 4 V, 5 V e 6 V).	61
Tabela 5.4 – Equivalência dos valores do arquivo <i>netc</i> e a equação da identificação da planta.	65
Tabela 5.5 – Montagem das matrizes w_{10} , w_1 , w_{20} e w_2 utilizando os dados do arquivo <i>netc</i>	66
Tabela C.1 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (Tensão de entrada 2V).	99
Tabela C.2 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (Tensão de entrada 3V).	100
Tabela C.3 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (Tensão de entrada 4V).	101
Tabela C.4 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (Tensão de entrada 5V).	102
Tabela C.5 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (Tensão de entrada 6V).	103

LISTA DE SÍMBOLOS

Letras gregas

Ω	Velocidade de rotação do rotor (Hz)
λ	Coefficiente de ponderação
φ	Função não-linear da rede neural
φ_i	Posicionamento das sapatas (45°, 135°, 225°, 315°)
μ	Viscosidade dinâmica do óleo ($N.s/m^2$)
α_0	Ângulo de abrangência das sapatas
δ_{est}	Equilíbrio estático

Letras latinas

c_{yy}, c_{zz}	Coefficientes de amortecimento do filme de óleo (Ns/m)
c_{yz}, c_{zy}	Coefficientes de amortecimento cruzadas do filme de óleo (Ns/m)
C_r	Folga radial (m)
C_p	Folga de usinado (μm)
$d(k)$	Distúrbio não medido u
$d_u)$	Atrasos dos dados de entrada
$d_y)$	Atrasos da saída recorrente
D	Diâmetro do mancal (m)
f_{un}	Força de desbalanço (N)
f_m	Força eletromagnética resultante (N)
F_1, F_2, F_3, F_4	Forças magnéticas geradas pelos atuadores eletromagnéticos (N)
F_{ext}	Força externa (N)
h_0	Distancia do entreferro (m)
$h(k)$	Distúrbio externo

i	Corrente elétrica no enrolamento
i_0	Corrente de ativação
i_c	Corrente de controle
I_1, I_2, I_3, I_4	Correntes dos atuadores eletromagnéticos (A)
I_p	Momento de inercia polar do rotor ($kg.m^2$)
I_t	Momento de inercia lateral do rotor ($kg.m^2$)
$J(k)$	Função custo
k	Instante de tempo (m)
k_{yy}, k_{zz}	Coefficientes de rigidez de filme de óleo (N/m)
k_{yz}, k_{zy}	Coefficientes de rigidez cruzadas do filme de óleo (N/m)
K_y	Coefficientes de rigidez da posição
K_i	Coefficientes de rigidez da corrente
L	Comprimento do rotor (m)
m	Massa do rotor (kg)
n_A, n_B	Atrasos do sistema
QP	<i>Quadratic Programming</i>
R	Raio do mancal (m)
S	Número de Sommerfeld
v_{ref}	Tensão de referência
$y(k)$	Saída da planta (m)
y_{nn}	Saída predita pela rede neural
$y_{ref}(k)$	Trajectoria de referência (m)
$y_p(k)$	Trajectoria predita pelo modelo de predição
$\hat{y}(k)$	Trajectoria predita pela rede neural (m)
Y_1, Z_1	Direções ortogonais auxiliares
Y, Z	Direções ortogonais inerciais

Notação especial: modelo e processo de controle

$A(q^{-1}), B(q^{-1})$ Coeficientes do polinómio com atraso e operador q^{-1}

$f(\cdot)$ Função não-linear que descreve um modelo dinâmico

$h(k)$ Distúrbio medido em um instante de tempo k

N Horizonte de predição

N_u Horizonte de controle

N_u Horizonte de controle

q Operador de mudança para trás

$u(k)$ Sequência de controle futuro

$u(k + p|k)$ Vetor de predição para um instante de tempo $k + p$ num instante k

u^{min}, u^{max} Magnitude das restrições impostas na entrada

$\Delta u(k + p|k)$ Incrementos do vetor de entrada para um instante de tempo $k + p$ num instante k

$\Delta u(k)$ Incrementos do vetor de entrada para um instante de tempo k sob horizonte de controle

x^{min}, x^{max} Magnitude das restrições impostas na entrada

$\hat{y}(k)$ Trajetória de predição para um instante de tempo k num instante k

$\hat{y}(k + p|k)$ Trajetória de predição para um instante de tempo $k + p$ num instante k

$y^{ref}(k + p|k)$ Trajetória de referência para um instante de tempo $k + p$ num instante k

y^{min}, y^{max} Magnitude das restrições impostas nas variáveis de saída

SUMÁRIO

1	Introdução	1
1.1	Controle Ativo do Rotor através dos Mancais	1
1.2	Controle Preditivo Baseado em Modelo	4
1.3	Tese	6
1.4	Organização do texto	6
2	Mancal hidrodinâmico com atuadores eletromagnéticos	7
3	Controle Preditivo baseado em Modelo - MPC	11
3.1	Características principais do MPC	11
3.2	Elementos básicos do MPC	13
3.3	Princípio do algoritmo de controle MPC	15
3.4	Algoritmo MPC baseado em modelo de redes neurais - NNMPC	17
3.4.1	Redes neurais artificiais	18
3.4.2	Identificação neural do sistema através de rede neural recorrente - NARX	19
3.4.3	Implementação do modelo de rede neural NARX no algoritmo MPC	24
4	Controle Preditivo Neural aplicado ao Modelo SISO (NNMPC-SISO)	27
4.1	Controle NNMPC-SISO através de Toolbox do Matlab/Simulink	27
4.1.1	Controle Preditivo neural aplicado ao mancal híbrido em modelo SISO	29
4.2	Controle NNMPC-SISO através de programa m-files	35
4.2.1	Identificação neural do sistema dinâmico modelo SISO	35
4.2.2	Linearização do modelo SISO do mancal híbrido ativo	36
4.2.3	Pre-processamento dos dados do treinamento	38
4.3	Resultados do controle NNMPC-SISO	40
4.4	Conclusão	48
5	Controle Preditivo Neural aplicado ao modelo MIMO (NNMPC-MIMO)	49
5.1	Estrutura da rede neural e algoritmos de aprendizagem para o sistema em modelo MIMO	49
5.2	Resultados do controle NNMPC-MIMO	51
5.2.1	Obtenção de dados experimentais para o treinamento da rede neural	52
5.2.2	Identificação não-linear multivariável mediante rede neural NARX MIMO	53
5.2.3	Resultados da identificação não-linear multivariável mediante rede neural NARX MIMO	58
5.2.4	Resultados do controle preditivo neural NNMPC- MIMO	66
5.3	Conclusão	80
6	Conclusões	81
	Referências	83

APÊNDICES	89
APÊNDICE A Procedimento de Linearização do modelo SISO do mancal híbrido ativo	91
APÊNDICE B Obtenção de dados experimentais da bancada mancal híbrido	93
APÊNDICE C Resultados da identificação do sistema dinâmico para a Estratégia 1: Entradas, 2V, 3V, 4V, 5V e 6V	99

1 INTRODUÇÃO

1.1 Controle Ativo do Rotor através dos Mancais

As inúmeras aplicações industriais nos mostram a importância de máquinas rotativas nas diversas etapas do sistema de produção de bens ou serviços. O mal funcionamento ou as falhas destes sistemas acarretariam em sérias consequências econômicas (paradas não programadas). Assim essas máquinas devem ser projetadas de forma a garantir alta eficiência, baixo consumo energético, alta confiabilidade e vida útil mais longa. Um dos principais elementos que definem as características dinâmicas das máquinas rotativas é o mancal. Este elemento de interface entre o rotor e as partes estáticas do sistema é projetado para que a máquina rotativa trabalhe em uma determinada faixa de operação, que pode mudar perante alterações imprevistas das condições de operação (variações súbitas de demanda ou falha). Estas novas faixas de operação podem não ser as mais apropriadas e as características dinâmicas da máquina rotativa podem ser alteradas afetando o desempenho e a sua disponibilidade, levando o sistema rotor-mancal a condições de instabilidades em determinadas condições de operação. Uma solução para reduzir as instabilidades desses sistemas é o incremento das reservas de amortecimento e consequentemente o aumento da faixa de operação (NICOLETTI, 2013).

Surge assim a ideia de se controlar ativamente o rotor através dos mancais. O controle aplicado a mancais permite alterar as características dinâmicas do mancal de forma que estas sejam as mais adequadas para diversas condições de operação obtendo assim amplas margens de estabilidade. O controle ativo de vibrações em sistemas rotativos iniciou-se com o controle dos mancais magnéticos que tem como principal característica a atuação sem contato e a vantagem de trabalhar em uma ampla faixa de frequências (CHIBA et al., 2005; SCHWEITZER; MASLEN, 2009). Entretanto, os mancais magnéticos utilizados em sistemas de grande porte tornam-se caros devido à complexidade do sistema e à necessidade de sistemas de proteção como mancais auxiliares (CADE et al., 2008; ISHIDA; INOUE, 2008; KASARDA, 2000). As pesquisas na área continuam, visando o aprimoramento da modelagem, otimização dos componentes, e as técnicas de controle perante distúrbios externos (BALINI et al., 2010; DONG; YOU, 2014; GRONEK; ROTTENBACH; WORLITZ, 2010; KIANI et al., 2016; PILAT, 2010).

As primeiras aplicações de controle ativo de sistema com mancais hidrodinâmicos são apresentados por Ulbrich e Althaus (1989), onde atuadores hidráulicos montados mediante servo-válvulas dentro do mancal modificam as características dinâmicas em malha fechada. Mais tarde, Santos (1994) utilizou a lubrificação ativa ao invés de atuadores hidráulicos obtendo forças superiores mas para menores faixas de frequências. Neste caso, óleo pressurizado é injetado diretamente na folga do mancal para alterar as características dinâmicas em malha fechada. Resultados experimentais mostraram a eficácia do sistema na redução das vibrações no rotor (SANTOS; NICOLETTI; SCALABRIN, 2003; NICOLETTI; SANTOS, 2004). Uma

diferente solução foi apresentada por [El-Shafei e Hathout \(1994\)](#) mediante dispositivos *hybrid squeeze-film dampers (HSFD)* que são conectadas a servo válvulas onde a pressão interna pode ser controlada em malha fechada incrementando a energia de dissipação. Outro resultado interessante mostra a redução de vibração eficaz durante condições de resposta a forças de desbalanço ([EL-SHAFEI; EL-HAKIM, 2000](#)). Os fluidos eletroreológicos também foram usados em HSFD para alterar as características dinâmicas do mancal ([JUNG; YOUNG; CHOI, 1995](#); [MORISHITA; MITSUI, 1992](#); [KIM; LEE; KOO, 2008](#); [ZHU; ROBB; EWINS, 2002](#)). Como se pode ver, houve avanços na área de projeto de mancais ativos, tanto para mancais magnéticos como para mancais hidrodinâmicos de forma independente. No entanto, a combinação de ambas soluções ainda é um tema aberto para a investigação.

As primeiras ideias de integração de atuadores eletromagnéticos em mancais hidrodinâmicos são encontrados na patentes: U.S.4827169 ([SOCIETE MECHANIQUE MEGNETIQUE, 1989](#)), onde atuadores eletromagnéticos são montados no anel exterior de um mancal hidrodinâmico. Em outra patente U.S.2001048257 ([NTN CORPORATION, 2001](#)) os atuadores são montados num mancal aerostático. Em ambos os casos, a capacidade de carga do mancal lubrificado é usada como mecanismo de suporte do rotor e os atuadores eletromagnéticos são usados para controlar os movimentos do rotor. Os resultados da integração de um mancal axial com mancal magnético mostram um sistema estável para rotações de 7100 rpm e o filme hidrodinâmico não é perturbado pelas forças magnéticas ([QINGCHANG; WEI; XUEJUN, 2002](#)). Outro exemplo de integração combina um mancal hidrodinâmico com ímãs permanentes para analisa-lo como sistema único. Os resultados mostram-se alentadores para baixas viscosidades de fluido lubrificante ([HIRANI; SAMANTA, 2007](#)).

Em publicações mais recentes [Farmakopoulos, Nikolakopoulos e Papadopoulos \(2012\)](#), apresentam uma análise numérica da integração de um mancal hidromagnético (similar à patente US4827169) em termos dos coeficientes dinâmicos equivalentes do sistema. Os autores mostram que numericamente a rigidez e amortecimento total do sistema é uma combinação de rigidez e de amortecimento de cada mecanismo (hidrodinâmico e eletromagnético). Assim, a margem de estabilidade do sistema rotativo pode ser aumentada porque as variações dos coeficientes dinâmicos do mancal devido à lubrificação hidrodinâmica são compensadas com a atuação eletromagnética. Esses resultados confirmam os resultados obtidos por [EL-Shafei e Dimitri \(2010\)](#) para um mancal magnético ativo, onde as instabilidades de *oil-whip* e *oil-whirl* (vibrações sub-harmônicas) observadas num rotor de Laval, são eliminadas pelos atuadores eletromagnéticos, usando estratégias de controle apropriadamente escolhidas. Neste caso, nenhuma solução de projeto para o sistema foi apresentada, sendo o rotor-mancal e os atuadores eletromagnéticos colocados em um modelo matemático linearizado.

Nesse contexto surge o mancal hidrodinâmico segmentado com atuadores eletromagnéticos, que é uma nova geração de mancais ativos, o qual visa aproveitar as vantagens dos mancais hidrodinâmicos e dos mancais magnéticos para a alteração das características dinâmicas,

a atenuação e o controle das vibrações laterais do sistema rotativo (NICOLETTI, 2007). A ideia principal é aproveitar a capacidade de carga e a estabilidade do mancal hidrodinâmico segmentado e encarregar a atuação e o controle aos atuadores eletromagnéticos que estão montados nas sapatas do mancal (Fig. 1.1). Sendo assim, a necessidade de um sistema de segurança para casos de falha do sistema magnético deixam de ser necessários pois o mancal hidrodinâmico sustentará o rotor através da lubrificação hidrodinâmica.




Figura 1.1. Mancal hidrodinâmico segmentado com atuadores eletromagnéticos (mancal híbrido ativo).

O mancal hidrodinâmico com atuadores eletromagnéticos que de agora em diante, será chamado de mancal híbrido ativo (MHA) já foi testado experimentalmente. Os primeiros resultados experimentais do MHA para um rotor na posição vertical, obtidos utilizando um controle PD mostram uma redução da amplitude de vibração em até um 56% para uma velocidade de rotação ainda baixa (300 rpm). No entanto, com o aumento da velocidade de rotação, o efeito dos atuadores diminui, mostrando assim as limitações do sistema eletromagnético para faixa de frequências altas. Outro resultado experimental para um rotor na posição horizontal aplicando um controle PD demonstra uma redução ainda pequena dos picos de ressonância (PIZARRO-VIVEROS; BUTTINI; NICOLETTI, 2011).

Com o intuito de aumentar a capacidade de atuação do sistema eletromagnético foram modificados os perfis dos atuadores sendo agora do tipo “E”. Assim, obteve-se um aumento da faixa de operação e melhores perspectivas de controle, conseguindo-se uma redução de até 18% do pico da amplitude de ressonância para uma velocidade de rotação de 1100 rpm. Estes resultados foram obtidos para um sistema em malha fechada (controlador PD) e analisados no domínio da frequência. Assim, uma comparação entre esta nova proposta de mancal e outros estudados na literatura mostram que o MHA é competitivo em termos de capacidade de controle específico (PIZARRO-VIVEROS; NICOLETTI, 2014).

1.2 Controle Preditivo Baseado em Modelo

Observando os resultados alentadores da utilização do MHA na atenuação das vibrações laterais é que se apresenta o desafio de desenvolver um sistema de controle capaz de aproveitar as condições promissoras desse novo mancal híbrido ativo. Nesse sentido, apresenta-se o algoritmo de controle preditivo baseado em modelo (*Model Predictive Control - MPC*). O MPC tem apresentado um considerável desenvolvimento especialmente no setor da indústria petroquímica e de processos desde sua aparição nos anos 1970. O termo MPC indica uma variedade de métodos de controle preditivo que utilizam expressamente o modelo de predição da planta para prever as saídas futuras do sistema e calcular os sinais de controle através da minimização de uma função custo (CAMACHO; BORDONS, 2004; MACIEJOWSKI, 2002; ROSSITER, 2003; TATJEWSKI, 2007; WANG, 2009).

Os primeiros algoritmos MPC foram projetados por engenheiros que trabalhavam na Indústria e baseavam-se em um modelo Heurístico (*Model Predictive Heuristic Control - MHPC*) (RICHALET et al., 1976; RICHALET et al., 1978). Estes algoritmos ficaram conhecidos mais tarde sob o nome de Controle Algorítmico baseado em Modelo (*Model Algorithm Control - MAC*) desenvolvidos por Rouhani e Mehra (1982). Este controlador utilizava como modelo de predição a resposta ao impulso da planta e sua principal vantagem estava na simplicidade de sintonização e na possibilidade de aplicação nos mais variados processos. Outro exemplo de aplicação pioneira de algoritmos MPC é o algoritmo com Controle por Matriz Dinâmica (*Dynamic Matrix Control - DMC*), concebido pelos engenheiros que trabalharam para a Shell Oil Co e que se tornou bastante popular na indústria química e petroquímica (CUTLER; RAMAKER, 1980). Uma característica única do algoritmo DMC é que ele utiliza como modelo de predição a resposta ao degrau do processo, o que pode ser obtido experimentalmente. Segundo Qin e Badgwell (2003), os algoritmos MHPC e DMC pertencem à primeira geração de algoritmos MPC. Na década de 1980 surge o algoritmo de Controle Preditivo Generalizado (*Generalized Predictive Control - GPC*) desenvolvido por Clarke, Mohtadi e Tuffs (1987). O algoritmo utiliza o princípio da Variância Mínima Generalizada (*Generalized Minimum Variance - GMV*) e consegue descrever uma variedade grande de processos incluindo processos instáveis em malha aberta e processos com integração. Esta estratégia tornou-se um dos métodos mais populares de controle preditivo. O controle MPC pode também ser usado no controle adaptativo, onde um modelo variante no tempo é sucessivamente identificado on-line. Assim, o controle MPC pode ser aplicado para processos não-lineares. Membros desta classe são: o Controle Preditivo auto-ajustável com Horizonte estendido (*Predictor Based Self Tuning Controller - PBSTC*) desenvolvido por Peterka (1984); o Algoritmo de Controle Adaptativo com horizonte Estendido (*Extend Horizon Adaptive Control - EHAC*) desenvolvido por Ydstie e Liu (1984); o algoritmo de controle adaptativo com predição estendida (*Extended Prediction Self Adaptive Control - EPSAC*) desenvolvido por Keyser e Cauwenberghe (1985); o algoritmo de controle adaptativo multivariável (*Multistep Multivariable Adaptive Control - MUSMAR*) desenvolvido por Greco et al. (1984). Nesta segunda

geração de algoritmos MPC as restrições (ações de controle desejadas) são parte integrante de um problema de otimização.

A característica da terceira geração de algoritmos MPC é a introdução de diferentes tipos de restrições, diferentes funções de custo e a introdução de otimização multiobjetivo. Assim, apresenta-se o algoritmo *Multivariable Optimizing Controlador - SMOC* (MARQUIS; BROUSTAIL; SMOC, 1988) o qual utiliza modelos de estado no controle MPC e permite descrever uma classe muito ampla de processos dinâmicos. Neste caso, um observador de estado é usado quando necessário. O grande progresso em plataformas de hardware de controle e no desenvolvimento de novos modelos e métodos de identificação tornou possível considerar aplicações práticas de estruturas não-lineares que constituem a quarta geração de algoritmos MPC (BEMPORAD; MORARI, 1999; MAGNI; SCATTOLINI, 2007; MAYNE et al., 2000). As questões mais importantes neste campo são a estabilidade e problemas de robustez. No entanto a análise teórica não-linear de controle é muito mais difícil do que nos casos lineares.

Dentro dessa variedade de algoritmos MPC, no presente estudo será utilizado um algoritmo de controle preditivo que utiliza as redes neurais artificiais como modelo preditor das saídas futuras da planta, denominado controle preditivo baseado em modelo de rede neural (*Neural Network Model Predictive Control-NNMPC*). A escolha deste preditor visa aproveitar a melhor característica das redes neurais que é a de lidar com não-linearidades dos sistemas dinâmicos. Neste sentido as redes neurais têm encontrado uma promissora aplicação no estudo da identificação, aproximação funcional e mesmo do controle de sistemas dinâmicos não-lineares (HAGAN; DEMUTH; DEJESUS, 2002; ŁAWRYŃCZUK, 2014; NARENDRA; PARTHASARATHY, 1990; SUYKENS; VANDEWALLE; MOOR, 1996). A rede neural mais utilizada na identificação de sistemas dinâmicos é a do tipo auto-regressivo não-linear com entradas exógenas (*Nonlinear Auto-Regressive with eXogenous inputs - NARX*) que, após um treinamento supervisionado, consegue prever o comportamento do sistema. A literatura contém inúmeros artigos referentes à identificação e ao controle de mancais magnéticos dentre os que podemos destacar (CHEN et al., 2014; GIBSON; CHOI; BUCKNER, 2003; LIANG et al., 2010), no entanto, estudos dedicados a utilização das redes neurais no controle de sistemas dinâmicos através de NNMPC são ainda recentes (HOSEN; HUSSAIN; MJALLI, 2011; KITTISUPAKORN et al., 2009; PEDRO; TSHABALALA, 2015; YU; GOMM, 2003; YU; WEN; ZHANG, 2008; ZARENEZHAD; AMINIAN, 2011).

A literatura disponível ainda não mostra aplicações de controle utilizando NNMPC em mancais híbridos. Assim, tem-se uma oportunidade para contribuir e ampliar o conhecimento sobre os mancais híbridos ativos (mancais hidrodinâmicos com atuadores eletromagnéticos) controlados mediante o controle preditivo baseado em modelo de rede neural para atenuar as vibrações laterais do rotor das máquinas rotativas. A identificação multivariável não-linear de mancais híbridos através de redes neurais recorrentes também é um tema em aberto que deve ser aproveitado.

1.3 Tese

Este trabalho pretende demonstrar a seguinte tese:

É possível aplicar o controle preditivo baseado em modelo de rede neural em um mancal híbrido ativo (MHA) e, com isto, controlar a posição do eixo.

Para tanto, tem-se:

- O projeto do algoritmo de controle preditivo baseado em modelo de rede neural;
- O desenvolvimento da metodologia de identificação do sistema MHA através da rede neural recorrente NARX;
- A verificação da viabilidade de uso do controlador no sistema não-linear MHA;
- A determinação do consumo de energia no sistema de controle.

1.4 Organização do texto

O documento está dividido em seis capítulos. O Capítulo 1 apresenta uma introdução ao problema e descrição dos objetivos da tese, o Capítulo 2 apresenta uma descrição do mancal hidrodinâmico com atuadores eletromagnéticos, um breve histórico e a sua modelagem matemática, o Capítulo 3 apresenta os conceitos básicos dos algoritmos de controle preditivo baseado em modelo - MPC e os conceitos do algoritmo MPC baseado em modelo de redes neurais - NNMPC, o Capítulo 4 apresenta o algoritmo NNMPC aplicado ao modelo SISO e resultados computacionais, o Capítulo 5 apresenta o algoritmo NNMPC aplicado ao modelo MIMO resultados de identificação com dados experimentais e resultados de controle computacionais. Enfim, o Capítulo 6 apresenta as conclusões do trabalho e sugestões de trabalhos futuros.

2 MANCAL HIDRODINÂMICO COM ATUADORES ELETROMAGNÉTICOS

O mancal hidrodinâmico com atuadores eletromagnéticos ou simplesmente mancal híbrido ativo (MHA) é um equipamento idealizado e desenvolvido na Escola de Engenharia de São Carlos da Universidade de São Paulo (EESC-USP). O MHA em estudo é composto por quatro atuadores eletromagnéticos embarcados em cada uma das quatro sapatas pivotadas do mancal. São geradas quatro forças eletromagnéticas que atuam em direções opostas. Um sistema hidráulico abastece de óleo pressurizado que preenche a cavidade interna do mancal. As sapatas e atuadores ficam submersos no óleo de tal forma que um filme de óleo envolve as superfícies de contacto das sapatas e do rotor produzindo a lubrificação hidrodinâmica. Pequenas galerias permitem o retorno do óleo ao reservatório fechando assim o circuito hidráulico. A sustentação do rotor é realizada através da lubrificação hidrodinâmica e os atuadores eletromagnéticos são os responsáveis por controlar ativamente as vibrações laterais do rotor.

Para o sistema de controle, medem-se os deslocamentos laterais do eixo por meio de sensores de posição cujos sinais são enviados a um computador para o processamento e o envio da ação de controle ao *driver* e aos atuadores no mancal. A tensão de referência é aplicada aos atuadores gerando forças eletromagnéticas em direções opostas o que permitira o controle da posição do rotor (Fig. 2.1).




Figura 2.1. Mancal Híbrido Ativo (MHA) com os quatro atuadores eletromagnéticos embarcados nas sapatas e com o eixo.

As primeiras ideias e conceitos do MHA, surgiram no ano de 2007 com o pedido de patente deste equipamento (NICOLETTI, 2007). A partir de então, diversos trabalhos foram


desenvolvidos nesta linha de pesquisa. Começou-se com o desenvolvimento de um modelo matemático para o sistema, de forma a se analisar a relação entre a capacidade de carga do mancal e a força de atuação dos eletroímãs. Com isso foram dimensionados os eletroímãs, o mancal e a bancada de testes (COSTAL; NICOLETTI, 2007). O estudo experimental teve início analisando-se a atuação eletromagnética, identificando-se as características estáticas e dinâmicas. Foi projetado o circuito eletrônico de controle (drive) e estabelecida a estratégia de acionamento dos atuadores eletromagnéticos (DIAS; MENUZZO; NICOLETTI, 2007). A primeira versão do mancal ativo junto com sua bancada foi finalizada em 2009, e os primeiros resultados experimentais obtidos no domínio do tempo, evidenciaram uma limitação em frequência da capacidade de atuação do sistema (MORAES; NICOLETTI, 2010).

Considerando essas limitações encontradas experimentalmente (queda de capacidade de atuação com o aumento da frequência), foi aprimorado o sistema de atuação do protótipo experimental e foram realizados novos testes para a identificação experimental do sistema (BUTTINI; NICOLETTI, 2009). Como consequência dessas investigações, foi modificada a posição da bancada construída originalmente na vertical para a posição atual na horizontal (Fig. 2.2). Também foram realizadas modificações na geometria das sapatas com o intuito de obter maior capacidade de atuação do mancal em frequências mais altas. Esta modificação resultou em um incremento da força eletromagnética ao ter um maior fluxo magnético entre o atuador e o eixo. Os resultados experimentais mostram um aumento na capacidade do sistema o que foi identificado e comparado com outros mancais ativos da literatura, concluindo que o MHA é competitivo em termos de capacidade específica de controle (PIZARRO-VIVEROS; NICOLETTI, 2014). Finalmente, a versão atual MHA está composta por 4 sapatas em formato “E” de aço de baixo carbono com os atuadores eletromagnéticos embarcados (Fig. 2.3).


Nesta bancada experimental, a primeira frequência natural do eixo é 389Hz. Assim, o eixo é considerado como corpo rígido na faixa de estudo (até 100Hz). Quando algum componente da bancada é considerado rígido, isto significa que as amplitudes de vibração oriundas da elasticidade do material não são significativas em relação as amplitudes dos movimentos de corpo rígido. A bancada de testes com o MHA possui os seguintes componentes (Fig. 2.2): um eixo de aço de 80 mm de diâmetro (1), é suportado por um mancal de rolamentos autocompensador de esferas (2) e um mancal híbrido ativo (3). O eixo é acionado pelo motor elétrico (4), através de uma junta universal (5), e a velocidade de rotação do eixo é controlada por um inversor de frequências. A bancada é montada em uma mesa inercial (6) com frequência natural aproximada de 2Hz. Sensores de proximidade (7) montados nas direções ortogonais do MHA medem os deslocamentos laterais do rotor. Um mancal auxiliar de esferas (8) é montado no eixo e usado como mancal de excitação do MHA, onde o shaker será conectado para a excitação do sistema MHA. Uma unidade hidráulica (9) é responsável pelo suprimento do óleo, sendo a temperatura controlada por um sistema trocador de calor (10). Este sistema hidráulico trabalha em malha fechada.



Figura 2.2. Bancada experimental do MHA: (1) Eixo, (2) mancal de rolamento autocompensador, (3) mancal hidrodinâmico com atuadores embarcados, (4) motor elétrico, (5) junta universal, (6) mesa inercial, (7) sensor de proximidade, (8) mancal de excitação, (9) unidade hidráulica, (10) sistema trocador de calor.



(a)



(b)

Figura 2.3. Versão atual do MHA com novos atuadores: (a) mancal híbrido com os quatro atuadores eletromagnéticos montados no interior; (b) atuador eletromagnético embarcado na sapata de formato “E”.

3 CONTROLE PREDITIVO BASEADO EM MODELO - MPC

Os controladores clássicos da família proporcional, integral e derivativo (PID) utilizam uma técnica de controle que envolve três parâmetros: proporcional, integral e derivativo. O proporcional depende do erro atual, o integral dos erros passados e o derivativo é uma previsão dos erros futuros, este tipo de controle apresenta uma grande efetividade. Já os controladores preditivos utilizam não só as informações passadas mas também as informações do comportamento futuro do processo. Uma das maneiras de se prever o comportamento futuro é a partir de um modelo matemático que represente a dinâmica do processo. Este conjunto de controladores que utilizam expressamente o modelo matemático do processo são conhecidos como Controles Preditivos baseados em Modelo (do Inglês *Model Predictive Control - MPC*). Trata-se de uma variedade de métodos que podem ser aplicados a processos lineares, não-lineares, mono e multivariáveis com restrições e atrasos (CAMACHO; BORDONS, 2004; MACIEJOWSKI, 2002; ROSSITER, 2003; TATJEWSKI, 2007; WANG, 2009). No decorrer dos anos as aplicações foram estendidas na áreas da engenharia mecânica, elétrica, energia, aeroespacial e de controle, inclusive existem aplicações na área da saúde. Nesse contexto, o presente capítulo descreve de maneira sucinta as características principais do controle preditivo baseado em modelo.

3.1 Características principais do MPC

Apesar da grande variedade de algoritmos preditivos desenvolvidos até o momento, o método de controle é desenvolvido em ideias comuns que basicamente se centram nos seguintes pontos (CAMACHO; BORDONS, 2004):

- Uso explícito do modelo de previsão do processo para prever as saídas futuras em um horizonte de previsão.
- Cálculo da sequência de controle através de sucessivas minimizações on-line da função de custo. Este processo pode estar sujeito a restrições, sendo esta a característica mais relevante diante de outras técnicas de controle.
- O uso do horizonte deslizante (*receding horizon*) que se desloca à frente para cada instante de tempo (k). Isso implica utilizar só o primeiro valor da sequência calculada do controle ($u(k)$) e desconsiderar o resto, dentro do horizonte de controle (N), repetindo o procedimento para cada instante de tempo.

A maior diferença entre os diversos algoritmos de controle preditivo está na utilização do modelo de previsão usado para representar o processo, que deve incluir a representação das perturbações e o ruído. A seleção do modelo de previsão é fundamental no controle porque ele deve ser completo o suficiente para obter a dinâmica do processo e prever adequadamente as relações entre as entradas, as perturbações e as saídas do processo. A grande maioria de

controladores preditivos baseados em modelo (MPC) utilizam a estrutura básica mostrada na Fig. 3.1 (CAMACHO; BORDONS, 2004; NORMEY-RICO; CAMACHO, 2007). O modelo preditor é usado para prever as saídas da planta, baseado nos valores passados e atuais do sistema que são utilizados para calcular a sequência de controle futuro. Esta ação é calculada no processo de otimização que minimiza a função custo considerando a trajetória de referência.

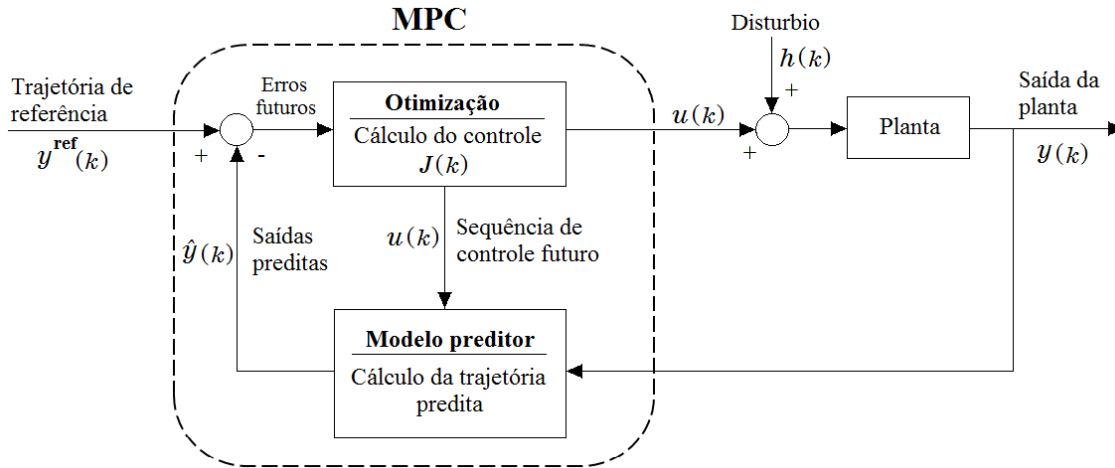


Figura 3.1. Estrutura básica do controle MPC.

Na Fig. 3.2 é mostrado o princípio do controle preditivo. Aqui, podem-se observar as três trajetórias importantes do controle preditivo: a trajetória de referência, a trajetória predita, e a trajetória futura de controle. O eixo horizontal representa o tempo discreto, sendo k o instante de tempo atual em que uma decisão de controle é efetivada (instante de amostragem).

1. Define-se o horizonte de predição N . As saídas futuras são preditas em cada instante de tempo k utilizando o modelo da planta (daqui em diante, será utilizada a notação $(k + p|k)$, leia-se como, o instante de tempo $k + p$ num instante atual k). As saídas da trajetória de predição $\hat{y}(k + p|k)$ sendo $p = 1, \dots, N$ são dependentes dos valores das entradas e saídas passadas, do instante k , e dos sinais de controle futuros $u(k + p|k)$, para $p = 0, \dots, Nu - 1$ que devem ser calculados (sendo Nu o horizonte de controle).
2. O objetivo é minimizar as diferenças entre a trajetória de referência $y^{ref}(k + p|k)$ e os valores de saída de predição $\hat{y}(k + p|k)$ sob um horizonte de predição N . Estes critérios têm a forma de equação quadrática de erros entre a trajetória de referência e o sinal de saída de predição. O esforço de controle é considerado também na função custo. É necessário utilizar um método numérico de otimização iterativo para obter a solução desta função.
3. A função de custo é minimizada on-line (para cada instante de tempo k). O primeiro elemento da sequência de controle futuro $u(k)$ é utilizado no processo de controle enquanto o restante é desconsiderada. Por exemplo, para calcular o seguinte instante de tempo $(k + 1)$ a predição avança um passo a frente e o procedimento para calcular o valor de $u(k + 1|k + 1)$ é repetido novamente.

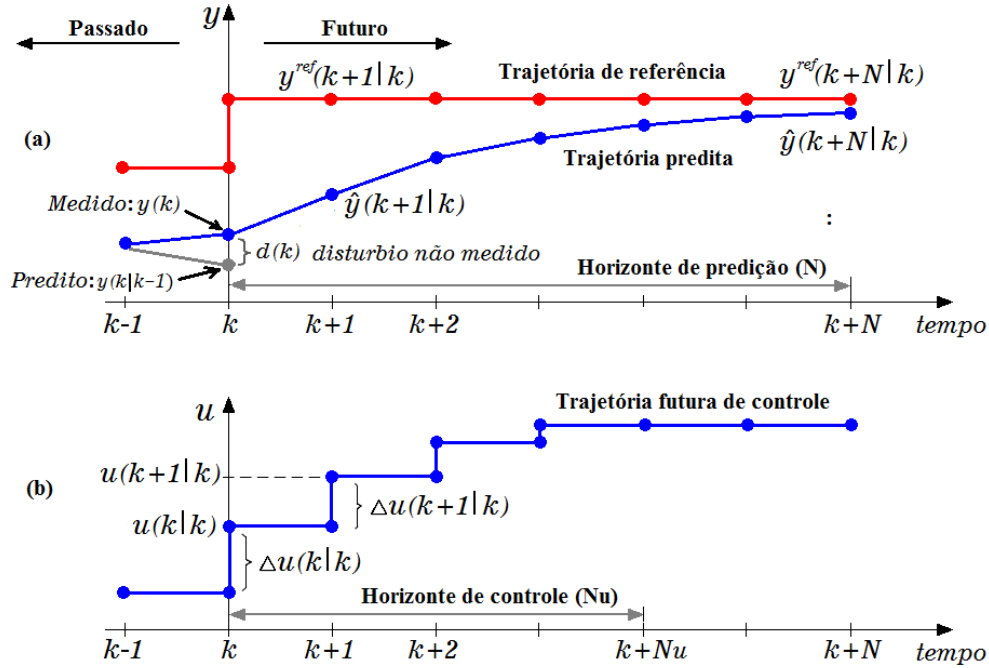


Figura 3.2. Princípio do controle preditivo: (a) trajetória predita $\hat{y}(k+1|k), \dots, \hat{y}(k+N|k)$ e a trajetória de referência $y^{ref}(k+1|k), \dots, y^{ref}(k+N|k)$; (b) cálculo da trajetória futura de controle $u(k|k), \dots, u(k+N_u-1|k)$, adaptado de [Ławryńczuk \(2014\)](#).

3.2 Elementos básicos do MPC

O MPC, possui três elementos básicos que compõem o controle preditivo baseado em modelo: o modelo de predição, a função custo e a lei de controle:

a) Modelo de predição: o principal fundamento de controladores MPC é o modelo de predição. Este modelo deve ser suficientemente completo para capturar a dinâmica do processo e, desta forma, obter as melhores previsões e permitir uma análise teórica adequada. Através desse modelo de predição são calculadas as saídas previstas em instantes futuros $\hat{y}(k+p|k)$. Existem diferentes estratégias para representar modelos de predição, sendo que muitas delas consideram as perturbações. Os principais modelos de predição adotados na literatura são listados a seguir:

- **Modelo de resposta ao impulso**, aplicado para sistemas lineares invariantes no tempo (TIR), que calcula o sinal de saída do sistema para qualquer sinal de entrada através da operação de convolução ([CAMACHO; BORDONS, 2004](#)):

$$y_p(k) = \sum_{i=1}^{\infty} g_i u(k-i) \quad (3.1)$$

onde g_i são as respostas do processo ao impulso unitário. Quando a soma é truncada e só se consideram M valores, por tanto são representados processos estáveis, tem-se:

$$y_p(k) = \sum_{i=1}^M g_i u(k-i) = G(q^{-1})u(k) \quad (3.2)$$

O operador de mudanças para trás (q), é uma notação útil ao trabalhar com atrasos de séries temporais.

- **Modelo de resposta ao degrau**, este modelo é similar ao anterior, cuja resposta truncada é dada por:

$$y_p(k) = y_0 + \sum_{i=1}^M g_i \Delta u(k-i) = y_0 + G(q^{-1})(1 - q^{-1})u(k) \quad (3.3)$$

onde g_i são as respostas do processo a entrada degrau, e $\Delta u(k) = u(k) - u(k-1)$ (NORMEY-RICO; CAMACHO, 2007). Este modelo é utilizado pelo algoritmo DMC (*Dynamic Matrix Control*). Pode-se assumir que o valor de y_0 é nulo sem perda de generalidade. Assim, as predições são:

$$y_p(k+p|k) = \sum_{i=1}^M g_i \Delta u(p+k-i|k), \quad p = 1, 2, \dots, N. \quad (3.4)$$

onde $y_p(k+p|k)$ é a resposta ao degrau para um instante de tempo $k+p$ num instante k , $\Delta u(p+k-i|k)$ é o incremento do vetor de entrada para um instante de tempo $k+p$ num instante k .

- **Modelo de espaço de estados**, usado amplamente em alguns tipos de controladores MPC, com a seguinte representação:

$$\begin{aligned} x(k) &= Ax(k-1) + Bu(k-1) \\ y(k) &= Cx(k) \end{aligned} \quad (3.5)$$

onde x é o estado, A e B e C são as matrizes do sistema de entrada e saída respectivamente.

- **Modelo de resposta por função de transferência**, onde os modelos são obtidos a partir de testes de resposta as entradas conhecidas. Neste caso, utiliza-se o conceito de função de transferência $G = B/A$, e a resposta é representada por:

$$A(q^{-1})y_p(k) = B(q^{-1})u(k-1) \quad (3.6)$$

$$\begin{aligned} A(q^{-1}) &= 1 + a_1q^{-1} + a_2q^{-2} + \dots + a_naq^{-na} \\ B(q^{-1}) &= b_0 + b_1q^{-1} + b_2q^{-2} + \dots + b_n bq^{-nb} \end{aligned} \quad (3.7)$$

assim a predição é dada por:

$$y_p(k+p|k) = \frac{B(q^{-1})}{A(q^{-1})}u(k+p-1|k), \quad p = 1, 2, \dots, N. \quad (3.8)$$

- **Modelo de resposta utilizando redes neurais**, que recentemente se tornou numa nova alternativa para obtenção do modelo de predição com grande potencial de aplicação nos controles MPC. A grande capacidade de lidar principalmente com sistemas dinâmicos não-lineares tornam interessante a sua utilização (ŁAWRYŃCZUK, 2014; TATJEWSKI, 2007), devido a isso, será utilizado no presente trabalho.

Uma outra alternativa para o treinamento das redes neurais e a predição de series temporais, é a utilização dos meta-modelos, que ajudaria a diminuir o custo computacional da otimização.

b) Função custo: Geralmente trata-se de uma equação quadrática que pode estar sujeita a restrições. Comumente é conhecido como um problema de programação quadrática (*Quadratic Programming - QP*) que deve ser resolvido através de métodos numéricos (a solução analítica na maioria dos casos torna-se mais complexo). Esta função esta formada por duas parcelas. A primeira parcela considera a diferença entre a trajetória de referência e a trajetória predita da variável de saída e sob um horizonte de predição N . Já a segunda parcela da função custo é conhecida como, os valores dos incrementos de controle futuros, que inclui um coeficiente de ponderação (λ) que penaliza o incremento de controle excessivo sob um horizonte de controle Nu . A expressão geral da função custo é:

$$J(k) = \sum_{p=1}^N (y^{ref}(k+p|k) - \hat{y}(k+p|k))^2 + \lambda \sum_{p=0}^{Nu-1} (\Delta u(k+p|k))^2 \quad (3.9)$$

onde $\lambda > 0$ é o coeficiente de ponderação (se λ é grande o algoritmo tende a ser lento). O valor da trajetória de referência para um instante de tempo $k+p$ num instante k é denotada como $y^{ref}(k+p|k)$, o valor predito da trajetória de saída para um instante de tempo $k+p$ num instante k é denotado por $\hat{y}(k+p|k)$. As saídas são preditas consecutivamente para um horizonte de predição N sendo que $p = 1, \dots, N$. Assume-se que $u(k+p|k) = u(k+Nu-1|k)$ para $p = Nu, \dots, N$.

c) Lei de controle: todos os algoritmos MPC têm como objetivo comum a minimização da função custo (Eq. (3.9)). Dessa forma são obtidos os valores ótimos de $u(k+p|k)$ que serão aplicados ao processo (CAMACHO; BORDONS, 2004). Para isto, as saídas preditas $\hat{y}(k+p|k)$ são calculadas em função das entradas, saídas e o sinal de controle futuro, utilizando o modelo de predição escolhido e substituído na função custo. Se o sistema é linear sem restrições uma solução analítica pode ser utilizada. No caso linear ou não-linear com restrições, é preciso utilizar um modelo de programação quadrática através de um método numérico de otimização.

3.3 Princípio do algoritmo de controle MPC

O algoritmo de controle MPC inicia conhecendo-se as saídas preditas, a trajetória de referência e os incrementos de controle futuros no instante de tempo k . A sequência de controle

futuro $u(k)$ do algoritmo MPC é determinada através de um processo de otimização quadrática (Eq. (3.10)), que é calculada on-line para cada iteração consecutiva do algoritmo.

Assim, são encontrados os valores ótimos da sequencia de controle futuro num horizonte de controle N_u , mas apenas, só o primeiro elemento da sequência $u(k)$ é enviado para a planta, enquanto que o restante da sequência é desconsiderado. Já no próximo instante de tempo $(k + 1)$, é repetido o procedimento de calculo da nova sequência de controle $u(k + 1|k + 1)$ e utilizado também só o primeiro elemento.

$$u(k) = \begin{bmatrix} u(k|k) \\ \vdots \\ u(k + N_u - 1|k) \end{bmatrix} \quad (3.10)$$

O vetor de incrementos de controle futuros da variável manipulável é dado por:

$$\Delta u(k) = \begin{bmatrix} \Delta u(k|k) \\ \vdots \\ \Delta u(k + N_u - 1|k) \end{bmatrix} \quad (3.11)$$

onde:

$$\Delta u(k + p|k) = \begin{cases} u(k|k) - u(k - 1|k) & \text{se } p = 0 \\ u(k + p|k) - u(k + p - 1|k) & \text{se } p \geq 1 \end{cases} \quad (3.12)$$

O sinal de controle oriundo do controlador preditivo é obtido a partir da minimização da função custo dado por:

$$\underbrace{\arg \min}_{\Delta u(k|k) \dots \Delta u(k + N_u - 1|k)} \{J(k)\} \quad (3.13)$$

esta função custo pode estar sujeita às seguintes restrições:

$$u^{min} \leq u(k + p | k) \leq u^{max}, \quad p = 0, \dots, N_u - 1 \quad (3.14)$$

$$-\Delta u^{max} \leq \Delta u(k + p | k) \leq \Delta u^{max}, \quad p = 0, \dots, N_u - 1 \quad (3.15)$$

$$y^{min} \leq \hat{y}(k + p | k) \leq y^{max}, \quad p = 1, \dots, N \quad (3.16)$$

onde u^{min} , u^{max} , Δu^{max} , y^{min} , y^{max} define as restrições impostas na magnitude das variáveis de entrada, dos incrementos de controle futuro, e da variável de saída predita respectivamente.

O algoritmo MPC utiliza um modelo dinâmico explicito para prever o comportamento futuro do processo. Assim, a predição é um modelo muito importante para qualquer algoritmo MPC, pois com esse modelo são preditos os valores ao longo do horizonte de predição (N_u) e cujos erros serão minimização na função custo do MPC (Eq. (3.9)). Durante o cálculo da predição é necessário considerar que o modelo da planta usualmente não é exato e que o processo

pode ser afetado por distúrbios não medidos, assim, define-se a equação geral de predição no instante de tempo $k + p$ (CAMACHO; BORDONS, 2004):

$$\hat{y}(k + p|k) = y_p(k + p|k) + d(k) \quad (3.17)$$

onde $\hat{y}(k + p|k)$ são os valores da trajetória predita para cada instante de tempo $k + p$ num instante k , $y_p(k + p|k)$ são os valores da predição (qualquer modelo) calculada diretamente do modelo para cada instante de tempo $k + p$ num instante k , e $d(k)$ é o distúrbio não medido do sistema. Para compensar o distúrbio não medido que afeta ao processo é preciso determinar a diferença entre os valores do processo real da planta (medido) e os valores do trajetória predita do modelo, o distúrbio não medido $d(k)$ esta dado por:

$$d(k) = y(k) - y_p(k|k - 1) \quad (3.18)$$

onde $y(k)$ são os valores reais medidos da planta e $y_p(k|k - 1)$ são os valores de predição calculados diretamente do modelo num instante de tempo anterior $k - 1$.

A otimização da função custo $J(k)$ que considera as restrições impostas é realizada utilizando um método numérico que resolve on-line a equação quadrática. Este tipo de solução envolve a utilização da Programação Quadrática Sequencial (do inglês *Sequential Quadratic Program-SQP*) cuja eficiência em resolver equações quadráticas não lineares com restrições tem sido comprovada e utilizada amplamente na literatura e será o método utilizado no estudo. No entanto, o esforço computacional necessário para o cálculo das gradientes desse método é alto.

Como o nosso estudo trata-se um problema de otimização convexa é possível utilizar também um outro método chamado, método dos pontos interiores aplicado a este tipo de problema. Assim, os resultados destes problemas de otimização podem ser obtidos com maior eficiência em termos de custo computacional (BOYD et al., 1994; GAHINET et al., 1994).

3.4 Algoritmo MPC baseado em modelo de redes neurais - NNMPC

O algoritmo de controle preditivo baseado em modelo de redes neurais (NNMPC) utiliza uma estrutura de rede neural como modelo de predição da planta para prever as saídas futuras. Assim é possível calcular os futuros sinais de controle através da minimização da função custo baseado no erro entre a trajetória de referência e a predição do modelo neural em um horizonte de predição e controle (ŁAWRYŃCZUK, 2014; TATJEWSKI, 2007). A seguir são apresentados um breve histórico das redes neurais artificiais, sua aplicação nos algoritmos MPC e o procedimento de identificação neural através da rede neural recorrente tipo NARX. Este é um tipo específico de rede neural denominado, rede não-linear auto-regressiva com entradas exógenas (NARX) utilizada amplamente para a previsão de sistemas dinâmicos não-lineares.

3.4.1 Redes neurais artificiais

Redes Neurais Artificiais (*Neural Network-NN*), chamadas também pelo nome curto de redes neurais, são modelos computacionais inspirados no sistema nervoso humano. Tais redes possuem a capacidade de aprendizagem através de exemplos e manutenção do conhecimento (quando treinadas adequadamente) e são definidas como um conjunto de unidades de processamento denominadas neurônios artificiais, que estão interligados por interconexões (sinapses artificiais) representadas por vetores ou matrizes que armazenam os pesos sinápticos e o bias (ou limiar de ativação) dos neurônios (HAYKIN, 1999).

Atualmente as redes neurais possuem inúmeras aplicações e são muito reconhecidas pela grande habilidade de lidar com problemas não-lineares. Os pesquisadores McCulloch e Pitts (1943) apresentaram a primeira concepção de neurônio biológico artificial através de um modelamento matemático definindo-se como máquina binária com várias entradas e saídas. No entanto, este modelo não tinha a capacidade do aprendizado. A ideia do primeiro método de treinamento foi apresentada por Hebb (1949), o qual atualmente denomina-se regra de Hebb. Com o decorrer dos anos o desenvolvimento de modelos inspirados no neurônio biológico continuaram, destacando-se o trabalho de Rosenblatt (1958), onde se desenvolveu o primeiro neurocomputador conhecido como *Mark I - Perceptron*, o qual podia reconhecer padrões de forma simples. Os pesquisadores Widrow e Hoff (1960) criaram o ADALINE (*ADaptive LINear Element*) e posteriormente o Madaline (Multiples Adaline), os quais utilizaram para o aprendizado a regra Delta (ou *least mean square LMS*).

Em 1969, Minsky e Papert (1969) demonstraram numericamente a limitação de uma rede neural (de uma única camada) para classificar padrões da função lógica não-linear Xor (ou-exclusivo). Esta forte crítica impactou negativamente nas pesquisas que vinham sendo realizadas e que ficaram estagnadas. Contudo, em 1982, o pesquisador Kohonen (1982) criou os mapas auto-organizáveis, e Hopfield (1982) propôs as redes recorrentes e devido a este estudo a área de redes neurais retomaram um novo destaque. Com o desenvolvimento dos computadores com maior capacidade de processamento e memória, foram testados novos algoritmos mais eficientes e robustos. Com isto, Rumelhart, Hinton e Williams (1985), demonstraram a possibilidade de ajustar os pesos de uma rede Perceptron com mais de uma camada (*Multilayer Perceptron-MLP*), fato que solucionou o antigo problema de aprendizado dos padrões da função lógica não-linear Xor (ou-exclusivo). O algoritmo foi denominado como *backpropagation* e significou um recomeço das pesquisas em redes neurais.

Atualmente é inúmera a literatura que estuda as redes neurais artificiais devido à grande habilidade que tem para lidar com as não-linearidades através da aprendizagem baseada em exemplos. Uma leitura recomendada para o entendimento dos conceitos básicos e o funcionamento pode ser encontrada em Haykin (1999), leitura que pode ser complementada com as aplicações para engenharia apresentadas por Silva, Spatti e Flauzino (2010). Em relação às aplicações das redes neurais aos algoritmos MPC a literatura mostra uma diversidade de trabalhos. Podemos

citar, [Yu e Gomm \(2003\)](#) com uma aplicação experimental do controlador que utiliza as redes neurais em algoritmos MPC implementados num reator químico multivariável, obtendo um controle satisfatório quando comparado com controle convencional. Já [Kittisupakorn et al. \(2009\)](#), utilizaram o MPC baseado em redes neurais para o controle do processo de tratamento do aço obtendo melhores resultados que com controle PI tradicional, mostrando assim a possibilidade de implementação em processos industriais não-lineares. Os pesquisadores [Pedro e Tshabalala \(2015\)](#) analisaram o controle híbrido NNMPC/PID aplicado a um mecanismo flexível de duas juntas com resultados efetivos do controlador proposto. Na maioria destes casos foram utilizados uma rede neural recorrente do tipo NARX.

3.4.2 Identificação neural do sistema através de rede neural recorrente - NARX

As redes neurais recorrentes são estruturas que conseguem representar o comportamento de sistemas dinâmicos tipicamente não-lineares. A estrutura mais utilizada é o modelo auto-regressivo não-linear com entradas exógenas (*Nonlinear Auto-Regressive with exogenous inputs - NARX*) que pertence às redes com entradas atrasadas no tempo e com saídas recorrentes às entradas. A característica principal deste tipo de rede é o aprendizado a partir de exemplos, ou seja, a partir de pares entrada-saída disponibilizados para o denominado treinamento supervisionado. O objetivo deste treinamento é encontrar os melhores pesos e bias (representados em matrizes) da estrutura neural e que após o processo de identificação consiga reproduzir o comportamento do sistema identificado.

O processo de identificação dinâmica é um processo iterativo que procura encontrar os melhores valores dos pesos e o bias da rede neural NARX. Este processo é realizado off-line utilizando um algoritmo de aprendizagem. A estrutura neural da rede neural NARX comumente possui uma única camada neural escondida (podem ser mais de uma) com um número de K neurônios e uma função de transferência não-linear. Já na camada de saída, a função de transferência é linear. Uma arquitetura de identificação neural pode-se representar de três formas: em modelo SISO, MISO ou MIMO. A arquitetura da rede neural de modelo NARX SISO, tem uma entrada e uma saída (*single-input single-output*) e é a arquitetura mais simples de identificação porém é muito efetiva (Fig. 3.3).

Neste caso, a equação do modelo de rede neural NARX SISO é dada por:

$$y_{nn}(k+1) = w_0^2 + \sum_{i=1}^K w_i^2 \varphi(w_{i,0}^1 + \sum_{m=0}^{d_u} w_{m,i}^1 u(k-m) + \sum_{n=0}^{d_y} w_{n,i}^1 y_{nn}(k-n)) \quad (3.19)$$

onde os superíndices 1 e 2 representam a camada de entrada e saída respectivamente, $y_{nn}(k+1)$ é a predição neural, $w_{m,i}^1$ e $w_{n,i}^1$ são os pesos das conexões entre a camada de entrada e a camada neural escondida, w_i^2 é o peso da camada de saída e $w_{i,0}^1$, w_0^2 são os biases da camada de entrada e saída, respectivamente, φ é a função não-linear, d_u e d_y são os atrasos da entrada e da saída recorrente, respectivamente.




Figura 3.3. Modelo de rede neural NARX SISO com 1 entrada (entrada controlada $u(k)$) e 1 saída recorrente ($y_{nn}(k+1)$).

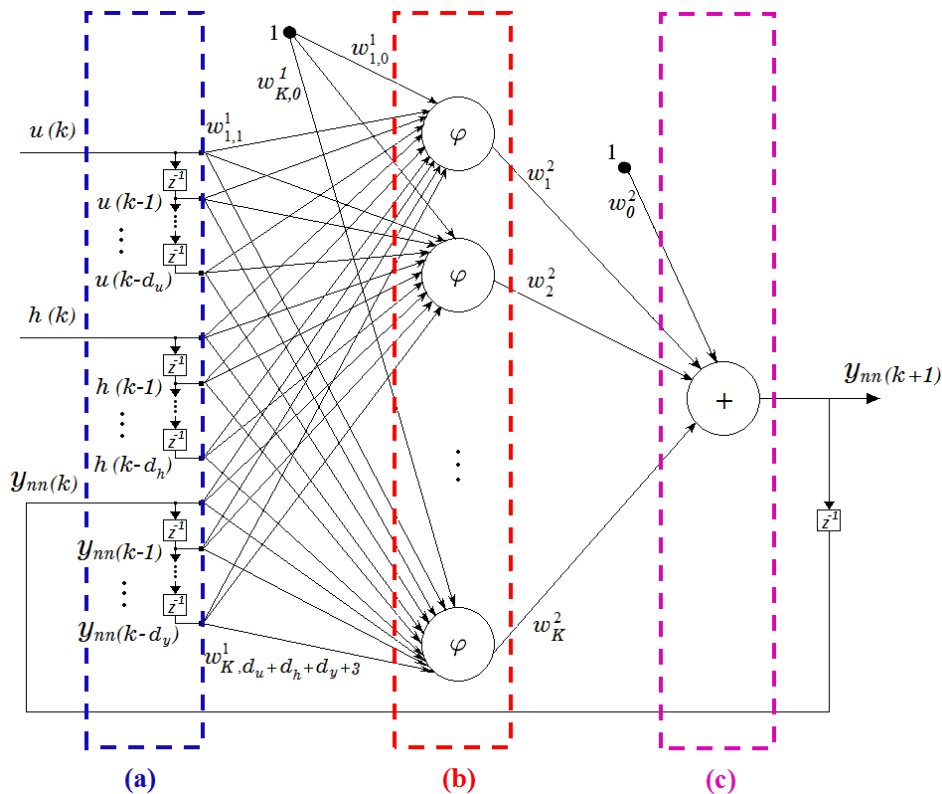


Figura 3.4. Modelo de rede neural NARX MISO com 2 entradas (uma entrada controlada $u(k)$ e uma entrada não controlada $h(k)$), e 1 saída recorrente ($y_{nn}(k+1)$). Onde: (a) camada de entrada; (b) camada neural escondida; (c) camada neural de saída.

A arquitetura para modelo de rede neural NARX MISO (*multi-input single-output*), está composta de varias entradas e uma saída. Para o nosso estudo temos duas entradas: a entrada $u(k)$, e uma entrada não controlada $h(k)$ (distúrbio medido). A saída, $y_{nn}(k)$ que é recorrente a entrada, todas em um instante de tempo k . Os atrasos da entrada, a entrada não controlada e a saída recorrente são: d_u , d_h e d_y . Sendo φ uma função não-linear, como mostra a Fig. 3.4.

A equação do modelo de rede neural NARX MISO com 2 entradas e 1 saída, obtida e adaptada de Ławryńczuk (2014) é dada por:

$$y_{nn}(k+1) = w_0^2 + \sum_{i=1}^K w_i^2 \varphi(w_{i,0}^1 + \sum_{m=0}^{d_u} w_{m,i}^1 u(k-m) + \sum_{n=0}^{d_h} w_{n,i}^1 h(k-n) + \sum_{q=0}^{d_y} w_{q,i}^1 y_{nn}(k-q)) \quad (3.20)$$

onde os superíndices 1 e 2 representam a camada de entrada e saída respectivamente, $w_{m,i}^1$, $w_{n,i}^1$ e $w_{q,i}^1$ são os pesos das conexões entre a camada de entrada e a camada neural escondida, w_i^2 é o peso da camada de saída, e $w_{i,0}^1$, w_0^2 são os biases da camada de entrada e saída respectivamente, φ é a função não-linear, d_u , d_h e d_y são os atrasos da entrada, da entrada não controlada (distúrbio medido) e da saída recorrente respectivamente.

Uma outra potencialidade da rede neural NARX é sua utilização como modelo de múltiplas-entradas e múltiplas-saídas ou modelo MIMO (*multi-input multi-output*). Uma arquitetura neural mais complexa que pode demorar em generalizar as características do sistema sendo dependente da quantidade e qualidade dos dados para o treinamento. Na Fig. 3.5 mostra um modelo de rede neural NARX MIMO duas entradas e duas saídas. Para nosso caso, temos como duas entradas: $u_1(k)$ e $u_2(k)$, que são as tensões de alimentação dos circuitos de cada par de atuadores eletromagnéticos. E duas saídas recorrentes: $y_{1nn}(k+1)$ e $y_{2nn}(k+1)$, que representam o deslocamento do rotor nas direções ortogonais.

A equação do modelo de rede neural NARX MIMO de 2 entradas e 2 saídas é dado por:

$$y_{nn}(k+1) = w_{j,0}^2 + \sum_{i=1}^K w_i^2 \varphi(w_{i,0}^1 + \sum_{m=0}^{d_{u1}} w_{m,i}^1 u_1(k-m) + \sum_{n=0}^{d_{u2}} w_{n,i}^1 u_2(k-n) + \sum_{r=0}^{d_{y1}} w_{r,i}^1 y_{1nn}(k-r) + \sum_{s=0}^{d_{y2}} w_{s,i}^1 y_{2nn}(k-s)) \quad (3.21)$$

onde $y_{nn}(k+1) = \begin{Bmatrix} y_{1nn}(k+1) \\ y_{2nn}(k+1) \end{Bmatrix}$, $w_{m,i}^1$, $w_{n,i}^1$, $w_{r,i}^1$ e $w_{s,i}^1$ são os pesos das conexões entre a camada de entrada e a camada neural escondida, w_i^2 é o peso da camada neural de saída, $w_{i,0}^1$ é o bias da camada de entrada, $w_{j,0}^2$ são os biases da camada neural de saída (onde $j = 1, 2$), φ é a função não-linear, e d_{u1} , d_{u2} , d_{y1nn} e d_{y2nn} são os atrasos das duas entradas e as duas saídas recorrentes, respectivamente.

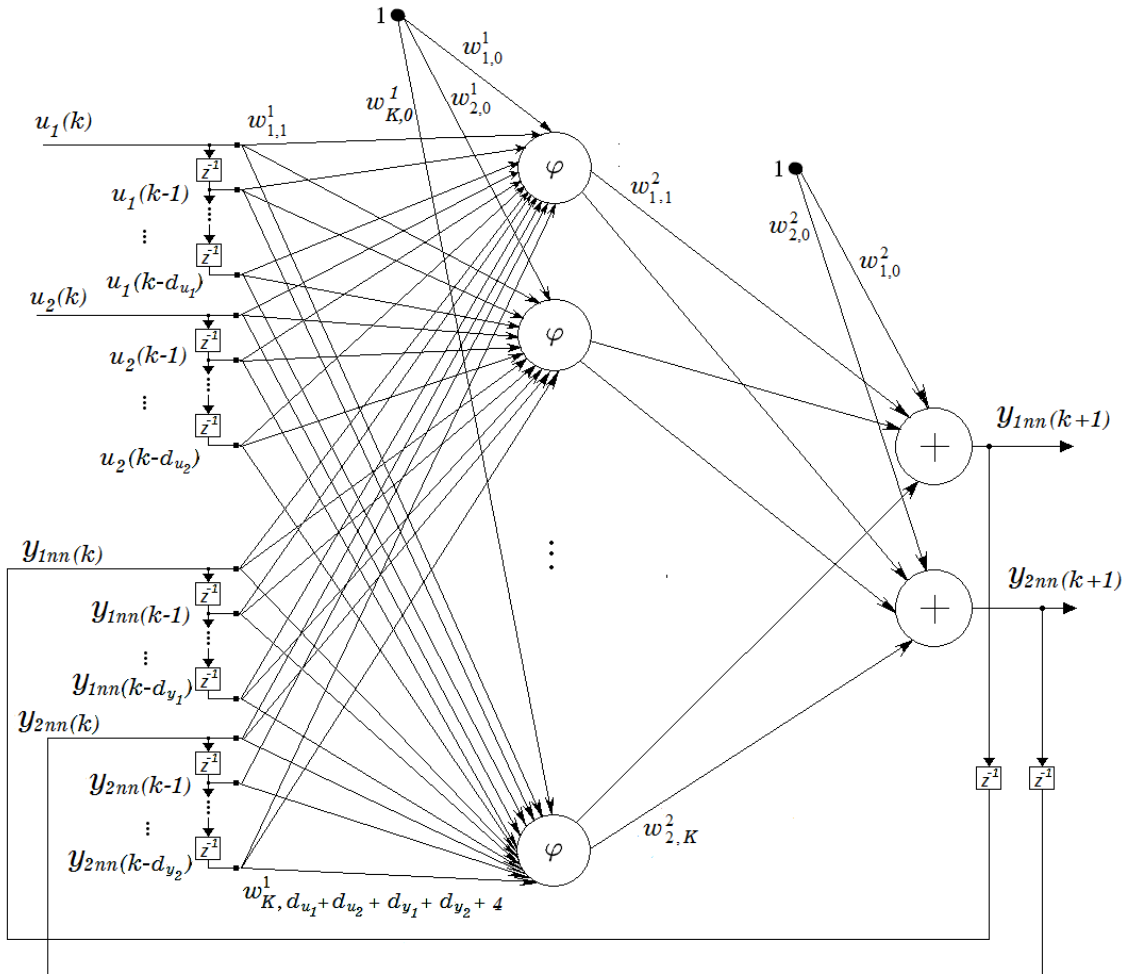


Figura 3.5. Modelo de rede neural NARX MIMO com 2 entradas (duas entradas controladas $u_1(k)$ e $u_2(k)$), e 2 saídas recorrentes ($y_{1nn}(k+1)$ e $y_{2nn}(k+1)$).

Após definir o modelo da rede neural que mais se adapta ao problema de interesse (SISO, MISO ou MIMO) inicia-se o processo de identificação do sistema dinâmico que normalmente tem duas fases: a fase de treinamento e a fase de operação.

a) Fase de treinamento: aqui são utilizados os dados em pares entrada-saída e um algoritmo de aprendizagem para alcançar o menor erro quadrático médio (*Medium Square Error - MSE*) definido previamente. Durante a fase de treinamento, dois modelos de configuração são possíveis: o modelo série-paralelo e o modelo paralelo (JANCZAK, 2005; ŁAWRYŃCZUK, 2014; NARENDRA; PARTHASARATHY, 1990).

- **Modelo de identificação série-paralelo:** neste modelo de treinamento é utilizado o sinal de saída da planta como entrada, junto com as outras entradas da rede neural. Esta configuração é chamada de modelo não-recorrente ou modelo de um passo a frente. Segundo Narendra e Parthasarathy (1990) este método é o mais recomendado para o treinamento das redes neurais e para a identificação de sistemas dinâmicos (Fig. 3.6).

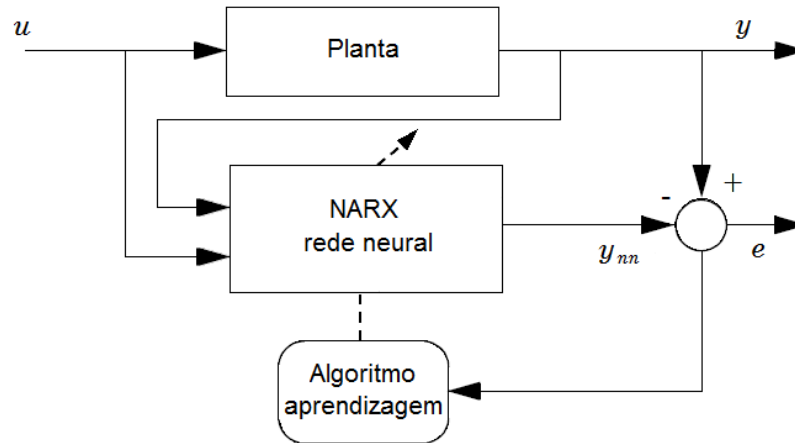


Figura 3.6. Configuração de identificação em série-paralelo.

A equação de identificação para o modelo série-paralelo em modelo SISO é dada por:

$$y_{nn}(k+1) = f(u(k), u(k-1), \dots, u(k-n_A), \dots, y(k), y(k-1), \dots, y(k-n_B))^T \quad (3.22)$$

onde $u(k)$ é a entrada ao sistema, $y(k)$ é a saída da planta num instante de tempo k e $y_{nn}(k+1)$ é a saída da rede neural, n_A e n_B , são constantes que definem os atrasos do sistema e $f(\cdot)$ é uma função não-linear.

- **Modelo de identificação paralelo:** diferente do modelo anterior, aqui o modelo é chamado de modelo de treinamento recorrente e é usado para obter previsões consecutivas (múltiplos passos à frente) chamado também de modelo de simulação. Neste caso, as saídas calculadas pela rede neural em instantes de tempo passados são utilizadas como entradas recorrentes. Segundo [Narendra e Parthasarathy \(1990\)](#) este modelo pode ser melhor utilizado na fase de operação porque permite a previsão de múltiplos passos à frente. O modelo de identificação paralelo assume a arquitetura da Fig. 3.7.

A equação de identificação para modelo SISO é dada por:

$$y_{nn}(k+1) = f(u(k), u(k-1), \dots, u(k-n_B), \dots, y_{nn}(k), y_{nn}(k-1), \dots, y_{nn}(k-n_B))^T \quad (3.23)$$

onde $u(k)$ é a entrada ao sistema, $y(k)$ é a saída da planta num instante de tempo k e $y_{nn}(k+1)$ é a saída da rede neural, n_A e n_B , são constantes que definem os atrasos do sistema e $f(\cdot)$ é uma função não-linear.

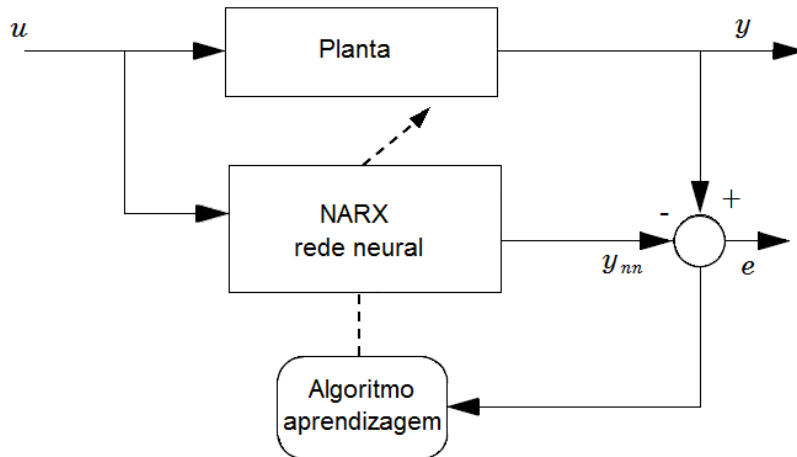


Figura 3.7. Configuração de identificação em paralelo.

b) Fase de operação: nesta fase não tem mais aprendizagem. Aqui são utilizados as matrizes dos melhores pesos e biases encontrados na fase de treinamento e que permanecerão constantes na fase de operação. Para a predição do comportamento futuro da planta estas matrizes de pesos e biases são substituídas na equação do modelo de rede neural escolhida para a predição, que pode ser: MISO, SISO ou MIMO (Eqs. (3.20), (3.19) e (3.21) respectivamente). Na fase de operação, são utilizados dados de entrada novos que normalmente a rede não conhece.

O presente estudo segue a recomendação da literatura de utilizar para a fase de treinamento o modelo série-paralelo (um passo de predição a frente) e para a fase de operação o modelo paralelo (múltiplos passos de predição a frente).

3.4.3 Implementação do modelo de rede neural NARX no algoritmo MPC

A implementação do controle preditivo baseado em redes neurais NNMPC inicia-se com o cálculo da trajetória de predição $\hat{y}(k + p|k)$ sob um horizonte de predição ($p=1, \dots, N$) através da equação geral de predição adaptada para modelo de rede neural NARX (Eq. (3.24)) (ŁAWRYŃCZUK, 2014):

$$\hat{y}(k + p|k) = y_{nn}(k + p|k) + d(k) \quad (3.24)$$

onde $\hat{y}(k + p|k)$ são os valores da trajetória predita para cada instante de tempo $k + p$ num instante k , $y_{nn}(k + p|k)$ são os valores da predição calculada mediante modelo de rede neural NARX para cada instante de tempo $k + p$ num instante k e $d(k)$ é o distúrbio não medido do sistema.

A diferença entre a trajetória de referência e a trajetória predita do sistema junto com os incrementos de controle serão minimizados na função custo sob um horizonte de predição e de controle. Assim pode-se intuir a importância de um adequado processo de identificação neural da planta de forma a garantir o sucesso do processo de controle.

Para um modelo de rede neural NARX SISO, a Eq. (3.24) pode ser expressa da seguinte forma:

$$\hat{y}(k+p|k) = w_2^0 + \sum_{i=1}^K w_i^2 \varphi(z_i(k+p|k)) + d(k) \quad (3.25)$$

onde $z_i(k+p|k)$ é a soma das entradas da camada escondida, φ é a função de transferência não-linear (tangente hiperbólica) e K número de neurônios na camada escondida:

$$z_i(k+p|k) = w_{i,0}^1 + \sum_{m=0}^{d_u} w_{m,i}^1 u(k-m) + \sum_{n=0}^{d_y} w_{n,i}^1 y_{nn}(k-n) \quad (3.26)$$

e $d(k)$ é o distúrbio não medido que é estimado pela equação seguinte:

$$\begin{aligned} d(k) &= y(k) - y_{nn}(k|k-1) \\ d(k) &= y(k) - \left(w_0^2 + \sum_{i=1}^K w_i^2 \varphi(z_i(k)) \right) \end{aligned} \quad (3.27)$$

onde $y(k)$ são os valores reais medidos da planta e $y_{nn}(k|k-1)$ são os valores de predição calculados diretamente do modelo neural num instante de tempo anterior $k-1$.

Assim, a trajetória predita, representada pela equação geral de predição $\hat{y}(k+p|k)$ esta agora expressa em função do modelo de rede neural NARX para cada instante de tempo $k+p$ num instante k .

4 CONTROLE PREDITIVO NEURAL APLICADO AO MODELO SISO (NNMPC-SISO)

Neste capítulo, apresenta-se o desenvolvimento e a aplicação do algoritmo de controle preditivo baseado em redes neurais NNMPC aplicado ao mancal híbrido para as configurações de modelo SISO. Na primeira parte do capítulo, apresenta-se a utilização de um aplicativo de controle preditivo baseado em redes neurais que está implementado no toolbox *NN Predictive Controller* no ambiente Matlab/Simulink. A segunda parte deste capítulo mostra o controle NNMPC-SISO desenvolvido através dos programas m-files. A terceira parte mostra os resultados de controle NNMPC-SISO obtidos através dos programas desenvolvidos m-files.

4.1 Controle NNMPC-SISO através de Toolbox do Matlab/Simulink

A primeira estratégia de controle preditivo proposta para controlar o sistema foi utilizar o aplicativo toolbox *NN Predictive Controller* implementado no toolbox *Neural Network* no ambiente Matlab/Simulink (versão Matlab 2015a, licença acadêmica). A Fig. 4.1 mostra o bloco que representa o aplicativo. Uma característica deste toolbox é que o modelo da planta, o processo de identificação e o controle são desenvolvidos inteiramente em ambiente Simulink. Este controlador utiliza um modelo de rede neural para prever as respostas futuras da planta e calcular os sinais de controle. Mediante um otimizador numérico são calculados os sinais de controle ótimos para o sistema em cada instante de tempo. O modelo da planta deve ser treinado *off-line* através de algum algoritmo de treinamento.

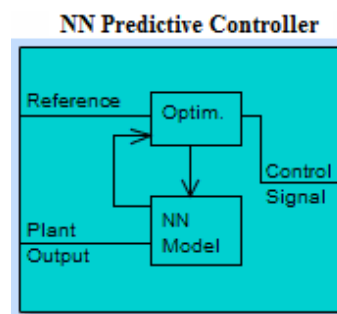


Figura 4.1. Bloco de Controle Preditivo baseado em Redes Neurais (*NN Predictive Controller*).

A seguir, a Fig. 4.2 mostra a tela principal do toolbox *NN Predictive Controller*. Aqui são definidos os parâmetros do controle preditivo: horizonte de controle (N_u), horizonte de custo (N_2), fator de ponderação (ρ) e otimização do controle (α). Aqui são modificados os parâmetros e testado o controle até ele convergir numa solução adequada.

A janela de identificação da planta (*Plant identification*) é mostrada na Fig. 4.3. Esta é a etapa mais importante do processo de controle. Aqui é importante gerar a quantidade suficiente de dados de entrada da planta e que estejam dentro da frequência de operação do sistema dinâmico.

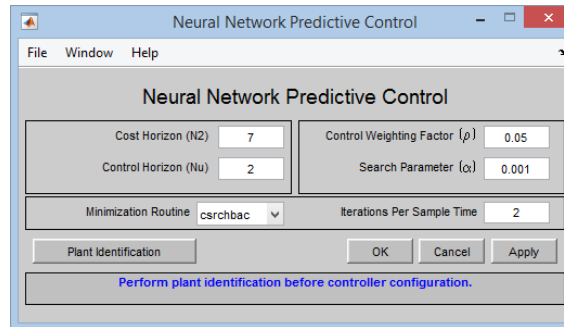


Figura 4.2. Janela do controlador preditivo com os parâmetros de controle.

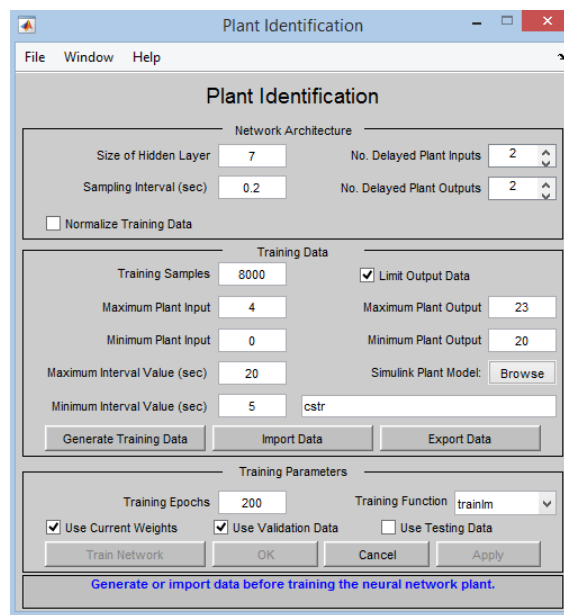


Figura 4.3. Janela de Identificação da planta para o controle preditivo.

A qualidade do controle final depende diretamente de uma adequada identificação e este depende da quantidade e qualidade da geração de dados entrada/saída. A janela de identificação tem três grupos de dados necessários:

- **Arquitetura da rede neural (Network Architecture):** o modelo neural da planta tem uma camada escondida. São definidos a quantidade de neurônios desta camada, o número de atrasos da entrada e da saída da planta junto com o intervalo de amostragem. A opção de normalização de dados de treinamento pode ser ativada aqui.
- **Dados de treinamento (Training Data):** nesta opção são gerados os dados de entrada que são utilizados no treinamento, validação e teste em base a um modelo de planta desenvolvida em Simulink (dados simulados). A geração dos dados de entrada da planta são de forma aleatória entre valores máximos e mínimos definidos pelo usuário e aplicados ao modelo para obter a saída do sistema. Finalmente os dados de treinamento são expressados em pares entrada/saída e aplicados à rede neural. Nesta janela também são definidos diversos parâmetros com os valores máximos e mínimos de entrada e saída da planta, os

valores dos intervalos máximos e mínimos de amostragem. A opção de importar e exportar dados para o treinamento também pode ser ativada.

- **Parâmetros de treinamento (Training Parameters):** aqui são definidos os períodos de treinamento (épocas) e o algoritmo de treinamento. A utilização dos pesos da rede neural, dados para o validação e o teste também são definidos aqui.

A janela de geração de dados de entrada para o treinamento é mostrada na Fig. 4.4, onde a amplitude é aleatória entre valores definidos previamente e aplicados ao modelo da planta em Simulink. A saída da planta é obtida e guardada para formar os pares entrada/saída. Esses dados devem estar dentro do intervalo de frequências onde o sistema trabalha.

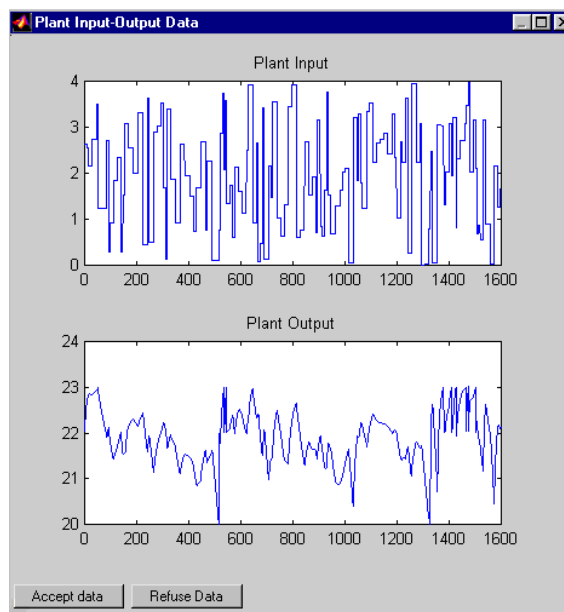


Figura 4.4. Janela de geração dos dados para treinamento da rede neural.

4.1.1 Controle Preditivo neural aplicado ao mancal híbrido em modelo SISO

Como primeira etapa do controle do sistema dinâmico, foi proposto o desenvolvimento do controle preditivo neural aplicado ao mancal híbrido em modelo SISO quando o rotor está na posição horizontal. Esse modelo SISO é composto por dois atuadores eletromagnéticos instalados simetricamente nas duas sapatas na direção vertical do mancal. Esse sistema tem um par de forças electromagnéticas em direções opostas e possui um grau de liberdade do eixo, como mostrado na Fig. 4.5.

Quando o rotor esta no centro geométrico do mancal híbrido a distância entre o rotor e os atuadores eletromagnéticos (sapatas) é h_0 (em cima e embaixo). A posição de equilíbrio estático é $\delta_{est} = mg/k_{yy}$. Sendo assim, a equação do sistema dinâmico para modelo SISO simplificado (desprezando os efeitos cruzados do acoplamento) incluindo a dinâmica dos dois atuadores eletromagnéticos é dada pela Eq. (4.1):

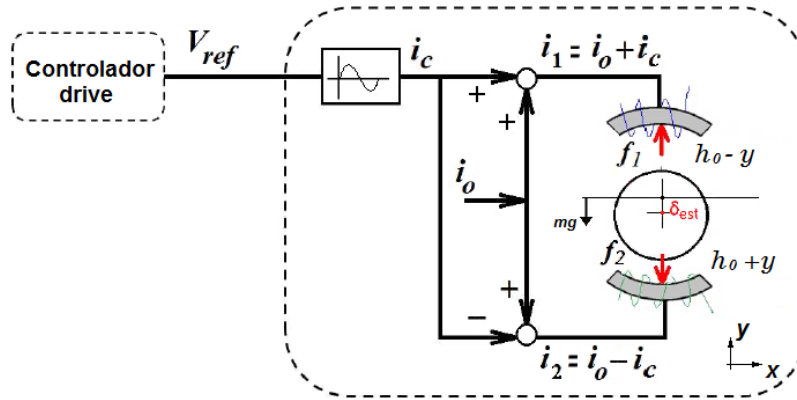


Figura 4.5. Mancal híbrido de um grau de liberdade do eixo para modelo SISO.

$$m\ddot{y} + d_{yy}\dot{y} + k_{yy}y = mg + f_m + f_{ext} \quad (4.1)$$

onde m é a massa do eixo, c_{yy} é o coeficiente de amortecimento equivalente do filme de óleo, k_{yy} é o coeficiente de rigidez equivalente do filme de óleo, f_m é a força magnética resultante dos dois atuadores e f_{ext} é a força externa (desbalanço). Os coeficientes do mancal foram obtidos das tabelas de [Someya \(1989\)](#) para um modelo de mancal aproximado ao do nosso estudo.

O sistema tem uma corrente bias i_0 (corrente de ativação) e uma corrente de controle i_c na combinação de ambas as correntes teremos as correntes: $i_1 = (i_0 + i_c)$ e $i_2 = (i_0 - i_c)$, uma dependente da outra que ativam os atuadores segundo a necessidade do controle. Assim, a força eletromagnética resultante é dada pela equação:

$$f_m = \left(\frac{i_0 + i_c}{h_0 - y}\right)^2 - \left(\frac{i_0 - i_c}{h_0 + y}\right)^2 \quad (4.2)$$

e a força externa que neste caso é a força de desbalanço:

$$f_{ext} = me\Omega^2 \sin(\Omega t) \quad (4.3)$$

Desta forma, tem-se a equação do sistema dinâmico para modelo SISO considerando a dinâmica dos dois atuadores eletromagnéticos que estão em função das correntes de controle e de ativação:

$$m\ddot{y} + d_{yy}\dot{y} + k_{yy}y = mg + \left(\frac{i_0 + i_c}{h_0 - y}\right)^2 - \left(\frac{i_0 - i_c}{h_0 + y}\right)^2 + me\Omega^2 \sin(\Omega t) \quad (4.4)$$

A Eq. (4.4) será implementada no ambiente Simulink para a geração dos dados de entrada/saída utilizados no treinamento da rede neural e finalmente à aplicação do controle preditivo neural.

Mancal híbrido em modelo SISO desenvolvido em ambiente Matlab/Simulink:

Considerando a equação do sistema dinâmico para modelo SISO (Eq. (4.4)) implementou-se no Simulink o modelo de planta para um grau de liberdade (duas sapatas instaladas na vertical, Fig. 4.6). Esse modelo da planta atualiza os valores instantâneos da rigidez e amortecimento do filme de óleo segundo o deslocamento que o rotor tenha num determinado instante de tempo. Desta forma, a não-linearidade presente na lubrificação hidrodinâmica do mancal é considerada nos coeficientes dinâmicos equivalentes k_{yy} e d_{yy} . A velocidade de rotação do sistema pode ser modificada na faixa de operação do sistema. Neste caso, o sistema foi testado com 30 Hz (1800 rpm) de velocidade de rotação. A dinâmica dos atuadores é também representada neste modelo. O controle preditivo neural para modelo SISO é desenvolvido tendo como base o modelo da planta em Simulink (Matlab 2015a, licença acadêmica), Fig. 4.6, e utilizando o bloco de controle preditivo neural (*NN Predictive Controller*) como mostra a Fig. 4.7. Devem ser definidos os valores dos parâmetros do controlador (horizonte de controle, horizonte de predição, fator de ponderação λ , etc) inicialmente na base da tentativa e erro.

O primeiro passo para utilizar o toolbox do controlador preditivo neural (*NN Predictive Controller*) é realizar a identificação da planta. A janela de identificação (Fig. 4.8) possui três campos: a arquitetura da rede neural (*Network Architecture*), os dados para o treinamento (*Training Data*) e os parâmetros de treinamento (*Training Parameters*). Desta janela de identificação utiliza-se inicialmente apenas o campo dos dados para o treinamento (*Training Data*). Aqui são definidos diversos parâmetros, como: máximo e mínimo valor de entrada, máximo e mínimo valor de intervalo, amplitude, frequência e número de amostras para o treinamento. Após definidos esses valores, são gerados os dados de entrada (*Generate Training Data*) que serão aplicados ao modelo da planta representada em Simulink e, enfim, são obtidos os dados de saída da planta. Assim, são conformados os pares de dados entrada/saída que serão utilizados para o treinamento da rede neural necessários na posterior identificação da planta. O segundo passo consiste em definir as características da rede neural (*Network Architecture* - Fig. 4.8), como o tamanho de rede, número de atrasos da entrada e saída, e o intervalo de amostragem. Aqui também se localiza a aba utilizada para a normalização dos dados de treinamento, quando necessário. O terceiro passo consiste na configuração dos parâmetros de treinamento (*Training Parameters*) como as épocas de treinamento e a função de treinamento (algoritmo de treinamento). Finalmente, preenchendo todas as abas pode-se começar com o processo de treinamento da rede neural.

No processo de identificação do mancal híbrido em modelo SISO, foram realizadas inúmeras tentativas para identificar a planta representada em Simulink. No entanto, os resultados obtidos não foram coerentes. Uma outra tentativa foi normalizando os dados entrada/saída (Fig. 4.8) ativando a aba *Normalize Training Data* da arquitetura da rede neural (*Network Architecture*), pois os dados de entrada (na faixa de $\pm 2,0$ V) e os dados de saída (deslocamento do rotor expressado em microns) estão em escalas diferentes. No entanto, normalizando os dados de treinamento não obtivemos resultados satisfatórios na identificação do sistema dinâmico.

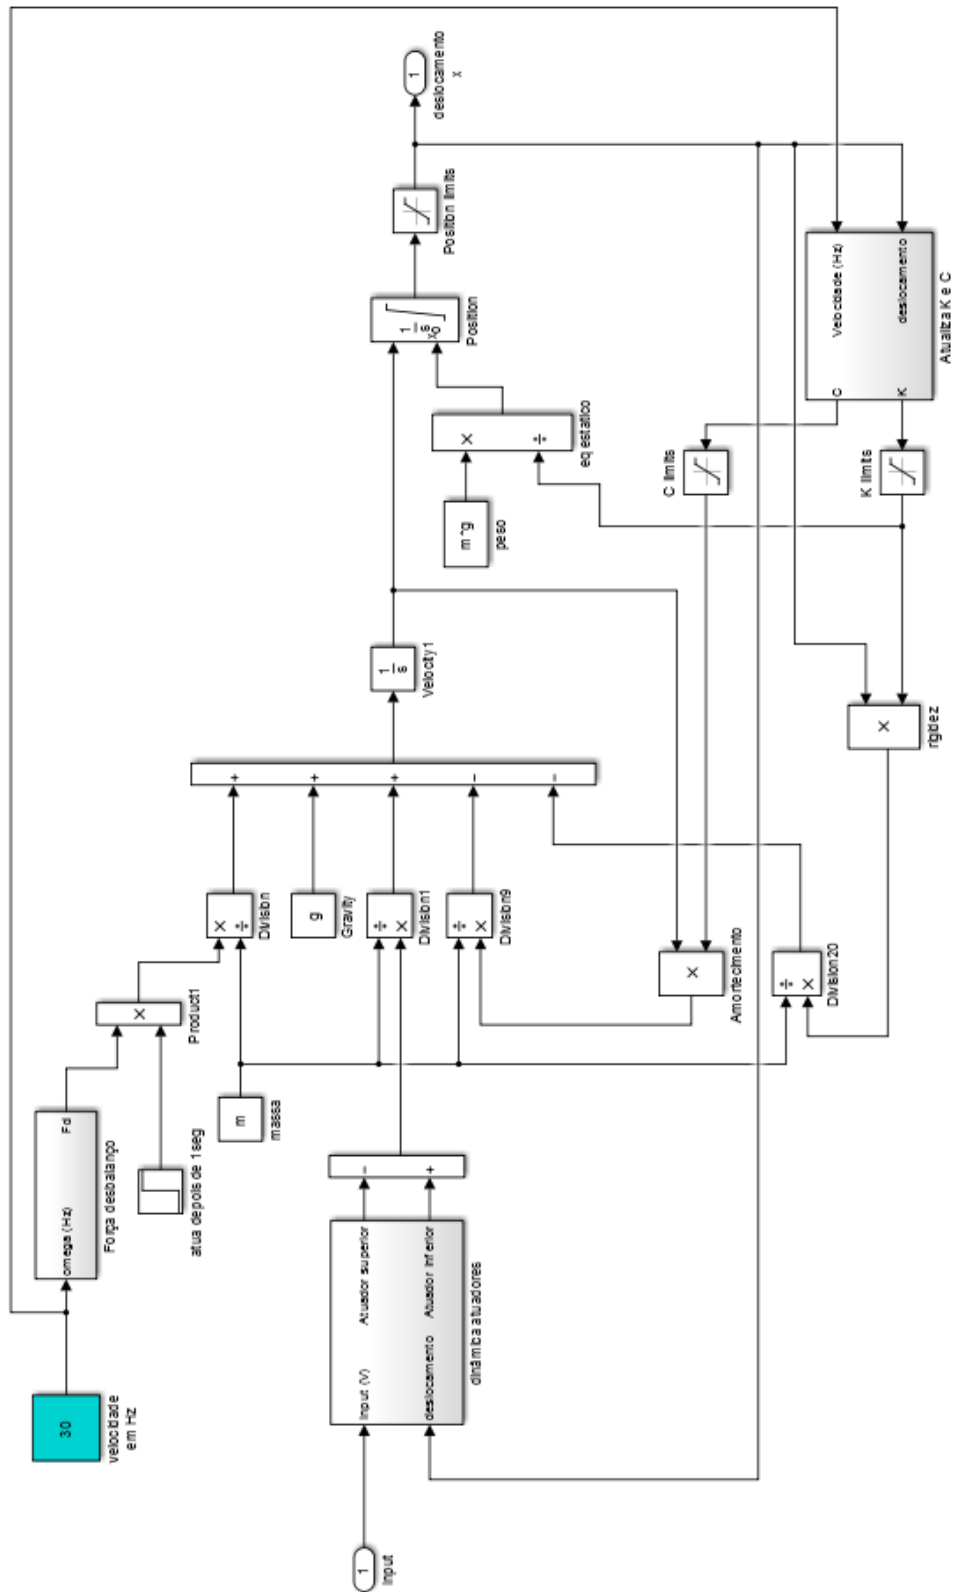


Figura 4.6. Sistema mancal híbrido modelo SISO desenvolvido em Simulink.

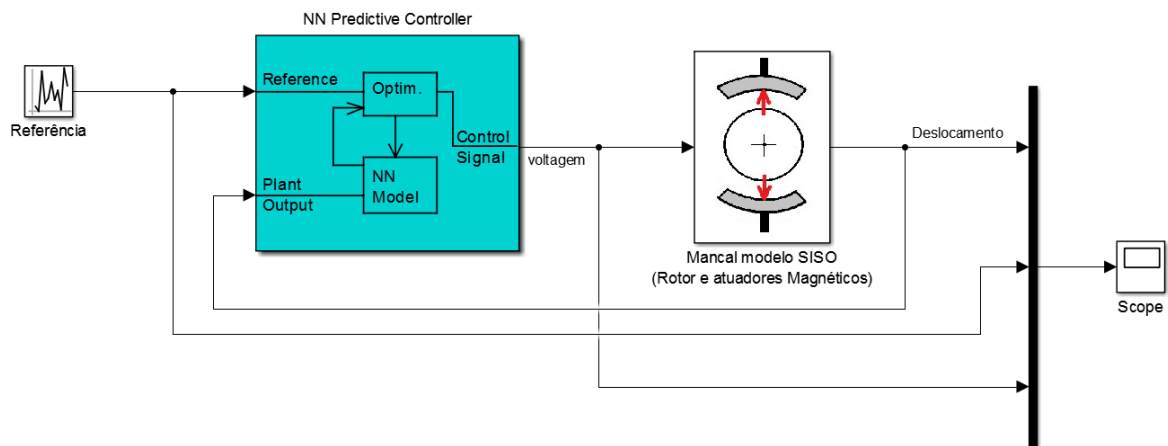


Figura 4.7. Toolbox de controle preditivo neural aplicado ao mancal híbrido modelo SISO.

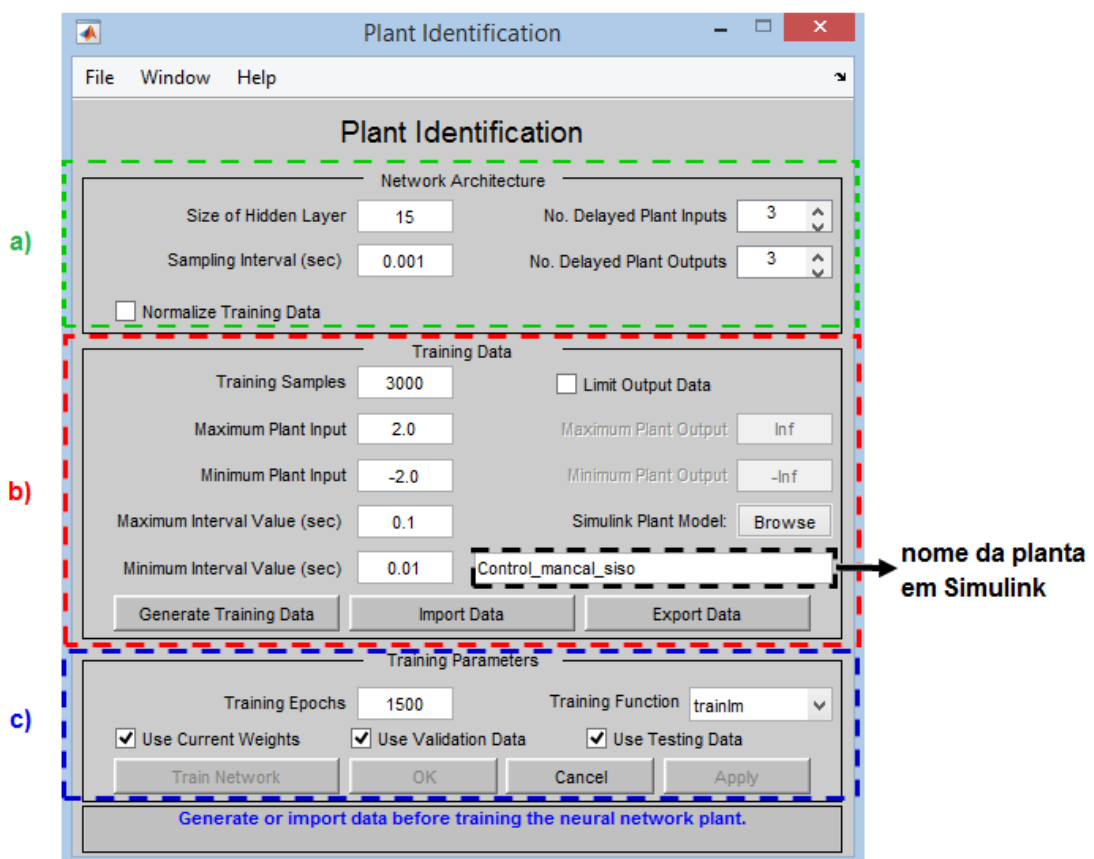


Figura 4.8. Janela de identificação para o mancal híbrido modelo SISO: a) Arquitetura da rede neural, b) Dados de treinamento, c) Parâmetros de treinamento.

No processo de normalização dos dados, surgiu a dúvida sobre qual seria a faixa de normalização utilizada pelo toolbox. Sendo assim, procurou-se o código fonte do programa encarregado do processo de identificação (arquivo: *nnident.m*, Matlab 2015a), e dentro dele a rotina de normalização dos dados. Nesta rotina, mediante a função *mapminmax* são normalizados os dados. Os valores mínimo e máximo da entrada: *minp* e *maxp*, e para os dados de saída: *mint* e *maxt*.

```

1812 % Inputs and targets are preprocessed so that minimum is -1
1813 % and maximum is 1
1814 % if Normalize
1815 [U,up] = mapminmax(tr_dat.U');
1816 U = U'; minp = up.xmin; maxp = up.xmax;
1817 [Y,yp] = mapminmax(tr_dat.Y');
1818 Y = Y'; mint = yp.xmin; maxt = up.xmax;
1819
1820 set(H.minp_ptr,'userdata',minp);
1821 set(H.maxp_ptr,'userdata',maxp);
1822 set(H.mint_ptr,'userdata',mint);
1823 set(H.maxt_ptr,'userdata',maxt);
1824
1825 % else
1826 % ODJ 6/30/99 We need the parameters minp,maxp,mint,maxt for latter simulations.
1827 if Normalize ~= 1
1828     Y=tr_dat.Y;
1829     U=tr_dat.U;
1830 end

```

Figura 4.9. Erro na rotina de normalização de dados do programa de identificação (*nnident.m*, versão Matlab 2015a) da janela *Plant Identification* do toolbox *NN Predictive Controller*.

Após o análise da rotina de normalização (arquivo: *nnident.m*, Matlab 2015a) achou-se um pequeno erro na atribuição do valor máximo dos dados de saída *maxt* que por engano atribui-se o valor do *maxp*. A Fig. 4.9 mostra o erro encontrado na rotina de normalização do programa de identificação que utiliza o toolbox *NN Predictive Controller*.

O controle preditivo utilizando o bloco de controle preditivo neural (*NN Predictive Controller*) para modelo SISO não teve resultados satisfatórios. Embora, obteve-se uma pequena melhoria no processo de identificação da planta (após corrigir o erro na rotina de normalização de dados), o resultado do processo de controle não acompanhou esta melhoria. O toolbox de controle preditivo neural é desenvolvido para sistemas com modelo SISO. Devido a isso se tem pouca versatilidade para manipular parâmetros como: as matrizes de pesos e biases para avaliar na equação da rede neural, e, o número de entradas e de saídas para futuras identificações em modelo MIMO.

Acredita-se que, a dificuldade em obter uma boa identificação da planta seja devido a que o sistema mancal híbrido é fortemente não-linear (por utilizar os atuadores eletromagnéticos e o filme de óleo, Eq. (4.4)), e que é preciso otimizar o processo de treinamento da rede neural. Assim, pode-se personalizar o processo de treinamento neural que teria como vantagens: geração de dados de treinamento (com comprovação da faixa de frequência de interesse), treinamento personalizado (com incremento de entradas, normalização de dados, uso do toolbox de treinamento (*Neural Network Training*) e principalmente a aplicação para modelo MIMO). Lembrando que o processo de controle preditivo depende fortemente da qualidade da identificação, então ao otimizar a identificação neural da planta as chances de sucesso no processo de controle aumentam.

4.2 Controle NN MPC-SISO através de programa m-files

A seguir, apresenta-se o desenvolvimento do controle preditivo neural para modelo SISO do mancal híbrido utilizando o Script do Matlab.

4.2.1 Identificação neural do sistema dinâmico modelo SISO

O modelo utilizado para a identificação de sistemas não-lineares tipo SISO é uma rede neural recorrente tipo NARX (*Non-Linear Auto-Regressive with exogenous inputs*) e a topologia de rede neural mais empregada é a rede *Perceptron* multicamadas (*Multilayer Perceptron-MLP*). Como mencionado, o procedimento de identificação mediante redes neurais consiste em três passos: seleção da arquitetura do modelo (escolha do número de neurônios, número de atrasos e de camadas escondidas), treinamento de modelo (obtenção dos pesos e *bias* dos neurônios) e a validação do modelo (utilizando dados novos nunca vistos pela rede neural). A abordagem mais segura é optar por formar uma série de modelos neurais variando o número de neurônios e, se for o caso, de camadas escondidas. Considerando um conjunto de treinamento composto por p amostras, a medição do desempenho da identificação é efetuada por meio da avaliação do erro quadrático médio - EQM, definido por:

$$EQM(w) = \frac{1}{p} \sum_{k=1}^p (d^{(k)} - u)^2 \quad (4.5)$$

onde $d^{(k)}$ é o valor desejado para a k -ésima amostra de treinamento, u é o valor real obtido e p é o número de amostras.

Segundo Haykin (1999) o Teorema de Aproximação Universal é diretamente aplicável as redes MLP. Demonstra-se então que uma topologia com uma única camada neural escondida é suficiente para mapear qualquer função contínua, não ideal em termos de tempo mas sim em termos de generalização. Assim, para a identificação do processo em modelo SISO utilizou-se uma rede neural tipo NARX com uma camada escondida, como mostra a Fig. 4.10.

O treinamento é composto por fase de aprendizado e a fase de teste. Este treinamento foi realizado seguindo a recomendação da literatura, ou-seja, considerando as condições de memorização excessiva (*overfitting* ou *overtraining*), que é quando a rede neural memoriza os dados mas não os generaliza adequadamente. Isto é percebido com a diferença que tem os erros quadráticos medios (EQM) que é menor na fase de aprendizado e muito maior na fase de teste (HAGAN et al., 2014). Em contrapartida um número mínimo de neurônios pode ser insuficiente para a extração das características do sistema, configurando assim uma condição de *underfitting*. Neste caso os erros quadráticos na fase de aprendizado e teste são bem altos (SILVA; SPATTI; FLAUZINO, 2010). A topologia de rede neural é treinada *off-line* de modo supervisionado com dados apresentados na forma de pares entrada/saída. O algoritmo de aprendizagem utilizado foi o *Levenberg-Marquardt* (HAGAN; MENHAJ, 1994).

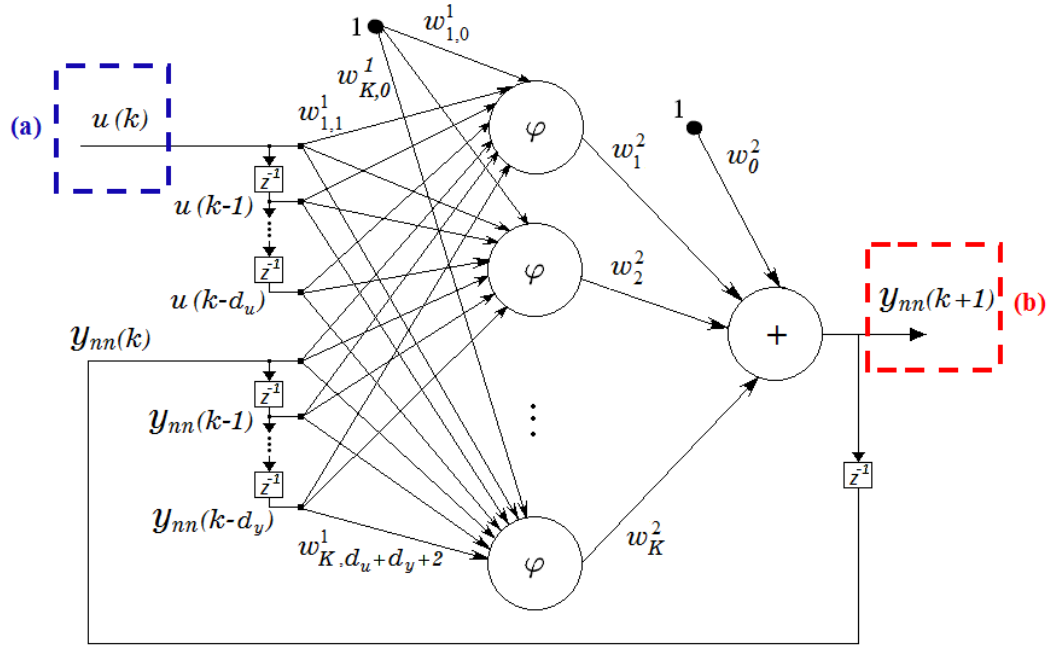


Figura 4.10. Modelo de rede neural NARX SISO: (a) entrada controla, (b) saída recorrente.

4.2.2 Linearização do modelo SISO do mancal híbrido ativo

De forma a melhorar o desempenho do sistema de controle, optou-se por linearizar o modelo SISO do mancal híbrido em torno de um ponto de operação do mancal. Trata-se de uma estratégia comumente adotada em mancais magnéticos (SCHWEITZER; MASLEN, 2009). Do sistema mancal híbrido com um grau de liberdade (translação na vertical) foi obtida a equação do sistema dinâmico que inclui a dinâmica dos dois atuadores eletromagnéticos, mostrada na Eq. (4.4). Nesta etapa, emprega-se esta equação, mas expressa no domínio de Laplace (modelo SISO). Sendo assim, é necessário considerar algumas hipóteses para a linearização da força em um ponto de operação específico (o Apêndice-A mostra o detalhe da linearização). Enfim, tem-se:

$$m\ddot{y} + c_{yy}\dot{y} + k_{yy}y - K_y y = K_i i \quad (4.6)$$

onde o K_i é chamado de coeficiente de rigidez da corrente e é definido como:

$$K_i = \frac{2i_0}{(h_0 - \delta_{est})^2} - \frac{2i_0}{(h_0 + \delta_{est})^2} \quad (4.7)$$

e K_y é chamado de coeficiente de rigidez da posição e esta definido por:

$$K_y = \frac{2i_0^2}{(h_0 - \delta_{est})^3} - \frac{2i_0^2}{(h_0 + \delta_{est})^3} \quad (4.8)$$

Tabela 4.1 – Parâmetros de ajuste do atuador eletromagnético (encontrados experimentalmente).

Parâmetros	Valores
\bar{a}_0	5,3310e-3
\bar{a}_1	4,9047e-5
\bar{b}_0	2,6 Ω
\bar{b}_1	0,095 H

Assim, transformando-se a Eq. (4.6) no domínio Laplace, obtém-se:

$$mY(s)s^2 + c_{yy}Y(s)s + k_{yy}Y(s) - K_yY(s) = K_iI(s) \quad (4.9)$$

O princípio de funcionamento dos atuadores baseia-se numa configuração de dois polos, de tal forma que eles podem atrair o rotor ao longo do eixo-Y. Os atuadores eletromagnéticos são acionados de acordo com a tensão do controlador: quando o sinal de controle é $\pm 10V$ a força máxima é obtida. [Pizarro-Viveros e Nicoletti \(2014\)](#) apresentam um modelo experimental ajustado das forças electromagnéticas dos atuadores. Esta força é uma função da corrente elétrica no enrolamento e o entreferro. A corrente elétrica no enrolamento é função da tensão de referência no *drive* do atuador, na forma:

$$i = \left(\frac{j\omega\bar{a}_1 + \bar{a}_0}{j\omega\bar{b}_1 + \bar{b}_0} \right) v_{ref} \quad (4.10)$$

onde i é a corrente elétrica no enrolamento do atuador, v_{ref} é a tensão de referência do drive. Os coeficientes ajustados \bar{a}_0 e \bar{a}_1 junto com os coeficientes \bar{b}_0 e \bar{b}_1 , que representam a resistência e a indutância equivalente do atuador respetivamente, são mostrados na Tabela (4.1). Agora, levando a equação da corrente no enrolamento Eq. (4.10) no domínio de Laplace tem-se:

$$I(s) = \left(\frac{s\bar{a}_1 + \bar{a}_0}{s\bar{b}_1 + \bar{b}_0} \right) V_{ref}(s) \quad (4.11)$$

Substituindo-se a Eq. (4.11) na Eq. (4.9) obtemos:

$$mY(s)s^2 + c_{yy}Y(s)s + k_{yy}Y(s) - K_yY(s) = K_i \left(\frac{s\bar{a}_1 + \bar{a}_0}{s\bar{b}_1 + \bar{b}_0} \right) V_{ref}(s) \quad (4.12)$$

Assim, obtém-se a função de transferência da planta no domínio de Laplace. Esta equação representará a dinâmica do sistema incluindo os dois atuadores eletromagnéticos:

$$\frac{Y(s)}{V_{ref}(s)} = \frac{K_i(s\bar{a}_1 + \bar{a}_0)}{(s\bar{b}_1 + \bar{b}_0)(ms^2 + c_{yy}s + (k_{yy} - K_y))} \quad (4.13)$$

Esta equação linearizada (Eq. (4.13)) deverá ser transformada na forma de equação de diferenças e será utilizada exclusivamente como a planta a ser controlada. Cabe lembrar que para o treinamento da rede neural no processo de identificação, utilizaram-se os dados entrada/saída gerados mediante a equação não-linear da planta Eq. (4.4) de um modelo implementado no ambiente Simulink (neste estágio não se tem dados experimentais para modelo SISO).

A equação de diferenças é mostrada a seguir:

$$A(q^{-1})y_m(k) = B(q^{-1})u(k-1) \quad (4.14)$$

$$A_{m,m}(q^{-1}) = 1 + a_1^m q^{-1} + \dots + a_{n_A}^m q^{-n_A} \quad (4.15)$$

$$B_{m,s}(q^{-1}) = b_1^{m,s} q^{-1} + \dots + b_{n_B}^{m,s} q^{-n_B} \quad (4.16)$$

Assim, tem-se a equação que representará a saída da planta expressa em função dos coeficientes da equação de diferenças:

$$y_m(k) = \sum_{l=1}^{n_B} b_l^{m,s} u(k-l) - \sum_{l=1}^{n_A} a_l^m y_m(k-l) \quad (4.17)$$

onde a_l, b_l são coeficientes e n_A, n_B define a ordem do sistema dinâmico.

A equação do modelo de rede neural NARX-SISO é dada por:

$$y_{nn}(k) = w_0^2 + \sum_{i=1}^K w_i^2 \varphi(w_{i,0}^1 + \sum_{j=1}^{n_u} w_{i,j}^1 u_j(k)) \quad (4.18)$$

Esta rede neural tem entradas $n_u(u_1, \dots, u_{n_u})$, com K neurônios na camadas oculta e a função de transferência não-linear $\varphi: \mathbb{R} \rightarrow \mathbb{R}$ e a saída $y_{nn}(k)$. A primeira camada é a soma dos sinais de entrada ligados aos i -ésimos ($i=1, \dots, K$) neurônios escondidos. Os pesos são indicadas por $w_{i,j}^1$, onde $i = 1, \dots, K$ e $j = 0, \dots, n_u$ os pesos da segunda camada são denotados por $w_{i,j}^2$, onde $i = 0, \dots, K$.

4.2.3 Pre-processamento dos dados do treinamento

O treinamento da rede neural NARX SISO para a identificação do sistema híbrido começa com o pré-processamento do conjunto de dados em pares entrada/saída. Este conjunto de dados geralmente possui diferentes ordens de grandeza e precisa ser normalizado. Isso de forma a contribuir na obtenção de melhores taxas de aprendizado. As faixas de interesse para a normalização podem estar no intervalo -1 a 1 ou no intervalo de 0 a 1, dependendo do tipo de dados e da função de ativação utilizada.




Figura 4.11. O princípio de normalização (Teorema de Tales) aplicado a faixa de -1 a 1.

O princípio de normalização utilizado é do Teorema de Tales ou dos segmentos proporcionais (HAGAN et al., 2014). Este princípio é mostrado na Fig. 4.11. Observa-se como exemplo o intervalo de -1 a 1 dado que a função de ativação corresponde a tangente hiperbólica (\tanh) tem esses limites. Sendo assim, é aplicado o Teorema de Tales obtendo-se a Eq. (4.19):

$$\frac{x - x_{min}}{x_{max} - x_{min}} = \frac{x_n - (-1)}{1 - (-1)} \quad (4.19)$$

Rearranjando-se a equação anterior a fim de se obter a equação utilizada no processo de normalização, tem-se:

$$x_n = \frac{2(x - x_{min})}{x_{max} - x_{min}} - 1 \quad (4.20)$$

onde x_n é o vetor normalizado (na faixa -1 a 1), x é a vetor de dados originais, x_{min} é o valor mínimo do conjunto de dados e x_{max} é o valor máximo do vetor de entrada.

Considerando-se que a normalização é um processo reversível, tem-se que a seguinte equação é utilizada para o processo de desnormalização:

$$x_{un} = \frac{(x_n + 1)(x_{max} - x_{min})}{2} + x_{min} \quad (4.21)$$

onde x_{un} é o vetor com dados desnormalizados. Esta equação converte as respostas da rede neural nos valores reais da aplicação.

Levando em consideração os aspectos de pré-processamento dos dados antes da fase de identificação e operação da rede neural, foi desenvolvido um diagrama de blocos que mostra a sequência dessas fases do processo de identificação neural aplicado ao sistema mancal-híbrido (Fig. 4.12).

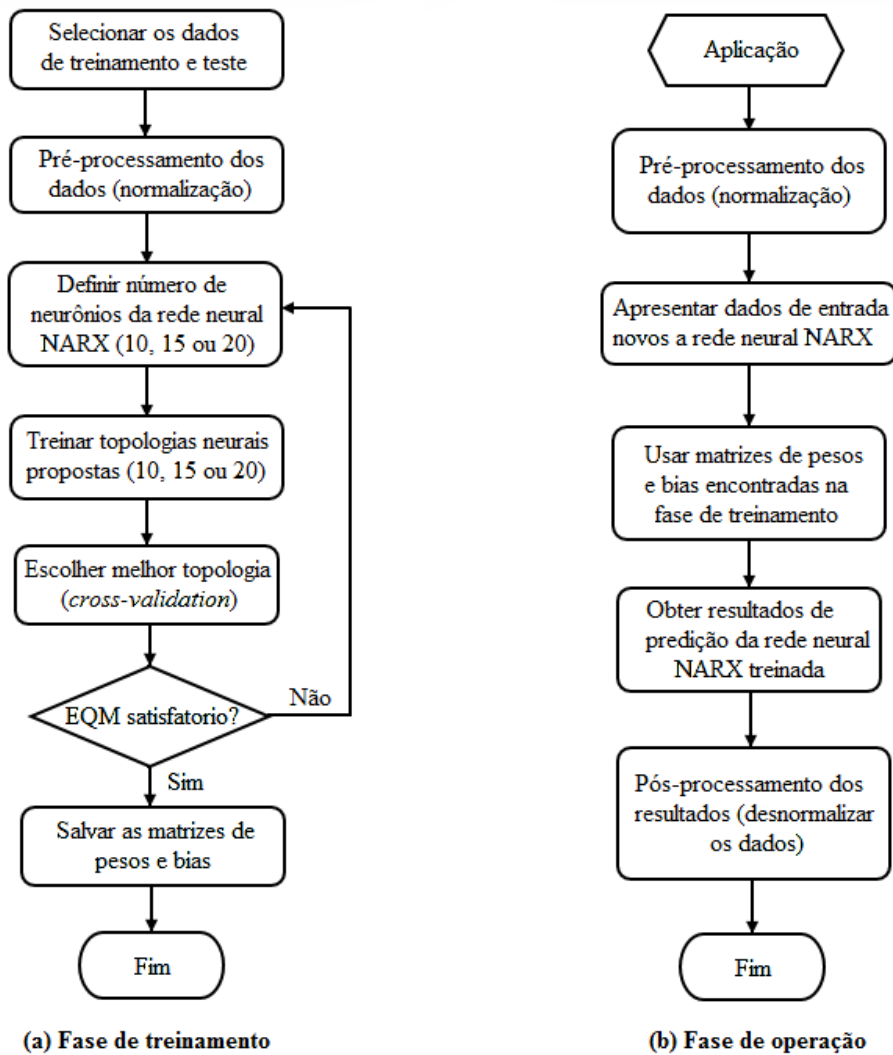


Figura 4.12. Diagrama de blocos das fases de treinamento e operação (SILVA; SPATTI; FLAUZINO, 2010).

4.3 Resultados do controle NNMP-C-SISO

Para obter os resultados de controle para o modelo SISO foi necessário primeiro obter a rigidez e o amortecimento equivalentes do filme de óleo do mancal. Someya (1989) apresenta valores de coeficientes dinâmicos para diferentes tipos de mancais segmentados, inclusive mancais segmentados de 4 sapatas em configuração de carregamento, como é o presente estudo. Estes coeficientes dinâmicos equivalentes estão descritos em função do número de Sommerfeld, mostrado na equação a seguir:

$$S = \frac{\mu \Omega L D}{W} \left(\frac{R}{C_p} \right)^2 \quad (4.22)$$

onde μ é a viscosidade dinâmica do óleo, Ω é a velocidade de rotação em Hz, D é o diâmetro do mancal, R é o raio do mancal, L é o comprimento e C_p é a folga de usinagem (diferença entre o raio da sapata e o raio do eixo).

Tabela 4.2 – Dados geométricos e de operação utilizados na análise do mancal híbrido.

massa do rotor	m	36,114	kg
raio do rotor na posição do mancal	R	40,0	mm
raio das sapatas	R_s	42,0	mm
folga radial	h_0	200	μm
folga de usinado	C_p	2000	μm
distância do pivot à superfície da sapata	Δ_s	56,8	mm
ângulo de abrangência das sapatas	α_0	69,7 °	
momento de inercia da sapata	I_s	0,0031	kg.m^2
comprimento das sapatas	L	97	mm
posicionamento das sapatas	φ_i	45°, 135°, 225 °, 315°	
momento de inercia polar do rotor	I_p	0,027	kg.m^2
momento de inercia lateral do rotor	I_t	8,194	kg.m^2
viscosidade dinâmica do óleo	μ	0,023	N.s/m^2
velocidade de rotação do rotor	Ω	30	Hz

O número Sommerfeld é um valor adimensional muito importante na análise do mancal porque considera características geométricas e operacionais (Tabela 4.2). A partir deste valor adimensional, obtêm-se a rigidez e amortecimento equivalentes. Utilizando a equação de Sommerfeld e as tabelas de [Someya \(1989\)](#) foi obtida a Fig. 4.13 para velocidades de rotação na faixa de 10-50 Hz (600 a 3000 rpm), considerando as características geométricas e operacionais do mancal ([PIZARRO-VIVEROS; NICOLETTI, 2015](#)).

Analisando a Fig. 4.13, observa-se que para valores maiores do número de Sommerfeld há menores valores de rigidez e amortecimento equivalente. Assim, é possível modificar as características dinâmicas do sistema mancal híbrido aumentando a rigidez e amortecimento equivalente de modo que as vibrações laterais sejam atenuadas. Para tanto, a estratégia de controle será estabelecer um determinado nível de rigidez e amortecimento desejados e utilizar o controlador preditivo para manter o sistema nesta condição. Isto pode ser feito mantendo-se o rotor em uma determinada posição dentro do mancal, o que, conseqüentemente, determinará o número de Sommerfeld de operação. Nos resultados a seguir, foi definida uma faixa de posições de teste do rotor entre $-50\mu\text{m}$ e $+150\mu\text{m}$.

Todas as simulações são realizadas em Matlab. O NN MPC para modelo SISO precisa resolver *on-line* e a cada instante de tempo o problema de otimização quadrática ou a minimização da função custo considerando restrições (Eq. (3.9)). A minimização da função custo foi realizada utilizando o algoritmo de programação sequencial quadrática SQP (*Sequential Quadratic Programming*), que possui uma eficiência na otimização de funções não-lineares com restrições, amplamente demonstrada na literatura. Este algoritmo está implementado no Matlab e é utilizado como a função `fmincon`. A restrição é imposta para o valor da sinal de controle: $V_{min} = -10\text{V}$ e $V_{max} = 10\text{V}$ (tensão limite do *drive* do controlador).




Figura 4.13. Relação do número de Sommerfeld com a rigidez e amortecimento equivalentes do sistema para mancal híbrido em modelo SISO.

Para o processo de identificação neural da planta em modelo SISO, primeiro são gerados os dados entrada/saída mediante simulações em malha aberta (sem controle) do modelo não-linear (Eq. (4.4)) desenvolvido no ambiente Simulink. O sinal de entrada foi a tensão ($V_x(V)$) gerada mediante pulsos aleatórios em amplitude e períodos dentro da faixa $\pm 2V$, e foi obtido como resposta do sistema o deslocamento do eixo ($Y(m)$) na ordem de microns. Do total de dados gerados, foram separados dois conjuntos de dados chamados: dados de treinamento e dados de teste. Foram geradas 5000 amostras a uma taxa de amostragem de 1 kHz (Fig. 4.14). Das 5000 amostras, 4500 foram usadas como dados de treinamento e 500 como dados de teste (verificação).




Figura 4.14. Conjunto de dados de treinamento (entrada/saída).

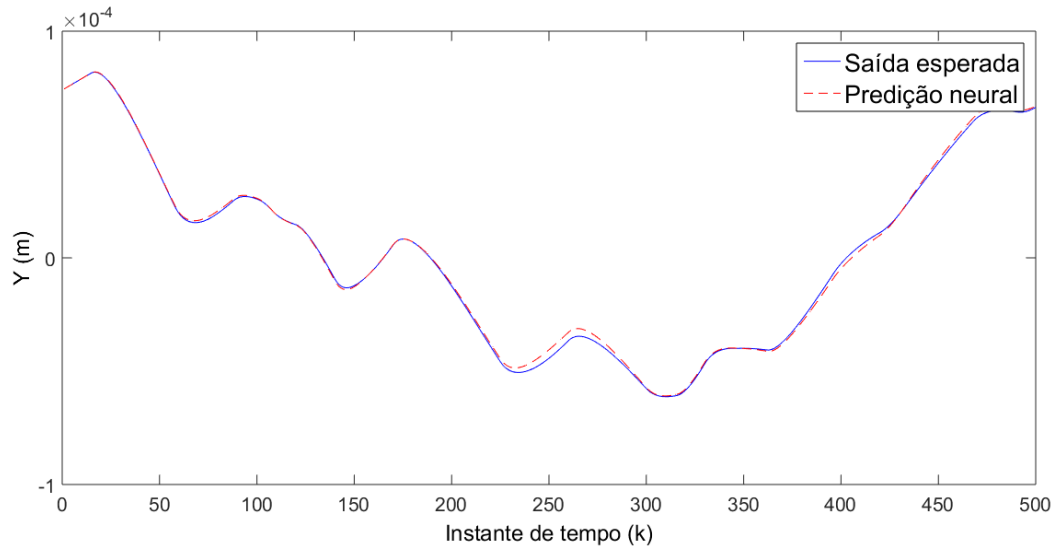


Figura 4.15. Dados de teste (500 amostras) da rede neural NARX.

Tabela 4.3 – Dados da rede neural NARX SISO.

Número de neurônios	K	10
Número de camadas escondidas	—	1
Atrasos da entrada	d_u	3
Atrasos da saída	d_y	3
Matrizes de pesos	x_1^1, x_2^2	-
Bias	x_0^1, x_0^2	-

A rede neural NARX SISO, tem uma única camada escondida e uma camada de saída. Ambas camadas têm como funções de ativação: a tangente hiperbólica e a função linear respectivamente (implementadas no Matlab como as funções: `tanh` e `purelin`). A rede neural é treinada repetidas vezes usando o algoritmo de treinamento supervisionado Levenberg-Marquardt até alcançar propriedades de generalização aceitáveis. A dinâmica da planta de terceira ordem é mostrada a seguir:

$$y_{nn}(k) = f(u(k-1), u(k-2), u(k-3), y_{nn}(k-1), y_{nn}(k-2), y_{nn}(k-3)) \quad (4.23)$$

onde os atrasos da entrada e da saída são três ($n_A = n_B = 3$). Após várias tentativas de treinamento determinou-se que 10 neurônios na camada escondida são suficientes para conseguir boas propriedades de generalização.

A generalização alcançada pela rede neural NARX-SISO foi avaliada pelo valores do Erro Quadrático Médio - EQM (Eq. (4.5)) no treinamento e no teste. Estes valores são: $EQM_{treinamento} = 5,328 \cdot 10^{-1}$, e para o teste $EQM_{teste} = 3,077 \cdot 10^{-1}$. Finalmente, é salvo um arquivo que contém as seguintes matrizes: o bias e os pesos da camada de entrada (w_{10}, w_1) e o bias e os pesos da camada de saída (w_{20}, w_2) calculadas para uma velocidade de rotação de 30 Hz. Posteriormente, esse arquivo contendo os pesos e o bias da rede neural será utilizado

na implementação do controle preditivo neural para a condição de operação do mancal em 30 Hz (1800 rpm). Com o intuito de avaliar o nível de generalização do conhecimento adquirido da rede neural, este controle será avaliado para controlar outras duas condições de operação do mancal (20 e 40 Hz), condições estas em que a rede neural não foi treinada.

Para a implementação do controle do modelo neural NARX SISO, utiliza-se o modelo linearizado da planta a controlar. Este modelo esta no domínio de Laplace (Eq. (4.13)), são substituídos os valores dos parâmetros do atuador da Tabela 4.1 e enfim obtém-se o modelo discreto linearizado da planta, definida pela equação de diferenças. Esta equação é mostrada na Eq. (4.24) para um intervalo de amostragem de 0,001 s com *zero-order hold*.

$$y(k) = b_1u(k-1) + b_2u(k-2) + b_3u(k-3) - a_1y(k-1) - a_2y(k-2) - a_3y(k-3) \quad (4.24)$$

Depois de várias tentativas de sintonização dos parâmetros do controlador NNMPC obtiveram-se os seguintes valores: $N=15$, $Nu = 3$, e $\lambda= 0,09$, sendo o horizonte de predição, horizonte de controle e fator de ajuste respectivamente, para $p = 1, \dots, N$. Foram simuladas duas condições de operação: a primeira condição, testando o sistema em condição ativa sem considerar distúrbio para as três velocidades de rotação propostas (20, 30 e 40 Hz). A segunda condição de operação testando o sistema em condição ativa mas desta vez é incluído um distúrbio externo (força de desbalanceamento), que é iniciado no instante de tempo $k = 162$.

Os resultados da primeira condição de operação estão mostrados nas Fig. 4.16 a Fig. 4.18, onde são apresentados os sinais de controle e a resposta do sistema em termos de tensão e deslocamento, respectivamente. Segundo os deslocamentos obtidos do rotor, observa-se que o controlador conseguiu manter o rotor sob a trajetória proposta o que mostra uma boa resposta do controlador perante as variações de posições da referência (lembrando que o modelo de predição por rede neural foi treinado com dados de velocidade de rotação de 30 Hz apenas). Os resultados obtidos para a velocidade de rotação maior (40 Hz) apresenta uma maior oscilação antes da estabilização na posição de referência devido a que o nível de amortecimento do filme de óleo é menor e que a identificação neural provavelmente não conseguiu representar as não-linearidades da velocidade maior.

Os resultados da segunda condição de operação (incluindo distúrbio externo ou força de desbalanceamento) e que é iniciado no instante de tempo $k = 162$ (tempo continuo kTa , onde Ta denota o período de amostragem do controlador) inicia na posição de equilíbrio definida por $\delta_{est} = mg/k_{yy}$ com número de Sommerfeld $S = 0,0147$ (Eq. (4.22)) calculado para a condição nominal de operação de 30 Hz. Os resultados mostrados nas Fig.4.21 a Fig. 4.23 apresentam os sinais de controle e a resposta do sistema em termos de tensão e deslocamento respectivamente. Observa-se, que o controlador atua e movimenta o rotor pelas trajetórias propostas, o que indica uma boa resposta do controlador perante as variações de posições da referência proposta. Principalmente do distúrbio externo para três velocidades de rotação diferentes. Os parâmetros do controlador permaneceram fixos para todas as simulações.

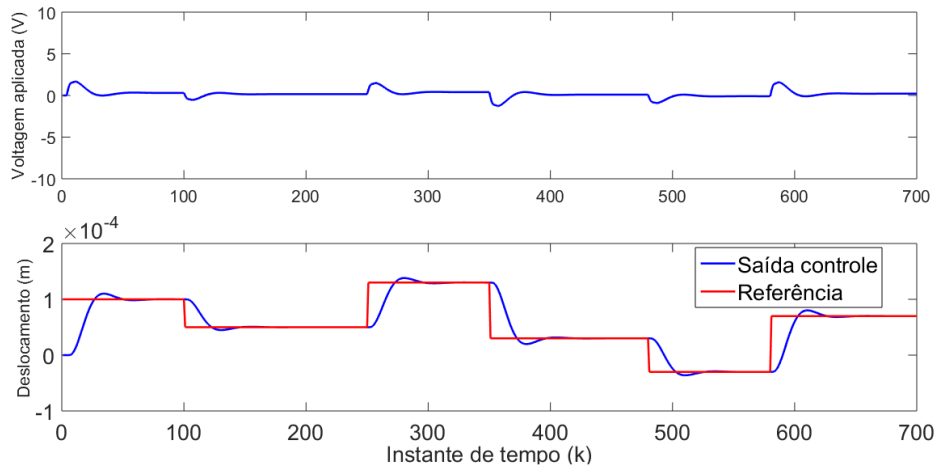


Figura 4.16. Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa sim distúrbio para 20 Hz de velocidade.




Figura 4.17. Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa sim distúrbio para 30 Hz de velocidade.




Figura 4.18. Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa sim distúrbio para 40 Hz de velocidade.




Figura 4.19. Sinal de controle NNMPC para modelo SISO das três velocidades simuladas (20, 30 e 40 Hz) do sistema rotor-mancal em condição ativa sim distúrbio.

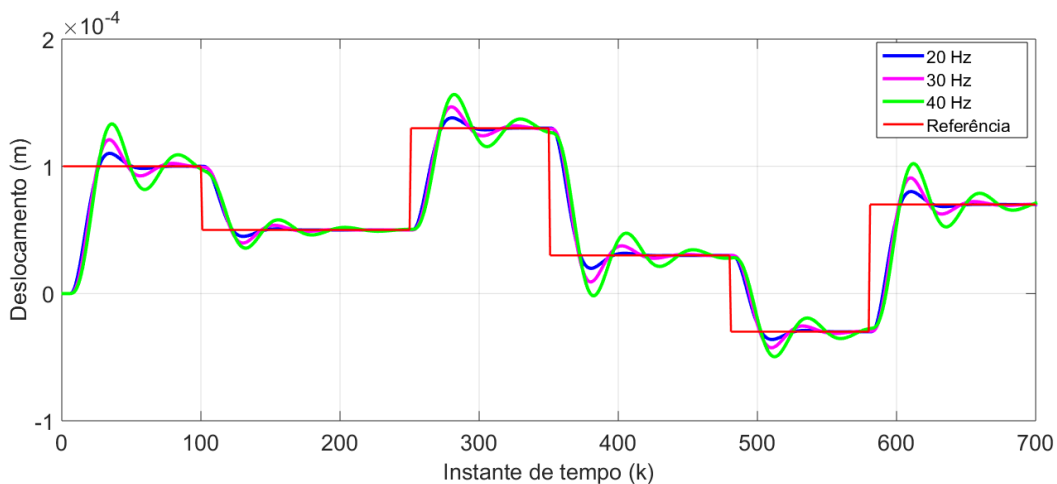


Figura 4.20. Sinal de deslocamento das três velocidades simuladas (20, 30 e 40 Hz) do sistema rotor-mancal em condição ativa sim distúrbio.

Para melhor análise agora os resultados do controle das três velocidades de rotação (20, 30 e 40 Hz) são plotados juntos. Assim temos a Fig.4.19, que mostra a tensão aplicada para controlar o sistema rotor-mancal nas três velocidades simuladas. Observa-se que a tensão aplicada para controlar o deslocamento do rotor incrementa-se quando a velocidade de rotação aumenta. A Fig.4.20, mostra o deslocamento controlado do rotor, aqui também, observa-se um incremento da amplitude da oscilação para velocidades maiores. Além disso, os três deslocamentos acompanham a referência proposta.




Figura 4.21. Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa com distúrbio externo ($k = 162$) para 20 Hz de velocidade.




Figura 4.22. Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa com distúrbio externo ($k = 162$) para 30 Hz de velocidade.




Figura 4.23. Sinal de controle NNMPC e deslocamento do sistema rotor-mancal em condição ativa com distúrbio externo ($k = 162$) para 40 Hz de velocidade.




Figura 4.24. Sinal de controle NN MPC para modelo SISO das três velocidades simuladas (20, 30 e 40 Hz) do sistema rotor-mancal em condição ativa considerando o distúrbio.




Figura 4.25. Sinal de deslocamento das três velocidades simuladas (20, 30 e 40 Hz) do sistema rotor-mancal em condição ativa considerando o distúrbio.

A Fig.4.24 e a Fig.4.25 apresentam os resultados do sinal de controle e do sinal de deslocamento respectivamente das três condições propostas.

4.4 Conclusão

Como se pode observar nos resultados obtidos para um sistema em modelo SISO aplicado ao mancal híbrido em estudo, é possível implementar um sistema de controle NN MPC (baseado em modelo de rede neural). Para tanto, o modelo de rede neural foi treinado para 30 Hz de velocidade de rotação utilizando os dados obtidos do modelo numérico não-linear representado no ambiente Simulink. A linearização do modelo numérico foi utilizada para obter o modelo da planta representada em equação de diferenças. A aplicação do controlador MPC no sistema não-linear apresentou resultados bastante satisfatórios em termos de posicionamento em relação à referência e tempo de acomodação, mesmo em condições de perturbação externa (desbalanceamento) ou velocidades de rotação não consideradas no treinamento da rede neural (20 e 40 Hz).

5 CONTROLE PREDITIVO NEURAL APLICADO AO MODELO MIMO (NNMPC-MIMO)

Neste capítulo, é desenvolvido um controlador NNMPC-MIMO utilizando para isso os dados experimentais colhidos da bancada experimental (mancal híbrido ativo). A bancada foi acionada em malha aberta sem controle e foram testadas diferentes tensões de acionamento dos atuadores eletromagnéticos. Em fim, tem-se duas entradas (para cada par de atuadores) e duas saídas nas direções ortogonais Y_1 e Z_1 . Estes dados foram utilizados para o treinamento da rede neural, e o desenvolvimento posterior do controlador NNMPC-MIMO em Matlab. Este controlador não foi implementado na bancada experimental.

5.1 Estrutura da rede neural e algoritmos de aprendizagem para o sistema em modelo MIMO

O mancal híbrido em modelo MIMO é composto por quatro atuadores eletromagnéticos instalados simetricamente nas quatro sapatas do sistema. São geradas forças eletromagnéticas em direções opostas sendo que o rotor, neste caso, possui dois graus de liberdade. Considerando a posição dos atuadores no interior do mancal, a voltagem é aplicada a cada par de atuadores, ou seja, para o par de atuadores 1 e 3 e para o par de atuadores 2 e 4, como mostrado na Fig. 5.1.

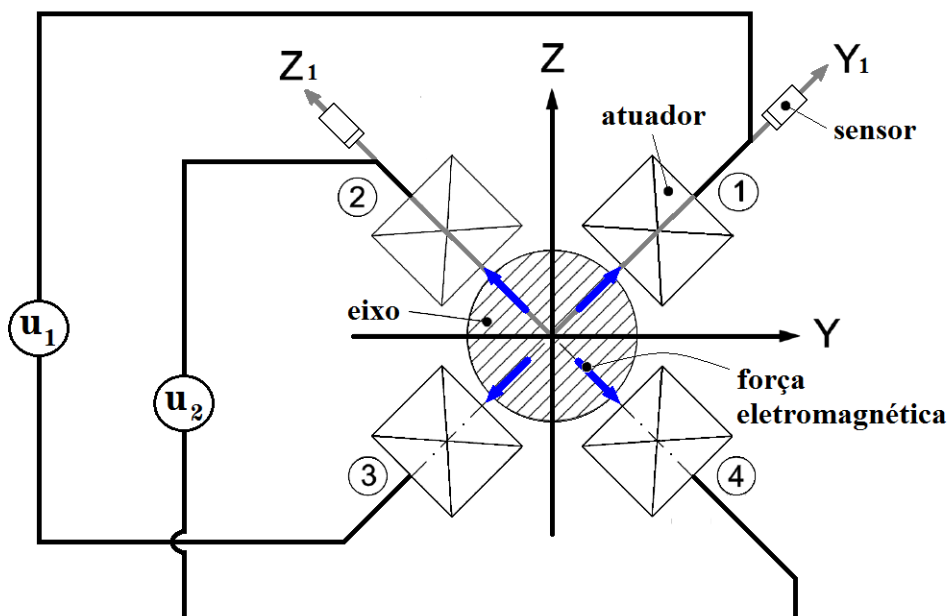


Figura 5.1. Sistema de coordenadas do mancal híbrido modelo MIMO e posição dos quatro atuadores eletromagnéticos instalados simetricamente.

Para o caso da identificação do sistema em modelo MIMO será utilizada uma rede neural recorrente tipo NARX (*Non-Linear Auto-Regressive with eXogenous inputs*), tornando-se num

modelo NARX-MIMO. O procedimento de identificação (similar ao modelo SISO) também considera os três passos seguintes: seleção da arquitetura do modelo (escolha do número de neurônios, número de atrasos e camadas escondidas), treinamento do modelo (obtenção dos pesos e *bias* dos neurônios) e finalmente a validação do modelo (utilizando dados novos nunca vistos pela rede neural). O critério de parada é dado em função do menor erro quadrático médio (Eq. (4.5)) obtido em relação a todas as amostras de treinamento.

O modelo neural utilizado para a identificação é o modelo NARX de múltiplas-entradas e múltiplas-saídas (*multi-input multi-output - MIMO*) com uma única camada escondida, sendo três entradas (duas entradas controladas e uma entrada não controlada) e duas saídas recorrentes (deslocamentos na direção dos eixos Y_1 e Z_1 respectivamente - Fig. 5.2). Para obter uma identificação do sistema com maior precisão é necessário normalizar os dados do treinamento, para isso é preciso definir os limites adequados para a entrada e a saída e assim obter uma normalização dentro da faixa de interesse.

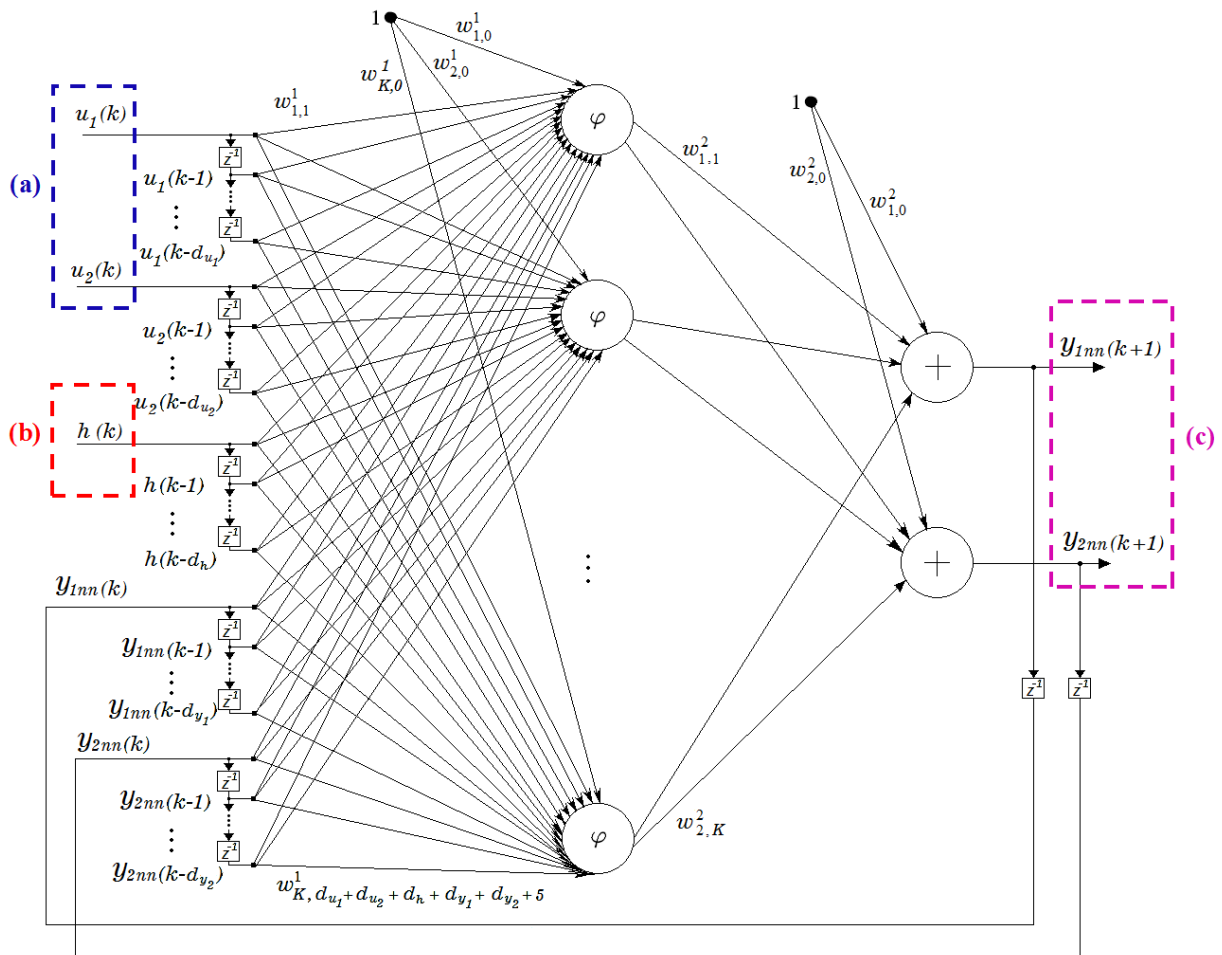


Figura 5.2. Modelo de rede neural NARX MIMO com 3 entradas ($u_1(k)$, $u_2(k)$ e $h(k)$) e 2 saídas ($y_{1nn}(k+1)$ e $y_{2nn}(k+1)$): (a) duas entradas controladas, (b) uma entrada não controlada (distúrbio medido), (c) duas saídas recorrentes (deslocamentos na direção dos eixos Y_1 e Z_1 respectivamente).

Existem diversos algoritmos de aprendizagem para o treinamento de uma rede neural. Cada um desses algoritmos tem uma aplicação específica segundo a característica do problema a estudar. Neste trabalho, foram utilizados apenas três algoritmos de aprendizado utilizados frequentemente para sistemas não-lineares como é o sistema mancal híbrido com atuadores eletromagnéticos. Os algoritmos escolhidos são: o algoritmo de Levenberg-Marquardt, o algoritmo de Regularização Bayesiana e o algoritmo de Gradiente Conjugado Escalonado.

O algoritmo Levenberg-Marquardt (LM) é uma variante do método do Newton. Este método tradicional de otimização utilizado para treinar diferentes redes neurais é muito eficiente, sendo que seu objetivo principal é minimizar a função de erro. Uma dificuldade desse método é quando o número de dados atinge mil ou mais número de dados, porque nessa condição o algoritmo reduz sua eficiência (HAGAN; MENHAJ, 1994; HAGAN et al., 2014). O algoritmo de Regularização Bayesiana (RB) utiliza para o treinamento da rede neural uma estrutura da estatística Bayesiana, a qual é útil para a seleção do parâmetro de regularização. Este algoritmo incorpora o Teorema de Bayes no processo de regularização (HAGAN et al., 2014). Desde a publicação do algoritmo (FORESEE; HAGAN, 1997; MACKAY, 1992), foi aplicado e amplamente utilizado em diferentes áreas do conhecimento (RAKHSHKHORSHID; SENDESI, 2014; SAINI, 2008; BUI et al., 2012). O terceiro algoritmo é o denominado algoritmo de Gradiente Conjugado Escalonado (SCG), o qual é muito eficiente e é diferente dos tradicionais métodos unidimensionais que envolvem um grande número de avaliações da função ou da derivada e, conseqüentemente, um elevado custo computacional. O pesquisador Møller (1993) introduziu uma variação no algoritmo de gradiente conjugado, o que evita uma busca unidimensional a cada iteração utilizando a abordagem de Levenberg-Marquardt com o objetivo de escalonar o passo de ajuste e reduzir o tempo de processamento (MARWALA, 2001; KOSTOPOULOS; GRAPSA, 2009).

A fase de treinamento da rede neural NARX é considerada como um problema de otimização e é realizada *off-line*. Para todas as análises foram utilizados os três algoritmos propostos, avaliando o desempenho através da obtenção do menor erro quadrático médio (MSE).

5.2 Resultados do controle NN MPC-MIMO

Nesta seção serão mostrados os resultados obtidos do processo de controle NN MPC aplicado ao modelo MIMO. Para esse processo foram utilizados dados experimentais da bancada de testes do mancal híbrido ativo obtidos através dos sensores de posição como mostrado na Fig. 5.1. Como no caso do sistema SISO, o primeiro passo envolve a identificação não-linear do sistema, mas desta vez serão utilizados os dados experimentais obtidos da bancada de testes do mancal híbrido. Aqui são obtidos as matrizes de pesos e o bias da rede neural proposta para ser utilizada posteriormente no controle do sistema. O segundo passo é o processo de controle NN MPC.

5.2.1 Obtenção de dados experimentais para o treinamento da rede neural

A bancada experimental de teste do sistema rotor-mancal híbrido é mostrada esquematicamente na Fig.5.3. A velocidade do motor elétrico é controlada digitalmente através de um inversor de frequência. O sistema precisa de um fluxo constante de óleo e a velocidade de rotação é medida mediante um tacômetro. Após a estabilização da temperatura do óleo no sistema rotor-mancal híbrido entre 18 e 20°C, obtiveram-se os dados experimentais. O sistema é excitado em malha aberta enviando-se sinais elétricos aos pares de atuadores em cada direção do mancal e a resposta do rotor é medida pelos sensores de proximidade montados no sistema. O sinal de excitação do sistema deve excitar toda a faixa de frequência desejada. Sendo assim, o sinal escolhido foi o sinal aleatório em período e amplitude, gerado a partir de um programa desenvolvido em Matlab. A Fig. 5.4 mostra o sinal de excitação (para amplitude máxima de 2 V) no domínio do tempo, cujo espectro em frequência também é mostrado na Fig. 5.4. Observa-se que a faixa de interesse do sistema (até 100 Hz) é preenchida totalmente.

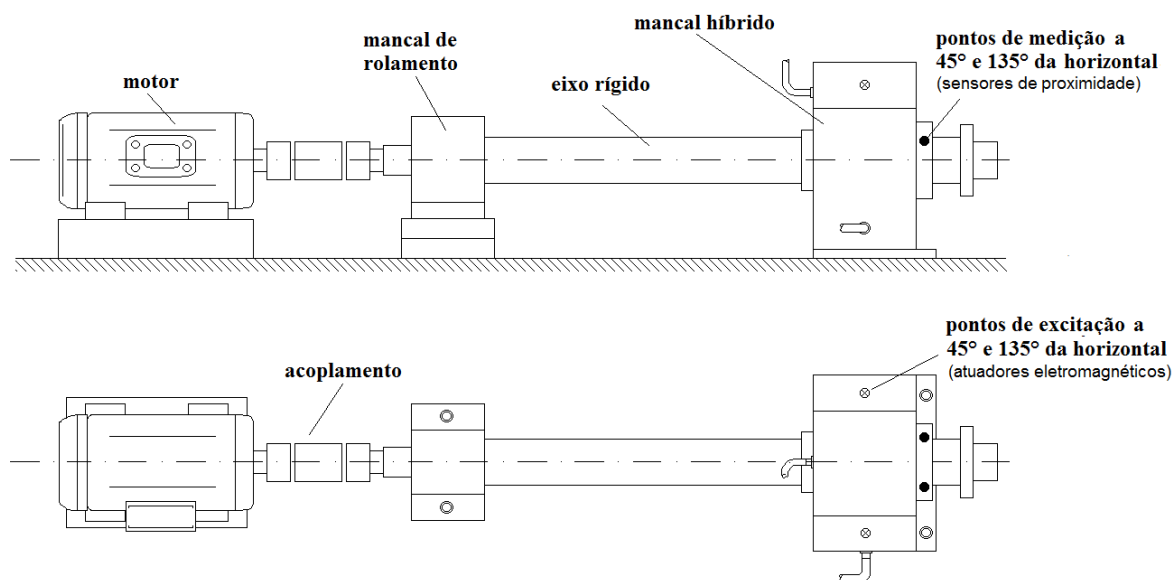


Figura 5.3. Bancada de testes do sistema rotor-mancal híbrido com os pontos de excitação (⊗) e de medição (●).

O motor da bancada é acionado a uma velocidade de rotação de 20 Hz em malha aberta (sem controle). As amplitudes máximas adotadas do sinal de excitação são cinco (2 V, 3 V, 4 V, 5 V e 6 V) e foram aplicadas aos dois pares de atuadores uma de cada vez (par 1-3 e o par 2-4 nas direções Y_1 e Z_1 respectivamente). O sistema apresenta um desbalanço residual (distúrbio). Os dados de saída foram colhidos nos pontos de medição (Fig. 5.3) obtendo-se para cada caso um total de 5000 amostras de dados a uma taxa de amostragem de 1kHz. Enfim, são formados os pares de entrada/saída que foram utilizados na fase de treinamento e do teste da rede neural NARX MIMO. O Apêndice B mostra maior detalhe da obtenção dos dados experimentais da bancada mancal híbrido para cada uma das cinco entradas propostas.

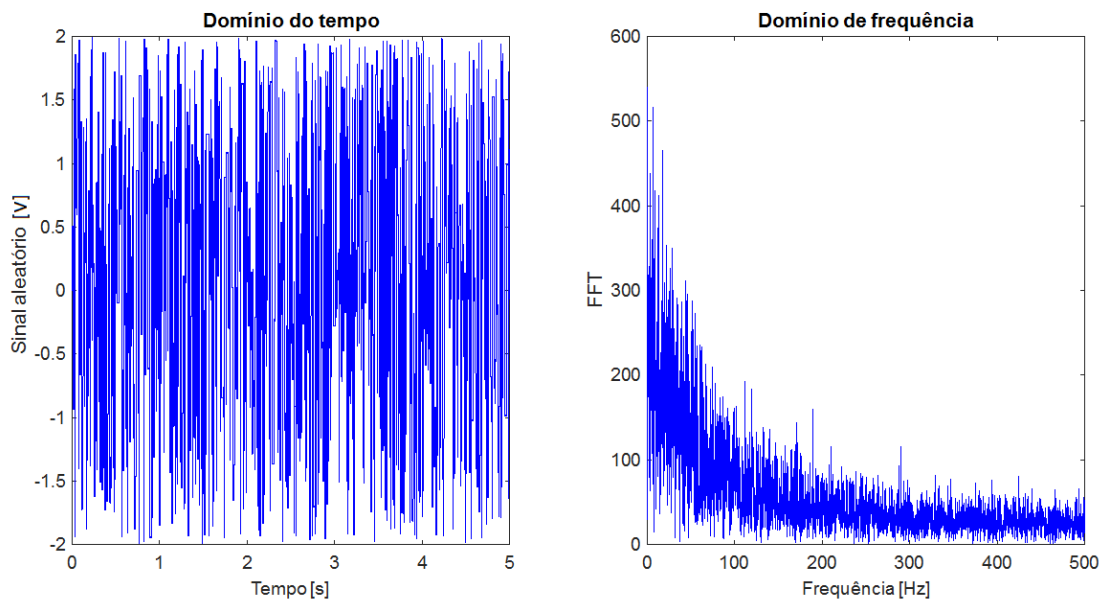


Figura 5.4. Sinal aleatório no domínio do tempo e da frequência, taxa de amostragem 1 kHz.

A fase de treinamento foi realizada *off-line*. Foram testados três diferentes algoritmos de identificação, que são: o algoritmos de Levenberg-Marquardt, a Regularização Bayesiana e o Gradiente Conjugado Escalonado. Todos os algoritmos de treinamento são recomendados para problemas não-lineares. O algoritmo Levenberg-Marquardt é um método de otimização para treinar diversas redes neurais diferentes. Este método tradicional consiste na redução do erro proporcional através do algoritmo de gradiente descendente (HAGAN; MENHAJ, 1994; HAGAN et al., 2014). Este algoritmo de treinamento é uma modificação do algoritmo de Newton, que busca minimizar a função de erro. Uma dificuldade desse método é o seu crescente requerimento da memória para calcular a matriz Jacobiana na função de erro e isso nem sempre garante o ótimo global no problema de otimização. A Regularização Bayesiana é um algoritmo que coloca o treinamento da rede neural no quadro estatístico bayesiano. Esta estrutura é útil para a seleção do parâmetro de regularização. O algoritmo de treinamento de Gradiente Conjugado Escalonado foi projetado para evitar a busca unidimensional a cada iteração. A busca unidimensional é computacionalmente custosa pois requer respostas a um grande número de avaliações da função ou de sua derivada a cada iteração. Møller (1993) introduziu uma variação no algoritmo de gradiente conjugado utilizando uma abordagem de Levenberg-Marquardt para obter um escalonamento do passo de ajuste (α). Este algoritmo foi utilizado com muito sucesso na literatura (MARWALA, 2001; KOSTOPOULOS; GRAPSA, 2009). De qualquer forma, o objetivo de todos os algoritmos de treinamento é minimizar o erro entre o sistema não-linear e a saída neural com base no erro quadrático médio (EQM).

5.2.2 Identificação não-linear multivariável mediante rede neural NARX MIMO

O modelo de rede neural multivariável denominado NARX MIMO é comumente utilizada para a identificação de sistemas dinâmicos (PIZARRO-VIVEROS; NICOLETTI, 2016).

Esta identificação é realizada *off-line* usando um algoritmo de treinamento supervisionado. A arquitetura neural tem uma única camada escondida com K neurônios e tem a função de transferência tangente hiperbólica (\tanh) para ativação da camada escondida, já na camada de saída a função de ativação é linear (purelin). O modelo neural multivariável NARX MIMO é definido com cinco entradas e duas saídas, sendo três entradas externas, $u_1(k)$, $u_2(k)$ e $h(k)$ (duas entradas de tensão e uma entrada não controlada respectivamente) e as duas entradas de retorno da planta, y_{1nn} e y_{2nn} (deslocamento do eixo nas direções ortogonais) como foi mostrada na Fig. 5.2. A equação que representa a rede neural NARX MIMO é mostrada a seguir:

$$y_{nn}(k+1) = w_{i,0}^2 + \sum_{i=1}^K w_i^2 \varphi(w_{i,0}^1 + \sum_{m=0}^{d_{u1}} w_{m,i}^1 u_1(k-m) + \sum_{n=0}^{d_{u2}} w_{n,i}^1 u_2(k-n) + \sum_{q=0}^{d_h} w_{q,i}^1 h(k-q) + \sum_{r=0}^{d_{y1}} w_{r,i}^1 y_{1nn}(k-r) + \sum_{s=0}^{d_{y2}} w_{s,i}^1 y_{2nn}(k-s)) \quad (5.1)$$

onde $y_{nn}(k+1) = \{y_{1nn}(k+1) \ y_{2nn}(k+1)\}^T$ é a predição neural nas direções Y_1 e Z_1 respectivamente, $w_{m,i}^1$, $w_{n,i}^1$, $w_{q,i}^1$, $w_{r,i}^1$ e $w_{s,i}^1$ são os pesos das conexões entre a camada de entrada e a camada neural escondida, w_i^2 é o peso da camada neural de saída, $w_{i,0}^1$ é o bias da camada de entrada e $w_{i,0}^2$ sendo $i = 1, 2$, são os biases da camada neural de saída, φ é a função não-linear, e d_{u1} , d_{u2} , d_h , d_{y1nn} e d_{y2nn} são os atrasos das duas entradas, da entrada não controlada (distúrbio medido) e as duas saídas recorrentes, respectivamente.

Nesta fase de treinamento foi utilizado o modelo *série-paralelo* (Fig. 5.5) cuja equação de identificação neural NARX MIMO é da forma da Eq. (5.2). Foi definido que a entrada u_1 é aplicada ao par de atuadores 1 e 3 e a entrada u_2 é aplicada ao par de atuadores 2 e 4. Dessa forma mede-se o deslocamento nas direções perpendiculares (Y_1 e Z_1):

$$y_{nn} = f(u(k), \dots, u(k-n_u), h(k), \dots, h(k-n_h), y(k), \dots, y(k-n_y))^T \quad (5.2)$$

onde:

$$y_{nn}(k+1) = \begin{Bmatrix} y_{1nn}(k+1) \\ y_{2nn}(k+1) \end{Bmatrix}; u(k) = \begin{Bmatrix} u_1(k) \\ u_2(k) \end{Bmatrix}; y(k) = \begin{Bmatrix} y_1(k) \\ z_1(k) \end{Bmatrix}; \quad (5.3)$$

onde $y_{nn}(k+1)$ é a saída da predição da rede neural NARX MIMO nas direções ortogonais (Y_1 e Z_1), $u(k)$ é a entrada (duas voltagens $u_1(k)$ e $u_2(k)$), e $h(k)$ é a entrada não controlada ou distúrbio medido (desbalanço), $y(k)$ e a saída da planta (y_1 e y_2); n_u , n_h e n_y são o número de atrasos das entradas e das saídas.

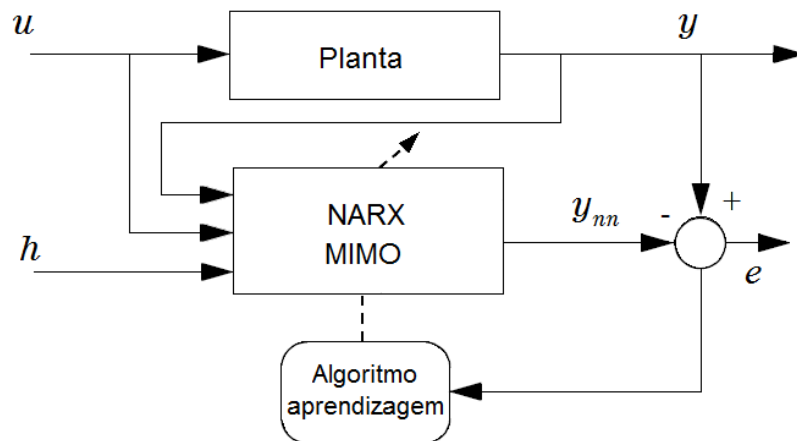


Figura 5.5. Configuração de identificação em série-paralelo para processo MIMO.

Na fase de treinamento tem-se como primeira ação a separação dos dados em dados de treinamento e dados de teste (verificação). Como descrito no capítulo anterior, antes de iniciar o processo de identificação neural é necessário um pré-processamento dos dados devido às diferentes ordens de grandeza que possuem todos os dados. Para isso, foi utilizada a Eq.(4.20) para normalizar os dados na faixa -1 a 1 e posteriormente é utilizada a Eq.(4.21) para obter a desnormalização dos dados.

Nesse contexto, com o intuito de obter uma melhor identificação do sistema dinâmico foram aplicadas duas estratégias para a seleção e preparação dos dados de treinamento:

a) Estratégia 1: Aqui os dados experimentais obtidos na bancada de teste foram concatenados, isto é, os resultados das excitações nas direções $Y_1(u_1)$ e $Z_1(u_2)$ são utilizados juntos para obter um único sinal que represente o comportamento do sistema considerando simultaneamente as duas excitações ao sistema mancal híbrido. Esta combinação de sinais foi realizada para cada amplitude de excitação aplicada 2 V, 3 V, 4 V, 5 V e 6 V, como mostrado na Fig. 5.6. No final obteve-se uma identificação neural para cada tensão de excitação, ou seja, cinco conjuntos de matrizes de pesos e bias respectivamente.

b) Estratégia 2: Esta estratégia combina parcelas dos sinais de excitação aplicados nas direções $Y_1(u_1)$ e $Z_1(u_2)$, e as respostas obtidas da bancada de testes. Foram combinadas quatro parcelas correspondentes as quatro tensões aplicadas 3 V, 4 V, 5 V e 6 V (desconsiderando a entrada de 2 V devido à pequena relação sinal-ruído da resposta). As parcelas foram de 3 s cada e dispostas de forma a se obter um único sinal com duas entradas (u_1 e u_2) e duas saídas (Y_1 e Z_1). O restante dos dados (2 s) serão utilizados na fase de operação (o comprovação) da rede neural após culminarem a fase de treinamento. Esta combinação de sinais deve estar na faixa de frequências de interesse do sistema e será utilizada no treinamento do sistema mancal híbrido (Fig.5.7). No final foi realizada uma única identificação neural obtendo um único conjunto de matrizes e bias que representa o sistema identificado para o conjunto de tensões aplicadas.

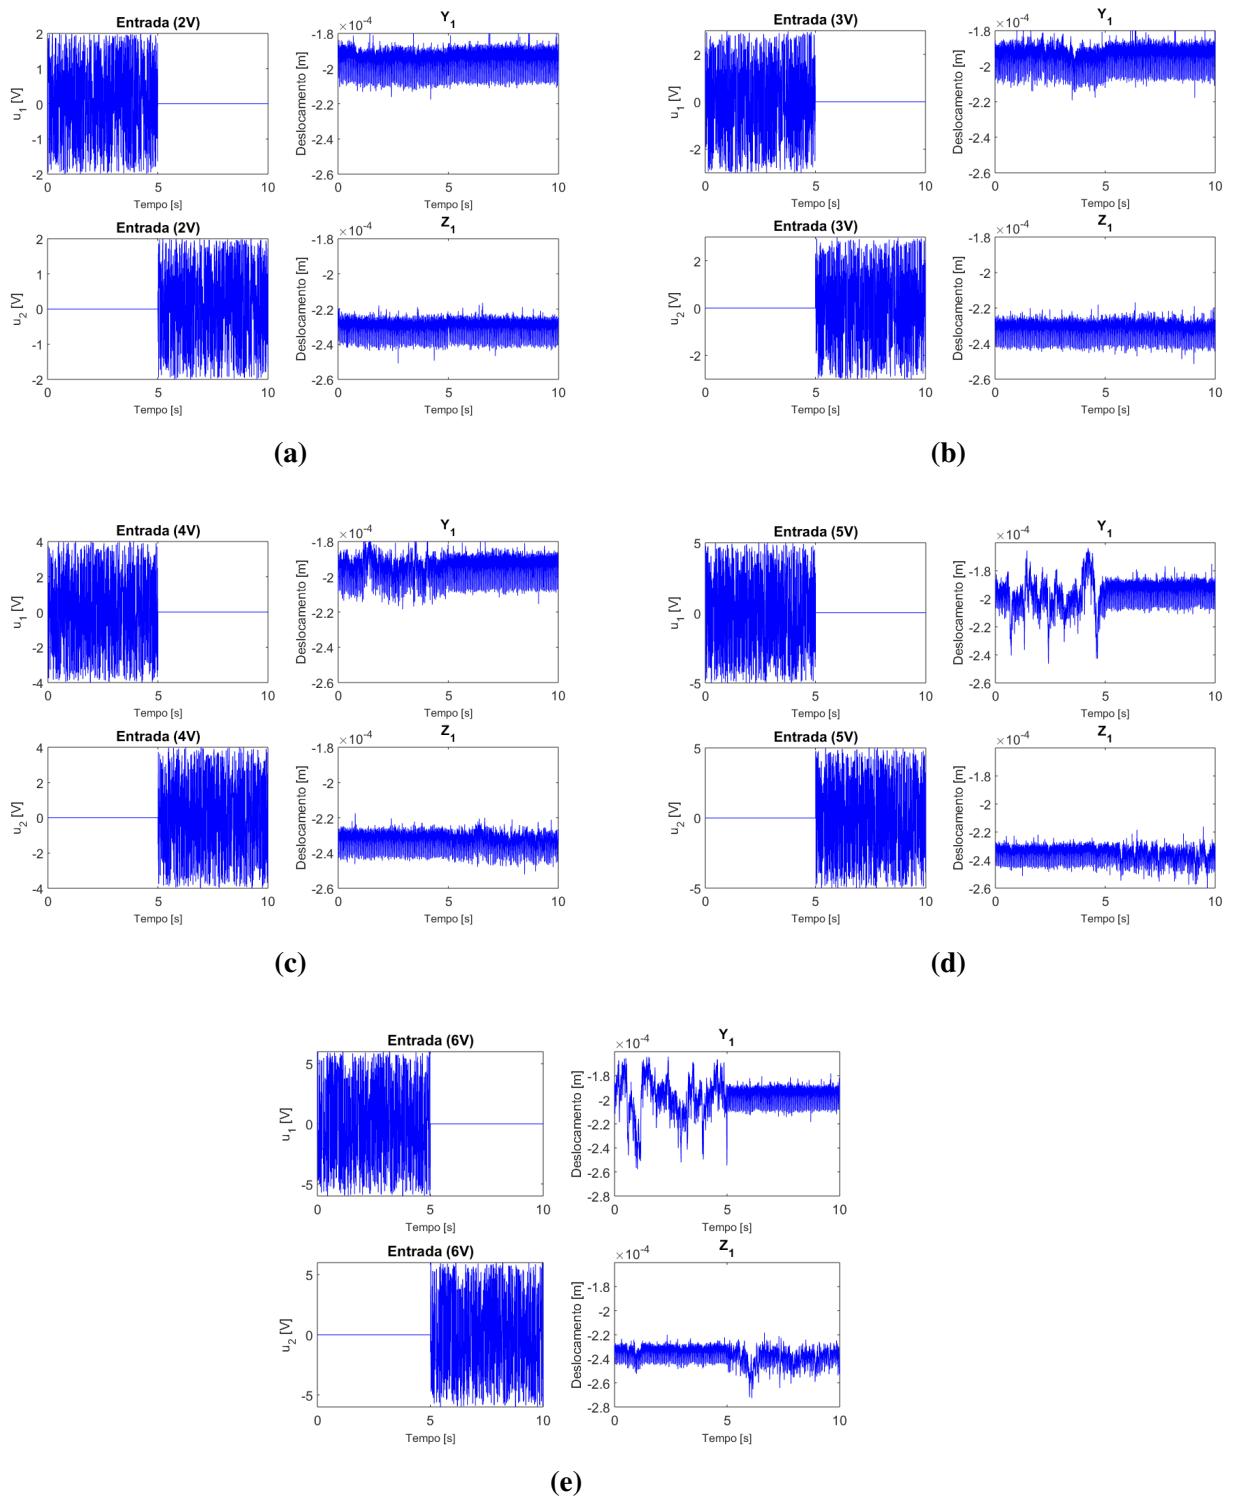


Figura 5.6. Estratégia 1: dados obtidos das excitações nas direções Y_1 (u_1) e Z_1 (u_2) concatenados num único sinal para cada amplitude de excitação: (a) excitação para 2 V; (b) excitação para 3 V; (c) excitação para 4 V; (d) excitação para 5 V e ; (e) excitação para 6 V.

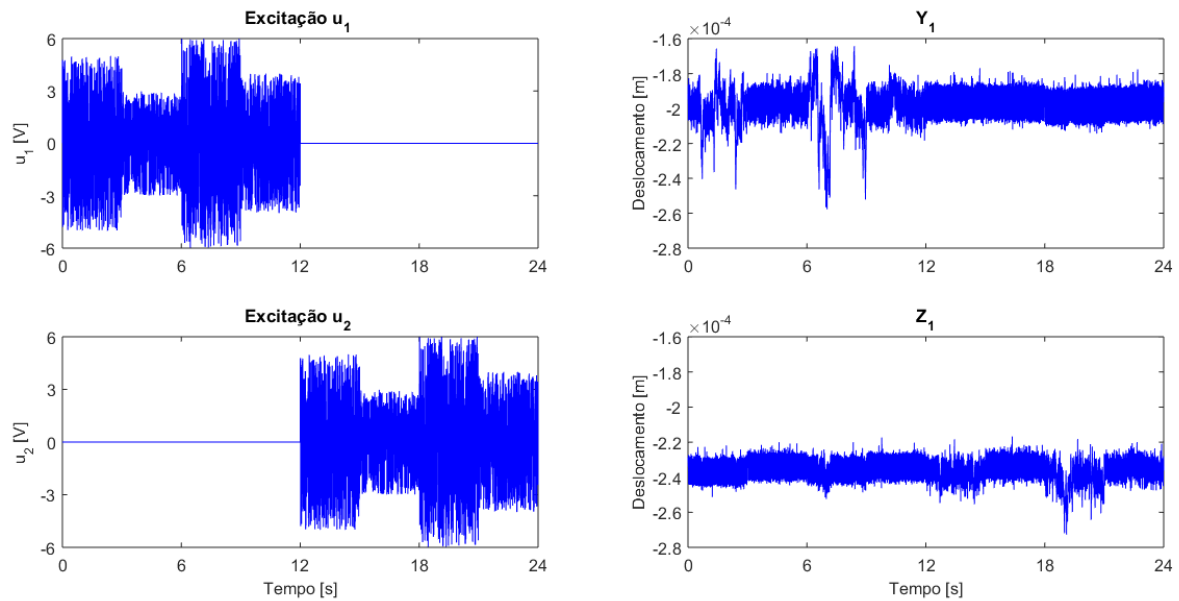


Figura 5.7. Estratégia 2: combinação dos dados obtidos das amplitudes de excitações nas direções $Y_1(u_1)$ e $Z_1(u_2)$ para as tensões 3 V, 4 V, 5 V e 6 V.

Observa-se para as tensões maiores (4 V, 5 V e 6 V) o deslocamento do rotor é maior. Nesta condição é quando aparecem todas as não-linearidades do sistema o que é ótimo para o treinamento da rede neural porque assim conseguira generalizar as características não-lineares do sistema. Após uma adequada identificação do sistema (treinamento com todos os dados), as previsões futuras da rede neural contribuíram com o sucesso do controle preditivo neural.

O modelo neural multivariável NARX MIMO foi definido com uma única camada escondida e será avaliado para 10, 15 e 20 neurônios. Serão utilizados os três algoritmos de aprendizagem descritos anteriormente: Levenberg-Marquardt, a Regularização Bayesiana e o Gradiente Conjugado Escalonado. No ambiente do Matlab utilizaram-se as funções implementadas dos algoritmos: `trainlm`, `trainbr` e `trainscg` que representam os algoritmos de treinamento, Levenberg-Marquardt, Regularização Bayesiana e Gradiente Conjugado Escalonado, respectivamente. Para atenuar o ruído e para que a identificação não tenha maiores dificuldades com o conjunto de dados experimentais, utilizou-se o filtro não-linear unidimensional chamado **mediana**. Este filtro não-linear apresenta um bom desempenho e é computacionalmente simples (PITAS; VENETSANOPOULOS, 1990). No Matlab está implementado como a função `medfit1`.

Cabe salientar, que também foram testadas arquiteturas neurais novas, incrementando camadas escondidas adicionais (duas e três camadas). No entanto, para os diversos testes realizados considerando os três algoritmos de treinamento, não foram observadas reduções significativas nos valores do MSE (apenas aumentou o tempo de processamento) motivo pelo qual, sua utilização foi descartada. Finalmente, é iniciado o processo de identificação e do teste da rede neural tendo como critério o menor MSE. Foram obtidos resultados para a Estratégia 1 e para a Estratégia 2 que serão detalhados a continuação.

5.2.3 Resultados da identificação não-linear multivariável mediante rede neural NARX MIMO

a) Resultados para a Estratégia 1

A Tabela 5.1 mostra o resumo dos resultados obtidos no processo de treinamento e do teste para a estratégia 1 analisados para as cinco entradas propostas (2 V, 3 V, 4 V, 5 V e 6 V). O detalhe do procedimento de identificação e do teste para cada entrada está mostrado no Apêndice C. Para a obtenção de cada resultado, procurou-se os menores MSE (treinamento e teste) dos três algoritmos de treinamento propostos. Variou-se também o número de neurônios (10, 15 e 20) para determinar o número ótimo de neurônios. Segundo estes resultados, o algoritmo de treinamento que apresentou o melhor desempenho na maioria do processo de treinamento e do teste, foi o algoritmo Regularização Bayesiana para 15 e 20 neurônios. Para cada resultado foi obtido e salvo um arquivo com as matrizes de pesos e bias (5 arquivos no total). Posteriormente, estas matrizes de pesos e bias serão utilizados no desenvolvimento do controle preditivo neural na predição do comportamento futuro do sistema dinâmico para quaisquer das entradas treinadas.

Analisando-se os resultados apresentados no Apêndice C, os três algoritmos de treinamento utilizados na estratégia 1 obtiveram o seguinte desempenho:

- O algoritmo Levenberg-Marquardt (`trainlm`) teve o tempo de processamento relativamente mais rápido para todos os casos (10, 15 e 20 neurônios), porém, isso não significou sua correta convergência para o mínimo global da função objetivo. A Fig. C.5, mostra uma predição aceitável para a resposta do sistema.
- O algoritmo Regularização Bayesiana (`trainbr`) foi mais lento que o algoritmo Levenberg-Marquardt, mas os resultados em termos de MSE foram melhores (no treinamento e no teste). A Fig. C.7 e a Fig. C.9 ($y_1(6V)$) mostram que as predições da rede neural não acertaram plenamente as saídas esperadas.
- O algoritmo Gradiente Conjugado Escalonado (`trainscg`) é o algoritmo que demorou mais tempo em comparação aos outros dois algoritmos de treinamento. No entanto, os valores de MSE obtidos não apresentaram reduções significativas em relação aos outros algoritmos. As figuras obtidas no treinamento e o teste da rede neural mostram que este algoritmo não teve uma convergência satisfatória.

Como se pode observar, cada condição de treinamento resultou em um modelo em rede neural diferente do outro. Desta forma, para a implementação do sistema de controle, seria necessário desenvolver um controle para cada condição de entrada treinada (5 entradas propostas) o que torna o sistema de controle preditivo pouco versátil. O que é preciso é um controle único que atenda as necessidades das cinco condições propostas.

Tabela 5.1 – Resumo dos melhores resultados da fase de treinamento e do teste para a estratégia 1 analisando as cinco entradas propostas (2 V, 3 V, 4 V, 5 V e 6 V).

Entrada	Algoritmo treinamento	K	$MSE_{treinamento}$	MSE_{teste}
2 V	Regularização Bayesiana	15	9,4490e-3	3,5763e-1
3 V	Regularização Bayesiana	20	8,1103e-3	5,8045e-1
4 V	Levenberg-Marquardt	10	5,9044e-3	3,3732e-1
5 V	Regularização Bayesiana	20	3,3269e-3	1,1835e-1
6 V	Regularização Bayesiana	20	2,5926e-3	4,9827e-2

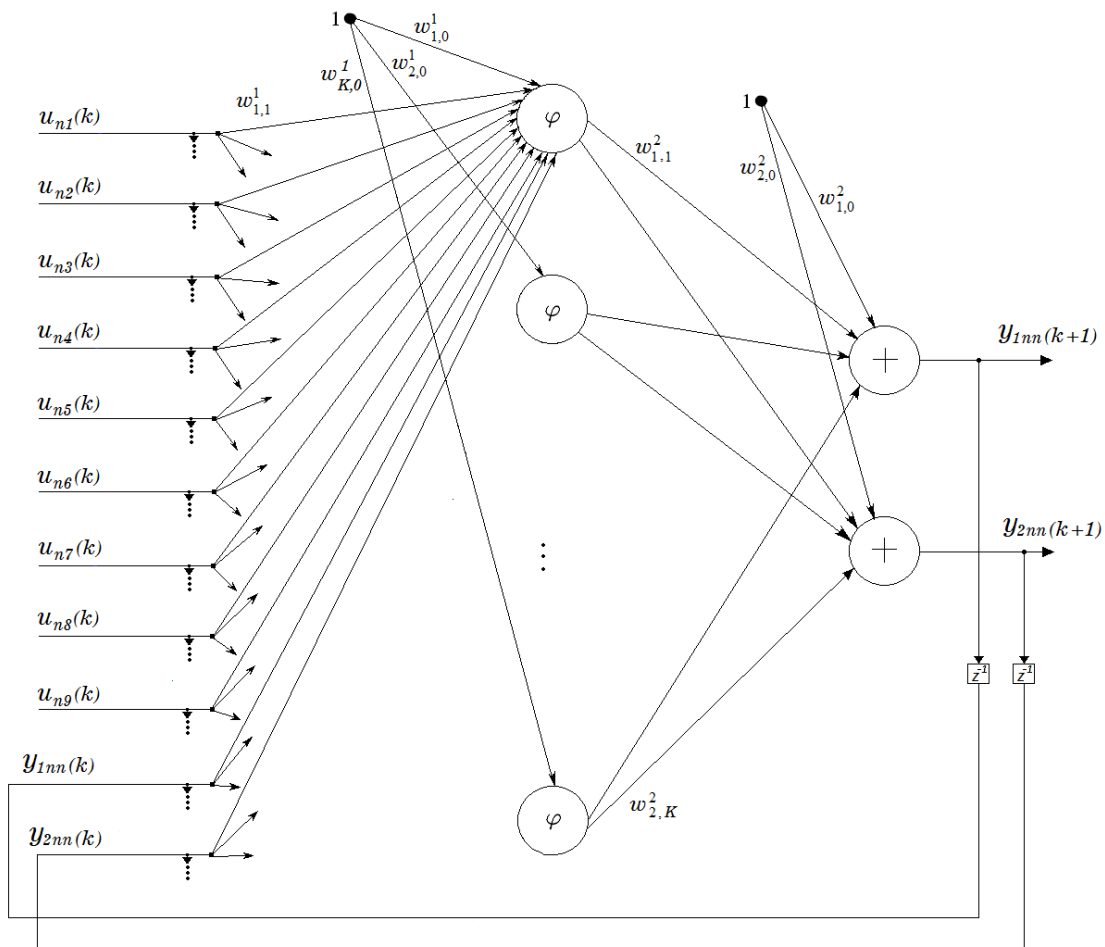
b) Resultados para a Estratégia 2

A rede neural NARX MIMO utilizada inicialmente foi com três entradas e duas saídas, sendo, três entradas externas: $u_1(k)$, $u_2(k)$ e $h(k)$, e duas entradas de retorno da planta: $y_1(k)$ e $y_2(k)$. No entanto, após inúmeras rodadas utilizando um único sinal de entrada observou-se que a rede neural NARX MIMO não convergiu adequadamente para nenhum resultado satisfatório. Isto ocorreu devido à complexidade de identificar várias condições da planta e suas não-linearidades contidas num único sinal, principalmente das entradas de 4 V, 5 V e 6 V. A capacidade da rede neural NARX MIMO de três entradas viu-se afetada, devido ao incremento do grau de dificuldade o que ocasionou uma inadequada identificação da planta. Ante esta situação, propõe-se algumas modificações no conjunto de entradas da rede neural NARX MIMO visando melhorar o desempenho do processo de identificação avaliado em um menor MSE ou numa correta convergência. A proposta agora é apresentar à rede neural um conhecimento prévio do processo através das equações não-lineares que descrevem o comportamento dinâmico. Ou seja, agora as entradas terão a forma das equações não-lineares. Com estas adaptações, a rede neural será treinada novamente até atingir a taxa de aprendizagem esperada ou alcançar uma convergência adequada. Se não acontecer isso, as entradas serão modificadas novamente e o processo será repetido até a rede neural apresentar uma identificação satisfatória.

Enfim, após diversas rodadas e modificações foram encontradas as melhores condições das entradas da rede neural (Tabela 5.2). Com essas novas entradas iniciou-se um novo processo de identificação utilizando o único sinal da estratégia 2, obtendo-se uma melhoria significativa nos resultados da identificação do sistema dinâmico avaliados em função do menor MSE. Foi salvo o arquivo com as matrizes de pesos e bias para utilizá-lo na predição do comportamento futuro no processo de controle. A Fig.5.8 mostra a nova rede neural NARX MIMO, agora com nove entradas sendo que todas estão em função das entradas originais u_1 e u_2 , onde $u_1(k)$ e $u_2(k)$ são as entradas da estratégia 2 (Fig. 5.7); $h(k)$ é a entrada não controlada (desbalanço); h_0 é o valor do entreferro do mancal; u_{n1} , u_{n2} , u_{n3} , u_{n4} , u_{n5} , u_{n6} , u_{n7} , u_{n8} e u_{n9} são as entradas novas modificadas.

Tabela 5.2 – Entradas novas modificadas da rede neural NARX MIMO.

Número	Entradas novas	Fonte
1	u_{n1}	$u_1 > 0$
2	u_{n2}	$u_1 < 0$
3	u_{n3}	$u_2 > 0$
4	u_{n4}	$u_2 < 0$
5	u_{n5}	h (desbalanço)
6	u_{n6}	$\left(\frac{u_{n1}}{h_0}\right)^2$
7	u_{n7}	$\left(\frac{u_{n2}}{h_0}\right)^3$
8	u_{n8}	$\left(\frac{u_{n3}}{h_0}\right)^2$
9	u_{n9}	$\left(\frac{u_{n4}}{h_0}\right)^3$

**Figura 5.8.** Rede neural NARX MIMO com as entradas modificadas para a estratégia 2.

A seguir é mostrada a equação que representa a rede neural da planta para as novas entradas modificadas da estratégia 2.

$$\begin{aligned}
y_{nn}(k+1) = & w_{j,0}^2 + \sum_{i=1}^K w_i^2 \varphi(w_{i,0}^1 + \sum_{n_1=0}^{d_{n_1}} w_{n_1,i}^1 u_{n_1}(k-n_1) + \sum_{n_2=0}^{d_{n_2}} w_{n_2,i}^1 u_{n_2}(k-n_2) \\
& + \sum_{n_3=0}^{d_{n_3}} w_{n_3,i}^1 u_{n_3}(k-n_3) + \sum_{n_4=0}^{d_{n_4}} w_{n_4,i}^1 u_{n_4}(k-n_4) + \sum_{n_5=0}^{d_{n_5}} w_{n_5,i}^1 u_{n_5}(k-n_5) \\
& + \sum_{n_6=0}^{d_{n_6}} w_{n_6,i}^1 u_{n_6}(k-n_6) + \sum_{n_7=0}^{d_{n_7}} w_{n_7,i}^1 u_{n_7}(k-n_7) + \sum_{n_8=0}^{d_{n_8}} w_{n_8,i}^1 u_{n_8}(k-n_8) \\
& + \sum_{n_9=0}^{d_{n_9}} w_{n_9,i}^1 u_{n_9}(k-n_9) + \sum_{m=0}^{d_m} w_{m,i}^1 y_{1nn}(k-m) + \sum_{n=0}^{d_n} w_{n,i}^1 y_{2nn}(k-n))
\end{aligned} \tag{5.4}$$

onde $y_{nn}(k+1) = \{y_{1nn}(k+1) \ y_{2nn}(k+1)\}^T$ é a predição neural nas direções Y_1 e Z_1 respectivamente, $w_{n_1,i}^1, w_{n_2,i}^1, w_{n_3,i}^1, w_{n_4,i}^1, w_{n_5,i}^1, w_{n_6,i}^1, w_{n_7,i}^1, w_{n_8,i}^1, w_{n_9,i}^1, w_{m,i}^1$ e $w_{n,i}^1$ são os pesos das conexões entre a camada de entrada e a camada neural escondida, w_i^2 é o peso da camada neural de saída, $w_{i,0}^1$ é o bias da camada de entrada, e $w_{j,0}^2$ são os biases da camada neural de saída (sendo $j = 1, 2$), φ é a função não-linear, e $d_{n_1}, d_{n_2}, d_{n_3}, d_{n_4}, d_{n_5}, d_{n_6}, d_{n_7}, d_{n_8}, d_{n_9}, d_m$ e d_n são os atrasos das novas entradas e das duas saídas recorrentes.

Com as novas entradas mostradas na Tabela 5.2 treinou-se a rede neural NARX MIMO variando o número de neurônios e os algoritmos de treinamento supervisionado obtendo-se a Tabela 5.3. Estes resultados mostram a condição vencedora do algoritmo de aprendizagem Regularização Bayesiana para uma rede neural de 20 neurônios na camada escondida. Os erros quadráticos médios (MSE) do treinamento e do teste foram os menores. As matrizes de pesos e bias foram salvas num arquivo para serem utilizadas no processo de operação e posteriormente no processo de controle aplicando a Eq. (5.4).

Tabela 5.3 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (amplitude de excitação 3 V, 4 V, 5 V e 6 V).

Algoritmo treinamento	K	MSE _{treinamento}	MSE _{teste}
Levenberg-Marquardt	10	2,3956e-3	7,5318e-2
Regularização Bayesiana	10	2,3836e-3	7,6256e-2
Gradiente Conjugado Escalonado	10	2,7600e-3	8,1977e-2
Levenberg-Marquardt	15	2,4104e-3	7,4701e-2
Regularização Bayesiana	15	2,3778e-3	7,2299e-2
Gradiente Conjugado Escalonado	15	2,8478e-3	8,7628e-2
Levenberg-Marquardt	20	2,3988e-3	7,5877e-2
Regularização Bayesiana	20	2,3806e-3	7,1955e-2
Gradiente Conjugado Escalonado	20	4,9369e-3	1,7543e-1




Figura 5.9. Melhor treinamento: Regularização Bayesiana para 10 neurônios na direção Y_1 .




Figura 5.10. Melhor treinamento: Regularização Bayesiana para 10 neurônios na direção Z_1 .

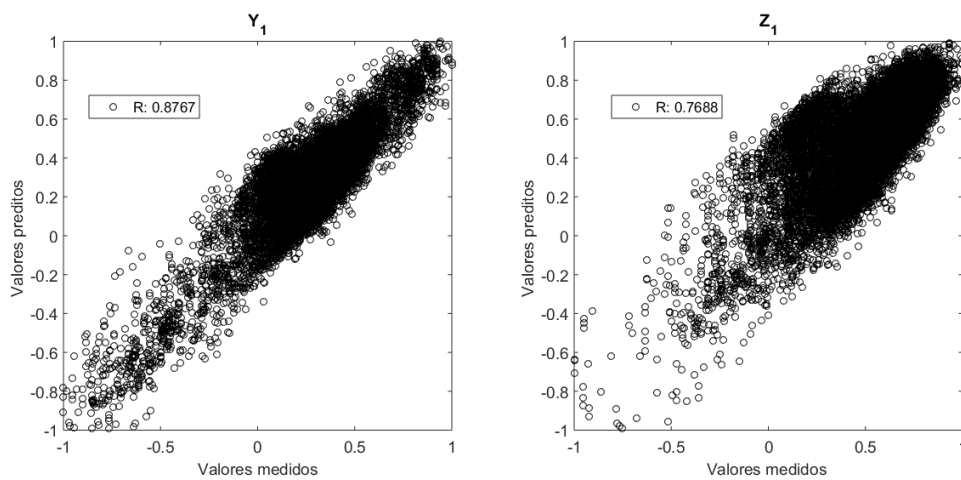


Figura 5.11. Correlação entre os valores medidos e os valores preditos do melhor treinamento.

Para a fase de treinamento foram utilizados aproximadamente 70% dos dados apresentados na Fig.5.7 (16 s) e para o teste de verificação o restante (8 s) do total de 24 s. O algoritmo de aprendizagem com melhor desempenho e menores MSE (treinamento e teste) foi a Regularização Bayesiana com 20 neurônios na camada escondida (Tabela 5.3). A Fig.5.9 mostra a resposta treinada da rede neural na direção Y_1 em comparação com o sinal de treinamento, onde se observa uma predição aceitável da resposta, mesmo em regiões de maior variação. A Fig.5.10 mostra a resposta da rede neural treinada na direção Z_1 em comparação com o sinal de treinamento, onde também se observa uma predição aceitável da resposta. Estes resultados são muito bons porque trata-se de dados experimentais que geralmente são difíceis de representar para uma rede neural como visto na literatura estudada. Para as duas figuras mostradas. A Fig.5.11 mostra a correlação entre os valores medidos experimentalmente e os valores preditos pela rede neural NARX MIMO. Observa-se que os dados nesta correlação formam uma linha de ângulo 45° com a horizontal o que indica uma boa identificação na fase de treinamento. Devemos considerar que os resultados são bons se comparamos com outros resultados que a literatura apresenta quando são utilizados dados experimentais. O MSE para o treinamento foi $MSE_{treinamento} = 2.3806e - 3$. O resultado do teste da fase de treinamento para as duas direções Y_1 e Z_1 é mostrada na Fig.5.12 obtendo-se uma predição aceitável com um MSE que foi $MSE_{teste} = 7.1955e - 2$.

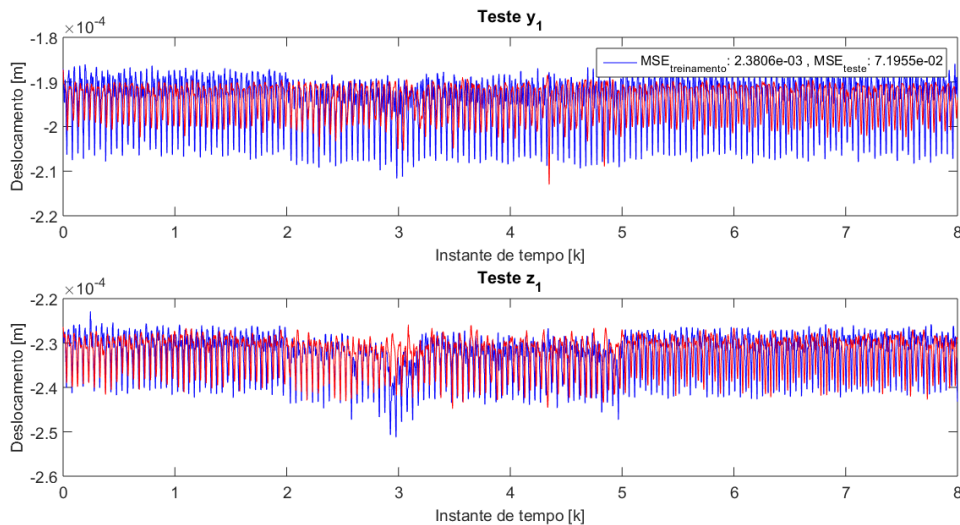


Figura 5.12. Resultados do teste da rede neural NARX MIMO nas direções Y_1 e Z_1 .

Após culminar a fase de treinamento e salvar o arquivo com as matrizes de pesos e o bias da melhor rede neural obtida, inicia-se a fase de operação (verificação da rede neural com dados não conhecidos da rede). Nesta fase, são testados os dados restantes do conjunto de dados mostrados na Fig.5.7, ou seja, 2 s de amostragem que não foram utilizados no treinamento da rede neural em cada direção de atuação do mancal. Assim, será avaliada a qualidade do treinamento da rede neural NARX MIMO, mas agora a fase de operação testará as quatro entradas (3 V, 4 V, 5 V e 6 V) uma de cada vez nas duas direções Y_1 e Z_1 . Desta maneira será avaliada a capacidade de generalização que a identificação alcançou das características não-lineares do sistema quando testados com cada entrada independentemente.

A Fig.5.13 apresenta os resultados da operação da rede neural NARX MIMO na direção Y_1 . Aqui observa-se que a rede neural conseguiu generalizar adequadamente as características do sistema devido a que a predição da rede neural (linha cor vermelho) representa a saída esperada (linha cor azul) principalmente para as entradas 4 V, 5 V e 6 V, no entanto com a entrada de 3 V não se teve resultados bons. A Fig.5.14 apresenta os resultados da operação da rede neural para a direção Z_1 , similar ao caso anterior. Novamente, observa-se um resultado aceitável na predição sob a saída esperada para as entradas 4 V, 5 V e 6 V e para a entrada de 3 V um resultado regular.

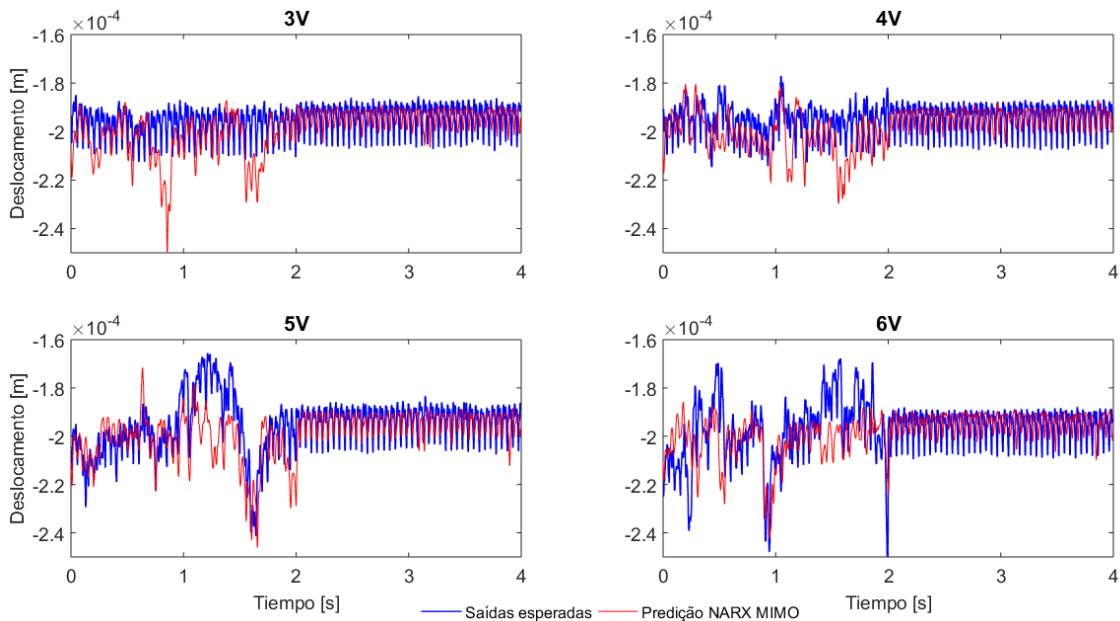


Figura 5.13. Fase de operação da rede neural NARX MIMO na direção Y_1 .

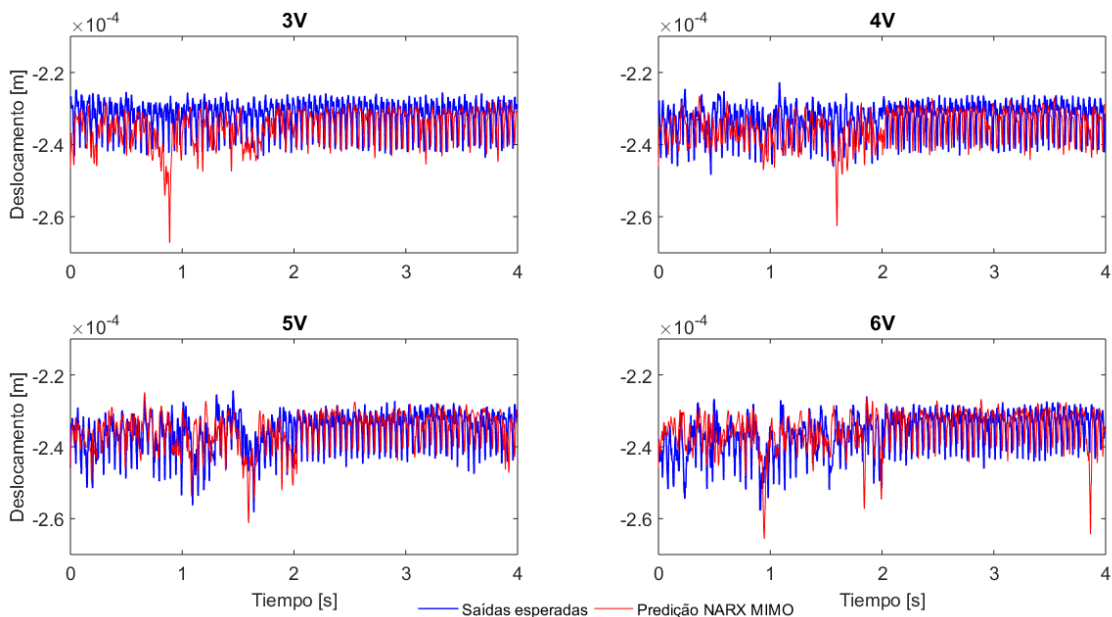


Figura 5.14. Fase de operação da rede neural NARX MIMO na direção Z_1 .

Após finalizar o processo de identificação (fase de treinamento e a fase de operação) do sistema dinâmico rotor-mancal, obtem-se o arquivo *netc* que contem as matrizes dos pesos e o bias da identificação da planta. A estrutura interna da rede neural NARX é mostrada na Fig.5.15 em diagrama de blocos. Observa-se na camada de entrada os atrasos (TDL), a matriz de pesos da camada de entrada ($IW^{1,1}$), o bias de entrada (b^1) e a matriz de pesos do retorno da planta ($LW^{1,2}$). Para a camada de saída tem-se o bias de saída (b^2) e a matriz de pesos da camada de saída ($LW^{2,1}$). As entradas estão representadas pelas nove entradas mostradas na Tabela 5.2 e as saídas são os deslocamentos do rotor nas direções ortogonais Y_1 e Z_1 .

A Tabela 5.4 relaciona os valores obtidos no processo de identificação (armazenados no arquivo *netc*) com os valores que representam as entradas modificadas da estratégia 2 (Eq. (5.4)). É importante conhecer esta equivalência para realizar uma correta montagem das matrizes de pesos e bias e ter sucesso na aplicação do controle. O passo seguinte é definir as matrizes de pesos e bias da forma w_{10} , w_1 , w_{20} e w_2 que serão utilizados no processo de controle preditivo neural. A Tabela 5.5 mostra como é a montagem dos dados contidos no arquivo *netc* para a formação das matrizes ditas.

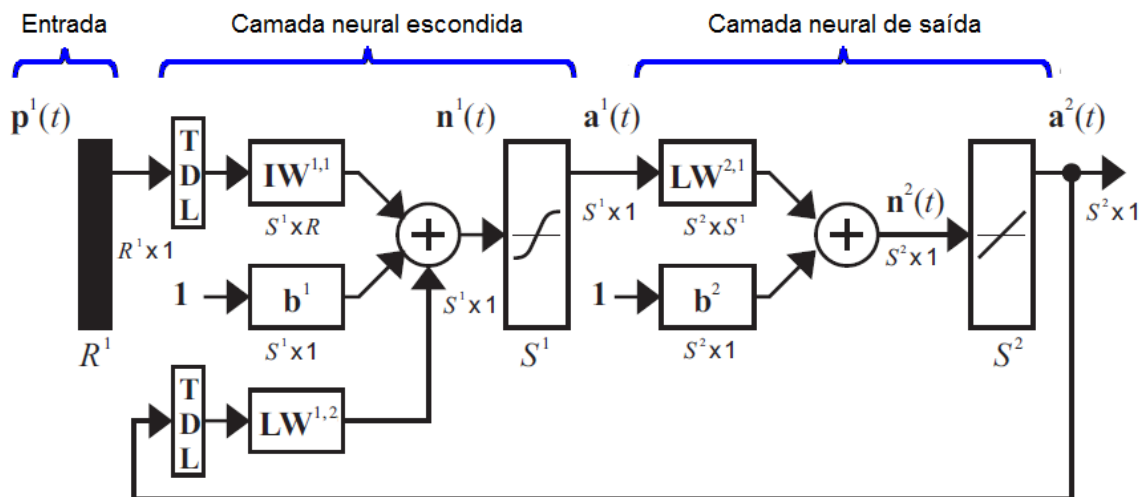


Figura 5.15. Estrutura interna da rede neural NARX, adaptado de Hagan et al. (2014)

Tabela 5.4 – Equivalência dos valores do arquivo *netc* e a equação da identificação da planta.

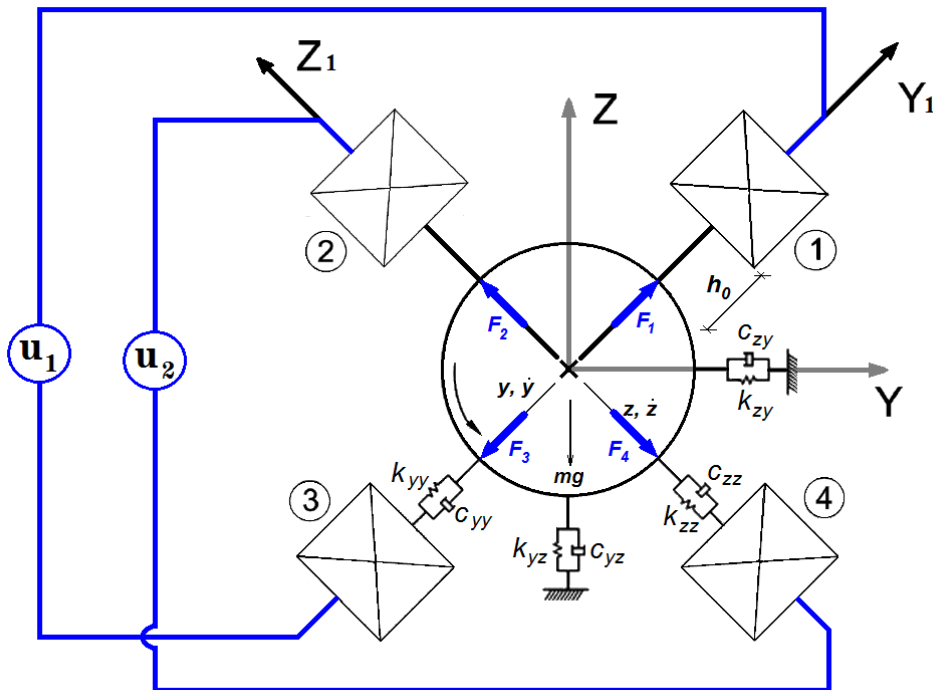
Pesos e bias	Estrutura NARX (<i>netc</i>)	Valores da Eq. (5.4)
Bias de entrada	$netc.b^1$	$w_{i,0}^1$
Pesos camada neural escondida	$netc.Iw^{1,1}$	$\{w_{n_1,i}^1, w_{n_2,i}^1, \dots, w_{n_9,i}^1\}$
Pesos retorno da planta	$netc.Lw^{1,2}$	$\{w_{m,i}^1, w_{n,i}^1\}$
Bias de saída	$netc.b^2$	$w_{j,0}^2 \{j = 1, 2\}$
Pesos camada neural saída	$netc.Lw^{2,1}$	w_i^2

Tabela 5.5 – Montagem das matrizes w_{10} , w_1 , w_{20} e w_2 utilizando os dados do arquivo *netc*.

Pesos e bias	Matrizes w_{ij}	Montagem das matrizes
Bias de entrada	w_{10}	<code>netc.b{1}</code>
Pesos camada neural escondida	w_1	<code>[netc.Iw{1,1} netc.Lw{1,2}]</code>
Bias de saída	w_{20}	<code>netc.b{2}</code>
Pesos camada neural saída	w_2	<code>netc.Lw{2,1}</code>

5.2.4 Resultados do controle preditivo neural NNMPC- MIMO

A simulação numérica do controle preditivo neural NNMPC-MIMO que considerou para a identificação multivariável da planta os dados experimentais da bancada, considera duas entradas (amplitudes de excitação) e duas saídas (deslocamento nas direções Y_1 e Z_1). Este modelo é similar ao modelo SISO, mas desta vez são consideradas as duas direções ortogonais (Y_1 e Z_1). São incluídos os coeficientes dinâmicos das direções ortogonais do filme de óleo. A dinâmica não-linear dos atuadores eletromagnéticos que geram as forças eletromagnéticas atuantes no sistema é incluída. Estas forças são atraentes e estão em direções opostas umas com outras e são ativadas em dois circuitos de controle diferentes que funcionam independentes um do outro. O princípio de funcionamento dos atuadores eletromagnéticos é baseado na configuração de quatro polos que atraem o rotor nas duas direções ortogonais. Quando o rotor está no centro geométrico do mancal híbrido o entreferro é h_0 .

**Figura 5.16.** Sistema de coordenadas e posicionamento dos atuadores eletromagnéticos no MHA.

A Fig. 5.16 mostra o sistema mancal híbrido em modelo MIMO, este sistema é modelado considerando o efeito dos atuadores eletromagnéticos que geram as forças eletromagnéticas atuantes em direções opostas, os coeficientes dinâmicos do filme de óleo e a folga radial, tendo como referência Y_1 e Z_1 respectivamente. Como as forças atuantes no rotor devem se equilibrar dentro do mancal, o peso do rotor é suportado por uma força resultante da pressão gerada no filme de óleo. Esta força resultante é representada pelos coeficientes dinâmicos equivalentes e a distancia em relação ao centro do mancal deste ponto de equilíbrio das forças que agem no rotor pode ser definidas pela excentricidade (a razão entre a distância até o centro do mancal e a folga radial).

Os coeficientes dinâmicos do sistema podem ser representados de uma forma simplificada como a rigidez e o amortecimento do filme de óleo, que serão chamados coeficientes dinâmicos equivalentes obtidos de [Someya \(1989\)](#). Utilizando as características geométricas do mancal e a velocidade de rotação ($\Omega = 20Hz$) é obtido o número de Sommerfeld ($S = 0,01761$) com o qual são estimados a rigidez e o amortecimento equivalente utilizando para isso um modelo de mancal similar ao utilizado no estudo. A Fig. 5.17 mostra os coeficientes dinâmicos calculados em função das características do mancal híbrido. Com o número de Sommerfeld calculado previamente são calculados os valores da rigidez e o amortecimento equivalente do sistema que serão utilizados na modelagem. Lembrando que os coeficientes cruzados não foram considerados.

A equações de movimento do sistema mancal híbrido em modelo MIMO serão utilizados no processo de controle preditivo NNMPC - MIMO e representarão o comportamento do sistema a ser controlado.




Figura 5.17. Coeficientes de rigidez e amortecimento equivalentes do sistema para mancal híbrido em modelo MIMO ($S = 0,01761$ e $\Omega = 20Hz$).

O sistema mostrado na Fig. 5.16 pode ser representado pelas seguintes equações de movimento (sendo a referência o Y_1 e Z_1 respectivamente):

$$m\ddot{y}_1 + c_{yy}\dot{y}_1 + c_{yz}\dot{z}_1 \cos 45^\circ + k_{yy}y_1 + k_{yz}z_1 \cos 45^\circ = (F_1 - F_3) - mg \cos 45^\circ + m_d e \Omega^2 \cos \Omega t \quad (5.5)$$

$$m\ddot{z}_1 + c_{zy}\dot{y}_1 \sin 45^\circ + c_{zz}\dot{z}_1 + k_{zy}y_1 \sin 45^\circ + k_{zz}z_1 = (F_2 - F_4) - mg \sin 45^\circ + m_d e \Omega^2 \sin \Omega t \quad (5.6)$$

onde:

$$F_i = \left(\frac{j\omega \bar{a}_1 + \bar{a}_0}{j\omega \bar{b}_1 + \bar{b}_0} \right)^2 \frac{v_i^2}{d_i^2} \quad (5.7)$$

sendo, v_i a tensão elétrica de controle, d_i a distancia entre o atuador e o eixo ($d_1 = h_0 - y_1$, $d_2 = h_0 - z_1$, $d_3 = h_0 + y_1$ e $d_4 = h_0 + z_1$). Assim, pode-se escrever as equações de movimento do sistema na forma:

$$\ddot{y}_1 = \frac{1}{m} [(F_1 - F_3) - \sqrt{2} mg - c_{yy}\dot{y}_1 - \sqrt{2} c_{yz}\dot{z}_1 - k_{yy}y_1 - \sqrt{2} k_{yz}z_1 + m_d e \Omega^2 \cos \Omega t] \quad (5.8)$$

$$\ddot{z}_1 = \frac{1}{m} [(F_2 - F_4) - \sqrt{2} mg - \sqrt{2} c_{zy}\dot{y}_1 - c_{zz}\dot{z}_1 - \sqrt{2} k_{zy}y_1 - k_{zz}z_1 + m_d e \Omega^2 \sin \Omega t] \quad (5.9)$$

onde F_1, F_2, F_3, F_4 são as forças magnéticas geradas pelos atuadores, h_0 é o entreferro do mancal, c_{yy} e c_{zz} são os coeficientes de amortecimento do filme de óleo, k_{yy} , k_{zz} são os coeficientes de rigidez do filme de óleo, k_{yz} , k_{zy} , c_{yz} , c_{zy} são os coeficientes de rigidez e de amortecimento cruzado do filme de óleo, respectivamente.

A seguir, é apresentado o critério utilizado para definir as duas trajetórias de referência nas direções Y_1 e Z_1 , e assim obter a trajetória de órbita controlada do rotor. Assim, são propostas quatro condições de trajetórias de referência que serão utilizadas nas simulações. A trajetória positiva, refere-se a deslocamento do rotor nas posições positivas dos eixos Y_1 ou do eixo Z_1 . A trajetória negativa é o deslocamento do rotor nas posições negativas dos eixos Y_1 ou do eixo Z_1 . A seguir são mostradas as quatro condições propostas:

- **Condição 1:** Y_1 trajetória negativa e Z_1 trajetória positiva
- **Condição 2:** Y_1 trajetória positiva e Z_1 trajetória negativa
- **Condição 3:** Y_1 trajetória negativa e Z_1 trajetória negativa
- **Condição 4:** Y_1 trajetória positiva e Z_1 trajetória positiva

Definidas as quatro trajetórias de referência, agora são avaliadas cada uma delas para determinar a capacidade de resposta que o controle NNMPC MIMO tem para as diferentes posições propostas. Os parâmetros do controle utilizados em todas as simulações são: $N = 5$, $N_u = 3$, $\lambda = 0.85$, $u^{min} = -10V$, $u^{max} = 10V$. O sistema foi simulado numericamente mas o processo de identificação foi desenvolvido com dados experimentais da bancada a diferentes tensões que foram aplicadas aos atuadores eletromagnéticos. A simulação considerou duas condições, a primeira quando o sistema não tem distúrbio e a segunda quando o sistema tem um distúrbio de desbalanço acionado no instante de tempo $k = 300$. Os resultados são mostrados em conjuntos de duas figuras para cada uma das quatro condições. A primeira figura mostra o sinal de controle e a resposta do sistema na direção Y_1 . A segunda figura mostra o sinal de controle e a resposta do sistema na direção Z_1 .

Nas Figs. 5.18 e 5.19 apresentam-se o detalhe (*zoom*) do sinal de controle e o detalhe da resposta do sistema respectivamente. Este *zoom* é necessário porque as respostas expressadas em voltagem (sinal de controle) e em deslocamento (resposta do sistema) são mostradas numa escala muito pequena. Lembrando que os deslocamentos do rotor está na ordem de microns e as voltagens necessárias para esses deslocamentos são também pequenas. Assim, a partir deste ponto, as figuras correspondentes a sinal de controle e a resposta do sistema para cada uma das quatro condições propostas serão apresentadas na forma de detalhe (*zoom*).

Nas Figs. 5.20 a 5.27, são mostrados os resultados obtidos para as quatro condições propostas estando o rotor a uma velocidade de rotação fixa de 20 Hz e sem distúrbio externo. Os resultados obtidos foram bastante similares em todos os casos e os sinais de controle ficaram dentro da faixa limite de tensão dos atuadores eletromagnéticos ($\pm 10 V$). A resposta do sistema mostra o percurso de rotor sob a trajetória de referência. Esta trajetória é formada de degraus de diferentes tamanhos na ordem de dezenas de microns (μm).

O sistema de controle teve uma resposta aceitável, qualquer que fosse o quadrante em que a trajetória de referência se encontrava. Além disso, há um tempo de acomodação maior na direção Z_1 , provavelmente porque os atuadores nesta direção têm menor capacidade de atuação do que na outra direção (lembrando que o controlador se baseia em uma rede neural treinada com dados experimentais da bancada de testes).

Uma possível aplicação do controle preditivo NN MPC-MIMO poderia ser o deslocamento do rotor a posições distantes das velocidades críticas em determinadas condições de operação. Para isso o controle seria utilizado somente para realizar esse deslocamento.




Figura 5.18. Sinal de controle mostrando o detalhe para o análise.

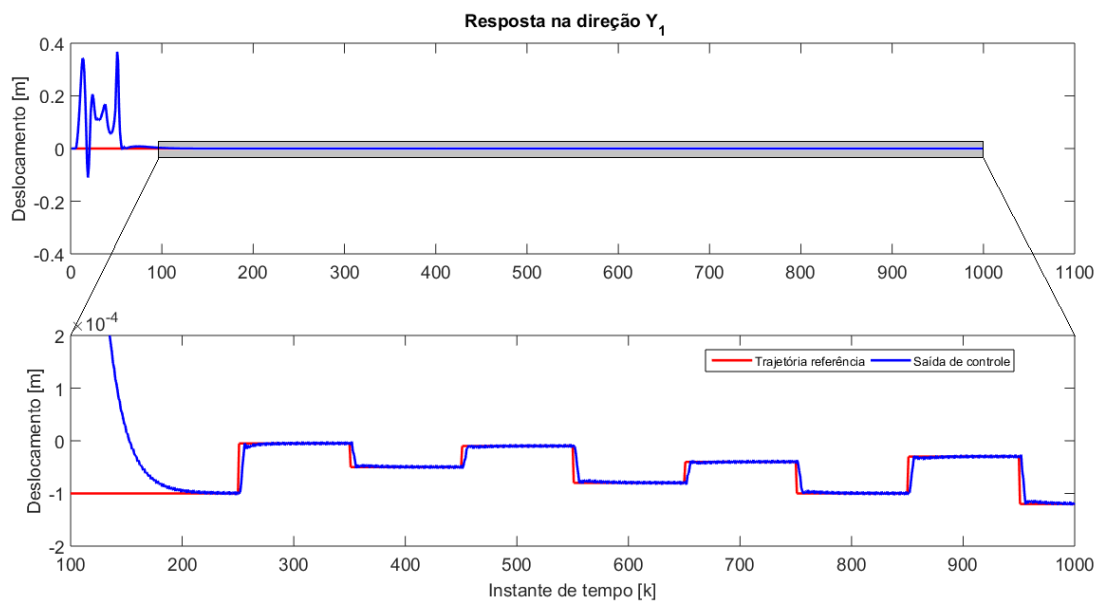


Figura 5.19. Resposta do sistema mostrando o detalhe para o análise.




Figura 5.20. Condição 1: (a) Sinal de controle, (b) Resposta do sistema na direção Y_1 .




Figura 5.21. Condição 1: (a) Sinal de controle, (b) Resposta do sistema na direção Z_1 .

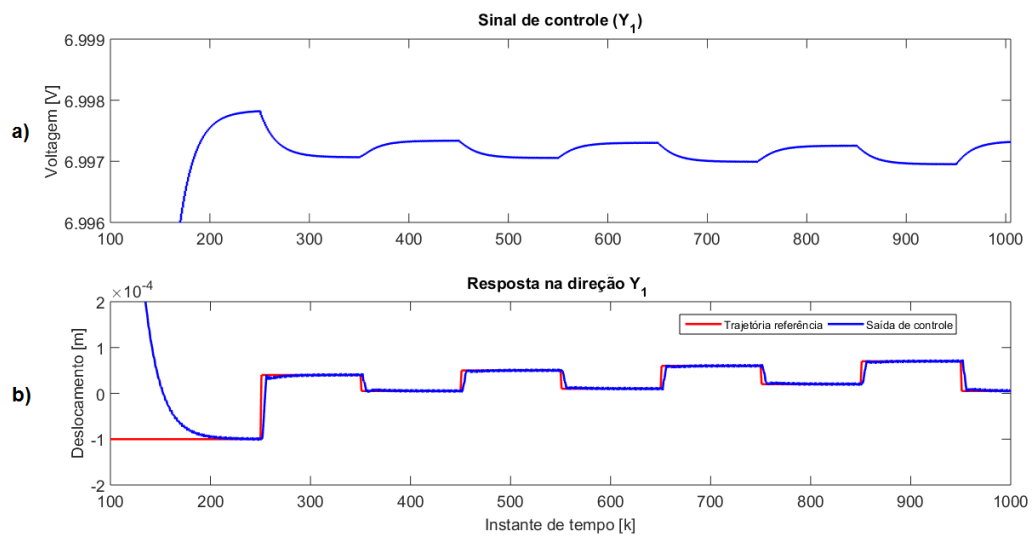


Figura 5.22. Condição 2: (a) Sinal de controle, (b) Resposta do sistema na direção Y_1 .




Figura 5.23. Condição 2: (a) Sinal de controle, (b) Resposta do sistema na direção Z_1 .

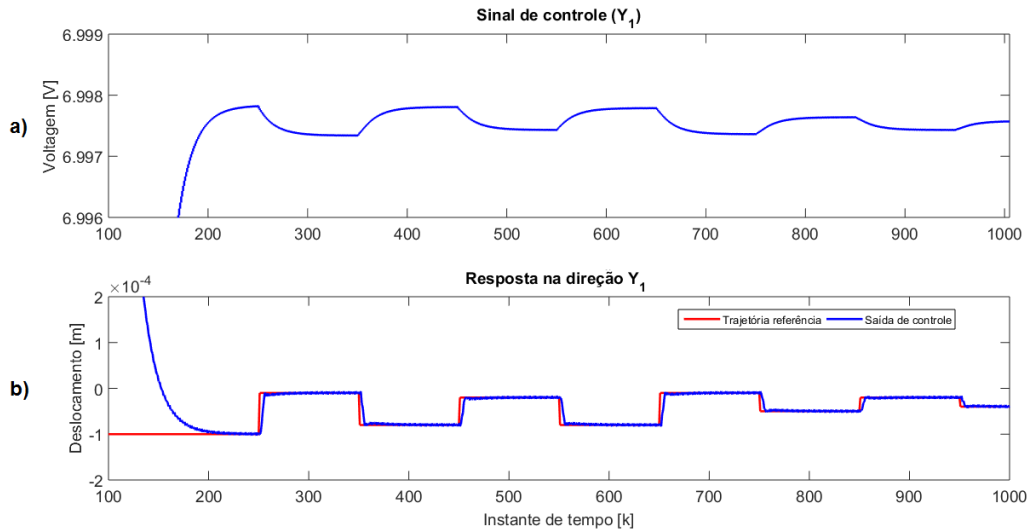


Figura 5.24. Condição 3: (a) Sinal de controle, (b) Resposta do sistema na direção Y_1 .




Figura 5.25. Condição 3: (a) Sinal de controle, (b) Resposta do sistema na direção Z_1 .




Figura 5.26. Condição 4: (a) Sinal de controle, (b) Resposta do sistema na direção Y_1 .




Figura 5.27. Condição 4: (a) Sinal de controle, (b) Resposta do sistema na direção Z_1 .

A seguir, as Figs. 5.28 a 5.35, mostram os resultados obtidos para as quatro condições propostas estando o sistema a uma velocidade de rotação fixa de 20 Hz, mas desta vez é considerado o distúrbio externo (desbalanceo) aplicado no instante de tempo $k = 300$. Os resultados também foram similares em todos os casos.

Novamente, a resposta do sistema mostra que o controle foi capaz de mover o rotor sob a trajetória de referência mesmo estando o sistema submetido ao distúrbio. O sistema de controle teve uma resposta aceitável, qualquer que fosse o quadrante desejado. Este deslocamento controlado do rotor apresenta variações sinusoidais devido ao distúrbio que tenta interferir na correta trajetória, no entanto, esta trajetória controlada continua sob a referência proposta. O tempo de acomodação também permanece maior na direção Z_1 , provavelmente porque os atuadores nesta direção têm menor capacidade de atuação do que na outra direção.




Figura 5.28. Condição 1 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Y_1 .




Figura 5.29. Condição 1 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Z_1 .




Figura 5.30. Condição 2 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Y_1 .




Figura 5.31. Condição 2 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Z_1 .




Figura 5.32. Condição 3 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Y_1 .




Figura 5.33. Condição 3 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Z_1 .




Figura 5.34. Condição 4 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Y_1 .

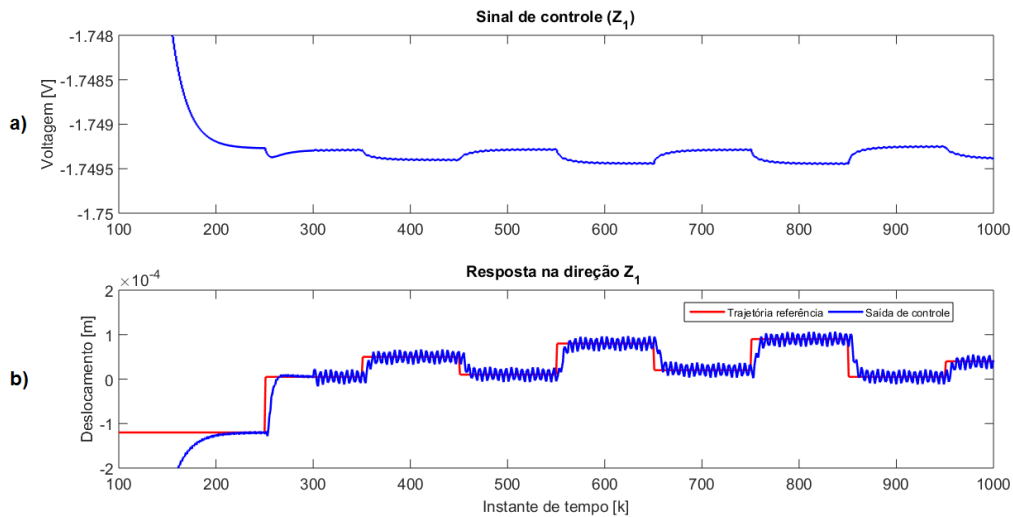


Figura 5.35. Condição 4 com distúrbio: (a) Sinal de controle, (b) Resposta do sistema em Z_1 .

Para avaliar mais uma vez a capacidade que tem o controle preditivo neural NNMPC-MIMO de lidar com distúrbios externos, desta vez o controle é testado com um distúrbio aleatório em amplitude e período. Assim, o controle NNMPC-MIMO foi testado com distúrbios de três diferentes amplitudes ($\pm 10, \pm 30, \pm 60 \mu m$) que interferem diretamente sob a trajetória controlada do rotor. A trajetória de referência variou-se a valores que combinam posições negativas e positivas alternadamente para observar a resposta do controlador. A seguir são mostrados as figuras com os resultados destas simulações.

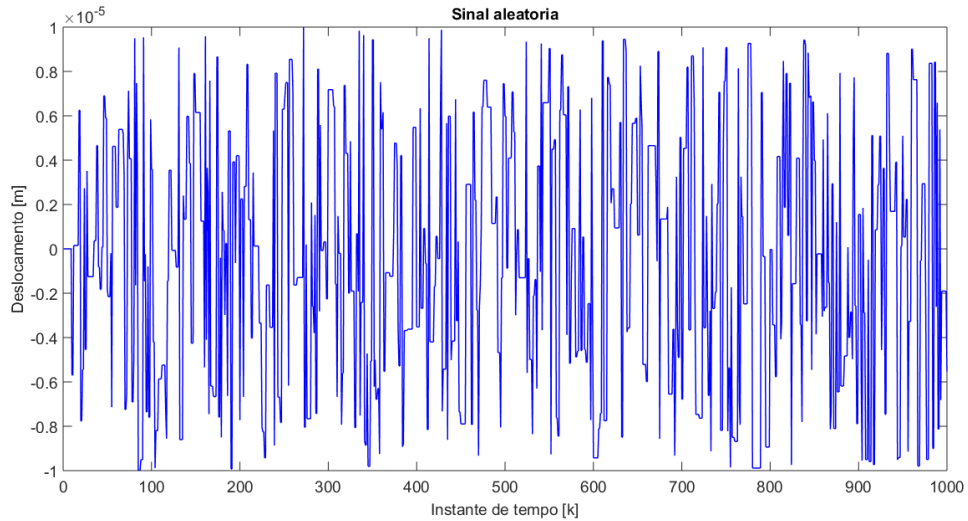


Figura 5.36. Sinal de distúrbio aleatório de amplitude máxima $\pm 10\mu m$.

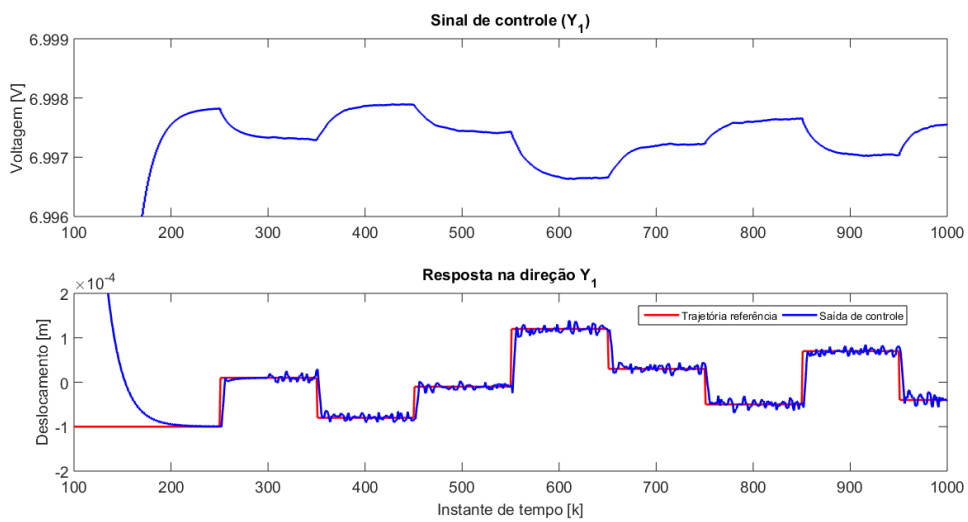


Figura 5.37. Distúrbio aleatório $\pm 10\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Y_1 .




Figura 5.38. Distúrbio aleatório $\pm 10\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Z_1 .




Figura 5.39. Sinal de distúrbio aleatório de amplitude máxima $\pm 30\mu m$.

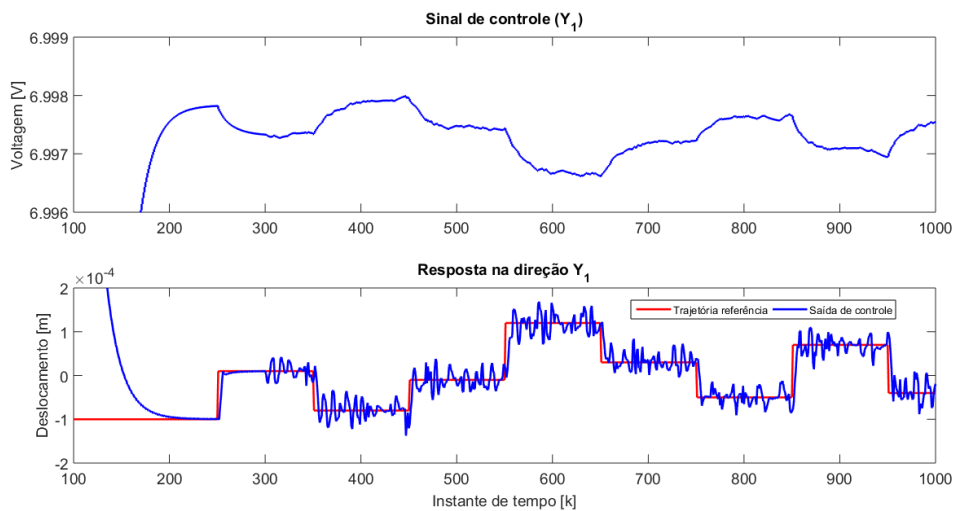


Figura 5.40. Distúrbio aleatório $\pm 30\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Y_1 .

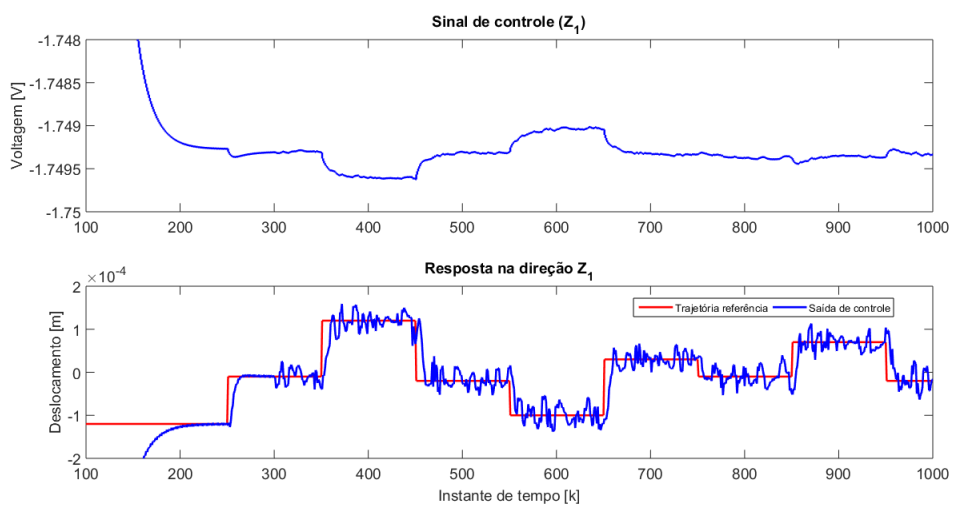


Figura 5.41. Distúrbio aleatório $\pm 30\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Z_1 .




Figura 5.42. Sinal de distúrbio aleatório de amplitude máxima $\pm 60\mu m$.




Figura 5.43. Distúrbio aleatório $\pm 60\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Y_1 .

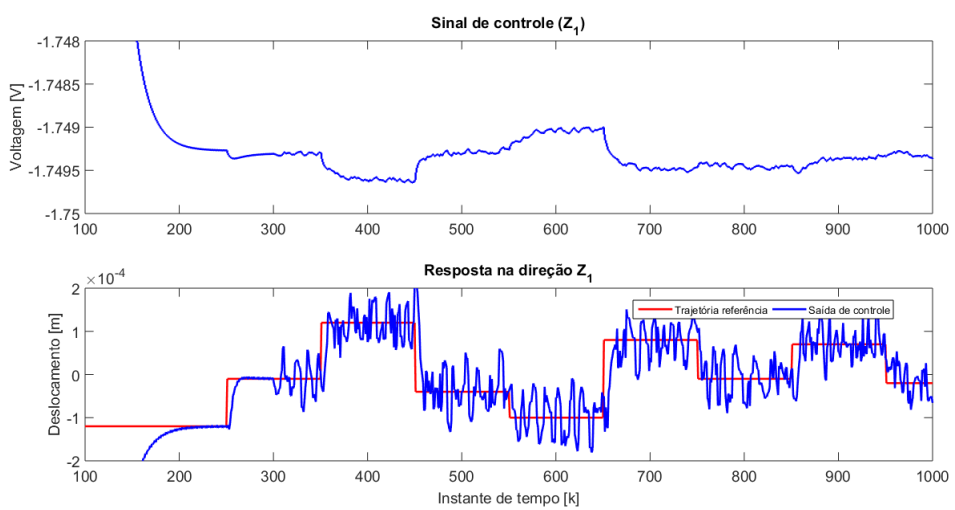


Figura 5.44. Distúrbio aleatório $\pm 60\mu m$: (a) Sinal de controle, (b) Resposta do sistema em Z_1 .

5.3 Conclusão

O algoritmo NN MPC-MIMO foi simulado numericamente tendo como base uma identificação multivariável não-linear da planta realizada mediante uma rede neural NARX-MIMO que utilizou dados experimentais colhidos na bancada de testes. Foram testadas diferentes amplitudes de excitação (2 V, 3 V, 4 V, 5 V e 6 V) aplicadas aos atuadores eletromagnéticos e com os resultados formaram-se os pares entrada/saída para o processo de identificação multivariável (treinamento e operação da rede neural NARX-MIMO). A velocidade de rotação do sistema foi fixada em 20 Hz. Foi aplicado um distúrbio externo (força de desbalanço) para avaliar a capacidade de resposta do controle preditivo neural.

Os resultados mostram que o controle preditivo NN MPC-MIMO é capaz de manter o deslocamento do rotor em uma determinada trajetória de referência definida previamente e em qualquer que seja o quadrante desejado. Acontece o mesmo, quando o sistema é submetido aos efeitos de um distúrbio externo (desbalanço ou ruído).

Cabe lembrar que o controlador NN MPC-MIMO precisa resolver um problema de otimização quadrática a cada instante de tempo k . Este fato pode se tornar uma desvantagem se quisermos a implementação experimental do controlador na bancada de testes. Para isso seria necessário algoritmos computacionais com menor custo computacional (por ex. método dos pontos interiores aplicado a problemas de otimização convexa) ou também possuir recursos computacionais (processamento extremamente rápido) e de hardware especializados (por ex. DSpace) para acompanhar a dinâmica do sistema a uma taxa de amostragem de 1 kHz e que não afete o desempenho do controlador.

6 CONCLUSÕES

Na presente tese foi abordado o controle ativo de posição do rotor mediante o mancal híbrido ativo. Para tal fim foi proposto o algoritmo de controle preditivo neural NNMPC-MIMO, desenvolvido sob a premissa de uma identificação experimental multivariável da planta mediante uma rede neural NARX-MIMO. A predição neural dos valores futuros da planta é usada no desenvolvimento do controle que prevê a minimização de uma função custo sujeita a restrições, a sua solução é obtida resolvendo para cada instante de tempo k o problema de otimização quadrática. Os resultados obtidos foram:

- Para o algoritmo NNMPC-SISO realizou-se uma identificação não-linear da planta com os dados entrada/saída gerados utilizando as equações não-lineares do sistema. Esta identificação ajudou a implementar o algoritmo de controle para um sistema de um grau de liberdade. Foram obtidos resultados no domínio do tempo com precisão aceitável principalmente quando foi aplicado um distúrbio (força de desbalanço) ao sistema. O algoritmo NNMPC-SISO controla o deslocamento do rotor de acordo com a trajetória de referência desejada.

O algoritmo NNMPC-MIMO considera uma identificação multivariável não-linear da planta mediante uma rede neural NARX-MIMO. Foram utilizados os dados experimentais reais colhidos da bancada de testes, e obtidos mediante a aplicação de diferentes entradas (2 V, 3 V, 4 V, 5 V e 6 V) aos atuadores eletromagnéticos para montar os pares entrada/saída que foram utilizados na identificação neural. Já a simulação numérica do algoritmo de controle NNMPC-MIMO apresentou resultados aceitáveis ao controlar o deslocamento do rotor nas duas direções ortogonais (Y_1 e Z_1). Quando o sistema está submetido a distúrbios (força desbalanço ou ruído) a resposta do controlador foi satisfatória pois manteve o deslocamento do rotor em torno da referência de posição.

- Foi desenvolvido uma metodologia para a identificação multivariável não-linear da planta mediante o uma rede neural NARX-MIMO. Além das duas entradas originais u_1 e u_2 foram utilizadas novas entradas que tem a forma das equações não-lineares do sistema e estão em função destas entradas originais. No total a rede neural de identificação utilizou 9 entradas e duas saídas recorrentes como se mostra na Tabela 5.2. A proposta de utilizar entradas da forma que expressem as equações não-lineares do sistema resultou numa melhoria significativa e contribuiu com o sucesso da identificação multivariável não-linear. O número de neurônios na camada escondida ficou em 20 e o melhor algoritmo de treinamento foi a Regularização Bayesiana (*Bayesian Regularization*). Esta metodologia torna-se uma contribuição importante na área de identificação não-linear de sistema com atuadores eletromagnéticos mediante redes neurais recorrentes.

- Para a verificação da viabilidade de uso do controlador preditivo neural no sistema mancal híbrido ativo (MHA) é necessário primeiro, alterar o algoritmo computacional a um de menor custo computacional (por ex. método dos pontos interiores aplicado a problemas de otimização convexa). Segundo, a implementação de hardware especializado em tratamento em tempo real para taxas de amostragem de 1kHz podem viabilizar a implementação do controle preditivo na bancada experimental. Sua viabilidade prática depende em grande medida da instalação desses equipamentos.

Como sugestão para trabalhos futuros e de continuação desta linha de pesquisa, tem-se a investigação de sistemas de hardware capazes de executar as operações necessárias para a implementação experimental em tempo real do controlador estudado. Assim, seria possível verificar a eficiência do controlador preditivo neural no mancal híbrido ativo existente na EESC/USP. Outra investigação, que ainda fica em aberto é o análise do comportamento do sistema rotor-mancal controlado pelo NNMPC-MIMO no domínio da frequência. Seria interessante, ainda, investigar a robustez do controlador NNMPC-MIMO a eventos não previstos na identificação neural e outros tipos de distúrbios (impactos, excitações assíncronas, etc).

REFERÊNCIAS

- BALINI, H. M. N. K. et al. Active magnetic bearings: Robust performance against uncertainty in rotational speed. **IFAC Proceedings Volumes**, v. 43, n. 18, p. 355–362, 2010.
- BEMPORAD, A.; MORARI, M. Robust model predictive control: A survey. In: **Robustness in identification and control**. [S.l.]: Springer, 1999. p. 207–226.
- BOYD, S. et al. **Linear matrix inequalities in system and control theory**. [S.l.]: Siam, 1994. v. 15.
- BUI, D. T. et al. Landslide susceptibility assessment in the hoa binh province of vietnam: a comparison of the levenberg–marquardt and bayesian regularized neural networks. **Geomorphology**, v. 171, p. 12–29, 2012.
- BUTTINI, T.; NICOLETTI, R. Direct synthesis from frequency response measurements applied to the controller design of a servo positioning system. In: ABCM (Ed.). **20Th. INT. CONGRESS OF MECHANICAL ENGINEERING**. [S.l.: s.n.], 2009. p. 1–7.
- CADE, I. et al. On the use of auxiliary bearings to escape from trapped contact modes in rotor/magnetic bearings. In: **Proceedings of the institution of mechanical engineers 9th international conference on vibrations in rotating machinery**. [S.l.: s.n.], 2008. p. 111–123.
- CAMACHO, E.; BORDONS, C. **Model predictive control**. [S.l.]: Springer-Verlag London Limited, 2004.
- CHEN, S.-C. et al. Nonlinear control of an active magnetic bearing system achieved using a fuzzy control with radial basis function neural network. **Journal of Applied Mathematics**, Hindawi Publishing Corporation, v. 2014, 2014.
- CHIBA, A. et al. **Magnetic bearings and bearingless drives**. [S.l.]: Elsevier, 2005.
- CLARKE, D. W.; MOHTADI, C.; TUFFS, P. Generalized predictive control—part i. the basic algorithm. **Automatica**, Elsevier, v. 23, n. 2, p. 137–148, 1987.
- COSTAL, G. Z.; NICOLETTI, R. Design definition of the pad-solenoid subsystem in active hidromagnetic bearings. In: ABCM (Ed.). **19Th. INT. CONGRESS OF MECHANICAL ENGINEERING**. [S.l.: s.n.], 2007. p. 1–10.
- CUTLER, C. R.; RAMAKER, B. L. Dynamic matrix control: A computer control algorithm. In: **Joint Automatic Control Conference**. [S.l.: s.n.], 1980. p. 72.
- DIAS, A.; MENUZZO, R.; NICOLETTI, R. Magnetic field force identification of commercial magnets for building electromagnetic shakers. In: ABCM (Ed.). **19Th. INT. CONGRESS OF MECHANICAL ENGINEERING**. [S.l.: s.n.], 2007. p. 1–10.
- DONG, L.; YOU, S. Adaptive control of an active magnetic bearing with external disturbance. **ISA transactions**, v. 53, n. 5, p. 1410–1419, 2014.
- EL-SHAFEI, A.; DIMITRI, A. S. Controlling journal bearing instability using active magnetic bearings. **ASME J. Eng. Gas Turbines Power**, p. 012502, 2010.

EL-SHAFEI, A.; EL-HAKIM, M. Experimental investigation of adaptative control applied to *HSFD* supported rotors. **ASME J. Eng. Gas Turbines Power**, p. 757–766, 2000.

EL-SHAFEI, A.; HATHOUT, J. Modelling and control of *HSFD* for active control of rotor-bearing systems. **ASME 1994 International Gas Turbine and Aeroengine Congress and Exposition**, 1994.

FARMAKOPOULOS, M.; NIKOLAKOPOULOS, P.; PAPADOPOULOS, C. Design of an active hydromagnetic journal bearing. **Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology**, 2012.

FORESEE, F. D.; HAGAN, M. T. Gauss-newton approximation to bayesian learning. In: IEEE. **Neural Networks, 1997., International Conference on**. [S.l.], 1997. v. 3, p. 1930–1935.

GAHINET, P. et al. The lmi control toolbox. In: IEEE. **Decision and Control, 1994., Proceedings of the 33rd IEEE Conference on**. [S.l.], 1994. v. 3, p. 2038–2041.

GIBSON, N. S.; CHOI, H.; BUCKNER, G. D. H-infinity control of active magnetic bearings using artificial neural network identification of uncertainty. In: IEEE. **Systems, Man and Cybernetics, 2003. IEEE International Conference on**. [S.l.], 2003. v. 2, p. 1449–1456.

GRECO, C. et al. Performance improvements of self-tuning controllers by multistep horizons: The musmar approach. **Automatica**, v. 20, n. 5, p. 681–699, 1984.

GRONEK, M.; ROTTENBACH, T.; WORLITZ, F. A contribution on the investigation of the dynamic behavior of rotating shafts with a hybrid magnetic bearing concept (hmbc) for blower applicationiasis. **Nuclear Engineering and Design**, v. 240, n. 10, p. 2436–2442, 2010.

HAGAN, M. T. et al. **Neural Network Design**. 2nd. ed.. ed. [S.l.]: Martin Hagan, 2014.

HAGAN, M. T.; DEMUTH, H. B.; DEJESUS. An introduction to the use of neural networks in control system. **Int. Journal of Robust and Nonlinear Control**, p. 959–985, 2002.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. **IEEE transactions on Neural Network**, v. 5, n. 6, p. 989–993, 1994.

HAYKIN, S. **Neural Networks**. [S.l.]: New Jersey: Prentice Hall, 1999.

HEBB, D. O. **The organization of behavior: A neuropsychological approach**. [S.l.]: John Wiley & Sons, 1949.

HIRANI, H.; SAMANTA, P. Hybrid (hydrodynamic+ permanent magnetic) journal bearings. **Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology**, v. 221, n. 8, p. 881–891, 2007.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the national academy of sciences**, National Acad Sciences, v. 79, n. 8, p. 2554–2558, 1982.

HOSEN, M. A.; HUSSAIN, M. A.; MJALLI, F. S. Control of polystyrene batch reactors using neural network based model predictive control (nnmpc): An experimental investigation. **Control Engineering Practice**, Elsevier, v. 19, n. 5, p. 454–467, 2011.

ISHIDA, Y.; INOUE, T. Vibration characteristics of a rotor system in contact with a backup bearing: cases with various failure patterns of the active magnetic bearing. **Journal of Vibration and Control**, v. 14, n. 4, p. 571–589, 2008.

JANCZAK, A. **Identification of Nonlinear Systems using Neural Network and Polynomial Models**. [S.l.]: Berlin: Springer-Verlag, 2005.

JUNG; YOUNG, S.; CHOI, S.-B. Analysis of a short squeeze-film damper operating with electrorheological fluids. **Tribology transactions**, v. 38, n. 4, p. 857–862, 1995.

KASARDA, M. An overview of active magnetic bearing technology and applications. **The shock and vibration digest**, v. 32, n. 2, p. 91–99, 2000.

KEYSER, R. D.; CAUWENBERGHE, A. V. Extended prediction self-adaptive control. In: **IFAC Symposium on Identification and System Parameter Estimation**. [S.l.: s.n.], 1985. v. 17, n. 1255–1260.

KIANI, M. et al. Hybrid control of a three-pole active magnetic bearing. **Mechatronics**, v. 39, p. 28–41, 2016.

KIM, K.; LEE, C.; KOO, J. Design and modeling of semi-active squeeze film dampers using magneto-rheological fluids. **Smart Materials and Structures**, v. 17, n. 3, p. 035006, 2008.

KITTISUPAKORN, P. et al. Neural network based model predictive control for a steel pickling process. **Journal of Process Control**, Elsevier, v. 19, n. 4, p. 579–590, 2009.

KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological cybernetics**, v. 43, n. 1, p. 59–69, 1982.

KOSTOPOULOS, A.; GRAPSA, T. Self-scaled conjugate gradient training algorithms. **Neurocomputing**, v. 72, p. 3000–3019, 2009.

ŁAWRYŃCZUK, M. **Computationally efficient model predictive control algorithms: a neural network approach, studies in systems, decision and control**. [S.l.]: Heidelberg: Springer, 2014. v. 3.

LIANG, Q. et al. Study on bearing load identification of rotor bearing system based on artificial neural networks. In: IEEE. **2010 International Conference on Measuring Technology and Mechatronics Automation**. [S.l.], 2010. v. 3, p. 568–571.

MACIEJOWSKI, J. M. **Predictive control with constraints**. [S.l.]: Harlow: Prentice Hall, 2002.

MACKAY, D. J. Bayesian interpolation. **Computational and Neural Systems**, v. 4, n. 3, p. 415–447, 1992.

MAGNI, L.; SCATTOLINI, R. Robustness and robust design of mpc for nonlinear discrete-time systems. In: **Assessment and future directions of nonlinear model predictive control**. [S.l.]: Springer, 2007. p. 239–254.

MARQUIS, P.; BROUSTAIL, J.; SMOC, A. Bridge between state space and model predictive controllers: Application to the automation of a hydrotreating unit. In: **Proceedings of the IFAC Workshop on model based predictive control**. [S.l.: s.n.], 1988.

MARWALA, T. Scaled conjugate gradient and bayesian training of neural networks for fault identification in cylinders. **Computers & structures**, v. 79, n. 79, p. 2793–2803, 2001.

MAYNE, D. Q. et al. Constrained model predictive control: Stability and optimality. **Automatica**, v. 36, n. 6, p. 789–814, 2000.

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

MINSKY, M.; PAPERT, S. **Perceptrons**. [S.l.]: MIT press, 1969.

MØLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural networks**, v. 6, n. 4, p. 525–533, 1993.

MORAES, D.; NICOLETTI, R. Hydrodynamic bearing with electromagnetic actuators: Rotor vibration control and limitations. **Int. Conference on Noise and Vibration Engineering. Leuven, Belgium.**, p. 3715–3721, 2010.

MORISHITA, S.; MITSUI, J. Controllable squeeze film damper (an application of electro-rheological fluid). **Journal of vibration and acoustics**, v. 114, n. 3, p. 354–357, 1992.

NARENDRA, K. S.; PARTHASARATHY, K. Identification and control of dynamic systems using neural network. **IEEE transactions on Neural Network**, p. 4–27, 1990.

NICOLETTI, R. **Mancal hidrodinâmico ativo com sapatas móveis magnéticas**. [S.l.], 2007. Revista de Propriedade Industrial, BR. No. PI 0.700.697-7.

NICOLETTI, R. **Estudo do Control Ativo e Passivo de Vibrações em Sistemas Rotativos e Estruturais**. 2013. Tese (Livre Docencia) — Escola de Engenharia de São Carlos - Universidade de São Paulo, 2013.

NICOLETTI, R.; SANTOS, I. F. Frequency response analysis of an actively lubricated rotor/tilting-pad bearing system. In: AMERICAN SOCIETY OF MECHANICAL ENGINEERS. **ASME Turbo Expo 2004: Power for Land, Sea, and Air**. [S.l.], 2004. p. 735–744.

NORMEY-RICO, J. E.; CAMACHO, E. **Control of dead-time processes**. [S.l.]: Springer Science & Business Media, 2007.

NTN CORPORATION. **Combined Externally Pressurized Gas-Magnetic Bearing Assembly and Spindle Device Utilizing the Same**. [S.l.], 2001. U.S. Patent 20020048257.

PEDRO, J. O.; TSHABALALA, T. Hybrid *NNMPC/PID* control of a two-link flexible manipulator with actuator dynamics. In: IEEE. **Control Conference (ASCC), 2015 10th Asian**. [S.l.], 2015. p. 1–6.

PETERKA, V. Predictor-based self-tuning control. **Automatica**, v. 20, n. 1, p. 39–50, 1984.

PILAT, A. Analytical modeling of active magnetic bearing geometry. **Applied Mathematical Modelling**, v. 34, n. 12, p. 3805–3816, 2010.

PITAS, I.; VENETSANOPOULOS, A. N. **Nonlinear Digital Filters**. [S.l.]: Springer & Business Media, 1990.

PIZARRO-VIVEROS, H.; BUTTINI, T.; NICOLETTI, R. Frequency response attenuation of rotating system using hydrodynamic bearing with electromagnetic actuators. In: MECÂNICAS, A. B. de Engenharia e C. (Ed.). **21st INT. CONGRESS OF MECHANICAL ENGINEERING - COBEM 2011**. [S.l.: s.n.], 2011.

PIZARRO-VIVEROS, H.; NICOLETTI, R. Lateral vibration attenuation of shafts supported by tilting-pad journal bearing with embedded electromagnetic actuators. **Journal of Engineering for Gas Turbines and Power**, v. 136, n. 042503-1, 2014.

_____. Active hybrid bearing using neural network applied model predictive control. In: ABCM (Ed.). **23rd INT. Congress of Mechanical Engineering - COBEM**. [S.l.: s.n.], 2015.

_____. Nonlinear identification of multivariable hydrodynamic-magnetic bearing through neural mimo narx model. In: ESCOLA DE ENGENHARIA DE SÃO CARLOS - UNIVERSIDADE DE SÃO PAULO. **1 Simpósio do Programa de Pós-Graduação em Engenharia Mecânica**. [S.l.], 2016.

QIN, S. J.; BADGWELL, T. A. A survey of industrial model predictive control technology. **Control engineering practice**, Elsevier, v. 11, n. 7, p. 733–764, 2003.

QINGCHANG, T.; WEI, L.; XUEJUN, X. Investigations on a magnetic-hydrodynamic hybrid thrust bearing. **Tribology Letters**, v. 12, n. 1, p. 61–66, 2002.

RAKHSHKHORSHID, M.; SENDESI, S.-A. T. Bayesian regularization neural networks for prediction of austenite formation temperatures (a c1 and a c3). **Journal of Iron and Steel Research, International**, v. 21, n. 2, p. 246–251, 2014.

RICHALET, J. et al. Algorithmic control of industrial processes. In: **Proceedings of the 4th IFAC symposium on identification and system parameter estimation**. [S.l.: s.n.], 1976. p. 1119–1167.

_____. Model predictive heuristic control: Applications to industrial processes. **Automatica**, v. 14, n. 5, p. 413–428, 1978.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958.

ROSSITER, J. **Model-based predictive control: a practical approach**. [S.l.]: CRC Press control series, 2003.

ROUHANI, R.; MEHRA, R. K. Model algorithmic control (mac); basic theoretical properties. **Automatica**, v. 18, n. 4, p. 401–414, 1982.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning internal representations by error propagation**. Cambridge, Massachusetts, USA, 1985.

SAINI, L. M. Peak load forecasting using bayesian regularization, resilient and adaptive backpropagation learning based artificial neural networks. **Electric Power Systems Research**, v. 78, n. 7, p. 1302–1310, 2008.

SANTOS, I. F. Design and evaluation of two types of active tilting pad journal bearings. In: **Proceeding of IUTAM Symposium on Active Control of Vibration**. [S.l.: s.n.], 1994. p. 79–87.

SANTOS, I. F.; NICOLETTI, R.; SCALABRIN, A. Feasibility of applying active lubrication to reduce vibration in industrial compressors. In: **AMERICAN SOCIETY OF MECHANICAL ENGINEERS. ASME Turbo Expo 2003, collocated with the 2003 International Joint Power Generation Conference**. [S.l.], 2003. p. 481–489.

SCHWEITZER, G.; MASLEN, E. H. **Magnetic bearings: theory, design, and application to rotating machinery**. [S.l.]: Springer Science & Business Media, 2009.

SILVA, I. d.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. [S.l.]: Artliber Editora Ltda., 2010.

SOCIETE MECHANIQUE MEGNETIQUE. **Hybrid Fluid Bearing With Stiffness Modified by Electromagnetic Effect**. [S.l.], 1989. U.S. Patent 4827169.

SOMEYA, T. **Journal Bearing Databook**. [S.l.]: Heidelberg: Springer-Verlag, 1989.

SUYKENS, J. A.; VANDEWALLE, J. P.; MOOR, B. L. de. **Artificial neural networks for modelling and control of non-linear systems**. [S.l.]: Springer Science & Business Media, 1996.

TATJEWSKI, P. **Advanced control of industrial processes: structures and algorithms**. [S.l.]: Springer Science & Business Media, 2007.

ULBRICH, H.; ALTHAUS, J. Actuator design for rotor control. In: **12th Biennial ASME Conference on Vibration and Noise**. [S.l.: s.n.], 1989. p. 12–22.

WANG, L. **Model predictive control system design and implementation using MATLAB®**. [S.l.]: Springer Science & Business Media, 2009.

WIDROW, B.; HOFF, M. Adaptive switching circuits. In: **NEW YORK. IRE WESCON convention record**. [S.l.], 1960. v. 4, n. 1, p. 96–104.

YDSTIE, B. E.; LIU, L. Single-and multi-variable control with extended prediction horizons. In: **American Control Conference**. [S.l.: s.n.], 1984. p. 1303–1308.

YU, D.; GOMM, J. Implementation of neural network predictive control to a multivariable chemical reactor. **Control Engineering Practice**, Elsevier, v. 11, n. 11, p. 1315–1323, 2003.

YU, Z.; WEN, D.; ZHANG, H. The identification model of magnetic bearing supporting system. In: **IEEE. Computer Science and Software Engineering, 2008 International Conference on**. [S.l.], 2008. v. 1, p. 70–73.

ZARENEZHAD, B.; AMINIAN, A. Application of the neural network-based model predictive controllers in nonlinear industrial systems. case study. **Journal of the University of Chemical Technology and Metallurgy**, v. 46, n. 1, p. 67–74, 2011.

ZHU, C.; ROBB, D. A.; EWINS, D. J. A magneto-rheological fluid squeeze film damper for rotor vibration control. In: **Proceeding of SPIE's 9th Annual International Symposium on Smart Structures and Materials**. [S.l.: s.n.], 2002. v. 4753, p. 516–522.

Apêndices

APÊNDICE A – PROCEDIMENTO DE LINEARIZAÇÃO DO MODELO SISO DO MANCAL HÍBRIDO ATIVO

A Fig. A.1, mostra o sistema mancal híbrido com um grau de liberdade (modelo SISO). Sendo assim, a equação do sistema dinâmico para modelo SISO incluindo a dinâmica dos dois atuadores eletromagnéticos é dada pela Eq. (A.1):

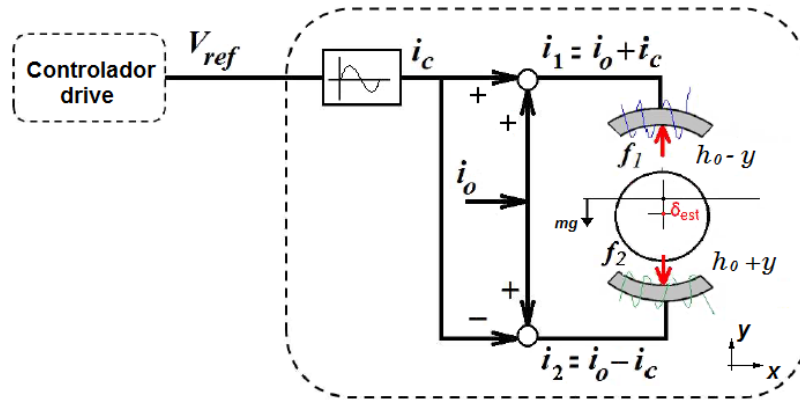


Figura A.1. Mancal híbrido de um grau de liberdade (modelo SISO).

$$m\ddot{y} + c_{yy}\dot{y} + k_{yy}y = mg + f_m + f_{ext} \quad (\text{A.1})$$

onde m é a massa do eixo, c_{xx} é o coeficiente de amortecimento equivalente, k_{xx} é o coeficiente de rigidez equivalente, f_m é a força magnética resultando dos dois atuadores, f_{ext} é a força externa (desbalanço). A força eletromagnética resultante é dada pela equação:

$$f_m = f_1 - f_2 \quad (\text{A.2})$$

$$f_m = \left(\frac{i_o + i_c}{h_0 - y} \right)^2 - \left(\frac{i_o - i_c}{h_0 + y} \right)^2 \quad (\text{A.3})$$

e a força externa que neste caso é a força de desbalanço:

$$f_{ext} = m\epsilon\Omega^2 \sin(\Omega t) \quad (\text{A.4})$$

É necessário considerar algumas hipóteses para a linearização da força eletromagnética resultante em um ponto de operação específico, neste caso esse ponto de operação está dado por: $i_c = 0$ e $x = \delta_{est}$. Onde i_c é corrente de controle e a posição do equilíbrio estático é $\delta_{est} = mg/k_{yy}$. Ignorando outras forças externas como os distúrbios medidos (força de desbalanço) $f_{ext} = 0$. A escolha apropriada do i_c pode ser realizada de modo a eliminar o termo

relativo ao peso próprio na equação. Para realizar uma aproximação linear da planta utilizamos a expansão por series de Taylor (CHIBA et al., 2005), assim tem-se:

$$f_m = f(i_p, y_p) + \underbrace{\frac{\partial f_m}{\partial i_p} \Big|_{i_p, y_p} (i_c - i_p)}_a + \underbrace{\frac{\partial f_m}{\partial y} \Big|_{i_p, y_p} (y - y_p)}_b \quad (\text{A.5})$$

desenvolvemos a parte (a) da equação de expansão nas condições estabelecidas:

$$\frac{\partial f_m}{\partial i_p} \Big|_{i_p=0, y_p=\delta_{est}} = \frac{2(i_0 + i_c)}{(h_0 - y)^2} - \frac{2(i_0 - i_c)(-1)}{(h_0 + y)^2} = \frac{2i_0}{(h_0 - \delta_{est})^2} + \frac{2i_0}{(h_0 + \delta_{est})^2} \quad (\text{A.6})$$

definimos o termo chamado de coeficiente de rigidez da corrente:

$$K_i = \frac{2i_0}{(h_0 - \delta_{est})^2} + \frac{2i_0}{(h_0 + \delta_{est})^2} \quad (\text{A.7})$$

desenvolvemos a parte (b) da equação de expansão nas condições estabelecidas:

$$\frac{\partial f_m}{\partial y} \Big|_{i_p=0, y_p=\delta_{est}} = \frac{(i_0 + i_p)^2(-2)(-1)}{(h_0 - y)^2(h_0 - y)} - \frac{(-2)(i_0 - i_p)^2}{(h_0 + y)^2(h_0 + y)} = \frac{2i_0^2}{(h_0 - \delta_{est})^3} + \frac{2i_0^2}{(h_0 + \delta_{est})^3} \quad (\text{A.8})$$

definimos o termo chamado de coeficiente de rigidez da posição:

$$K_y = \frac{2i_0^2}{(h_0 - \delta_{est})^3} + \frac{2i_0^2}{(h_0 + \delta_{est})^3} \quad (\text{A.9})$$

Finalmente, o coeficiente de rigidez da corrente (Eq. (A.7)) e o coeficiente de rigidez da posição (Eq. (A.9)) são utilizados para a linearização do modelo SISO do mancal híbrido ativo.

APÊNDICE B – OBTENÇÃO DE DADOS EXPERIMENTAIS DA BANCADA MANCAL HÍBRIDO

A seguir, são mostrados os dados experimentais da bancada mancal híbrido para uma frequência de rotação de 20 Hz com excitação na direções Y_1 e Z_1 (uma de cada vez). Os sinais de entrada aos atuadores foram os voltagens seguintes: 2 V, 3 V, 4 V, 5 V e 6 V.

EXCITAÇÃO NA DIREÇÃO Y_1 : Atuadores 1-3 e excitação com distúrbio não medido (desbalanceamento).




Figura B.1. Sistema rotor-mancal híbrido com excitação em u_1 na direção Y_1 .

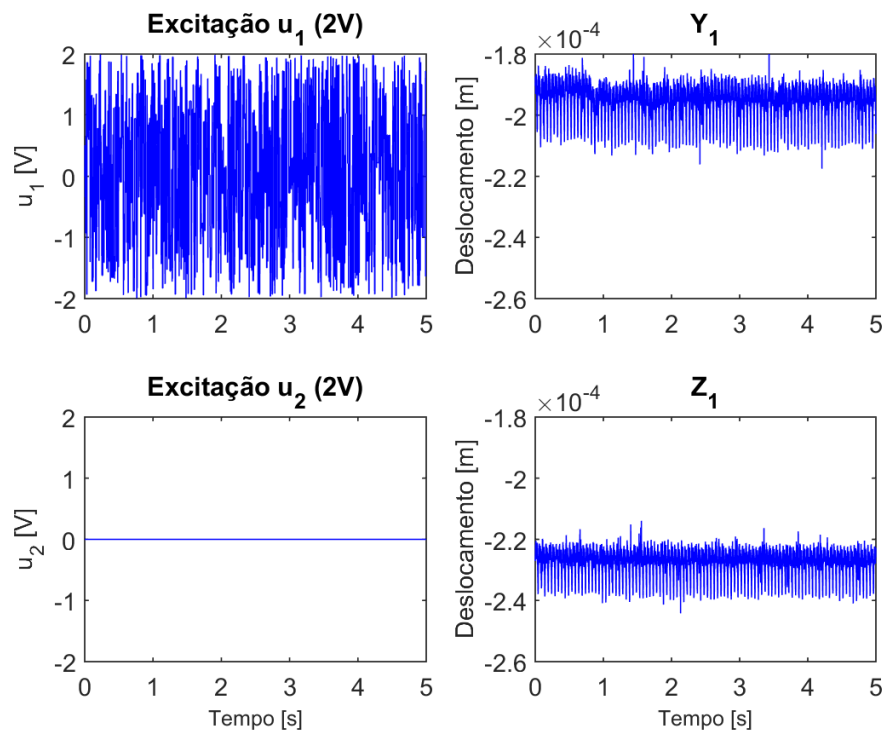


Figura B.2. Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Y_1 (2V) e medição em ambas direções (Y_1 e Z_1).

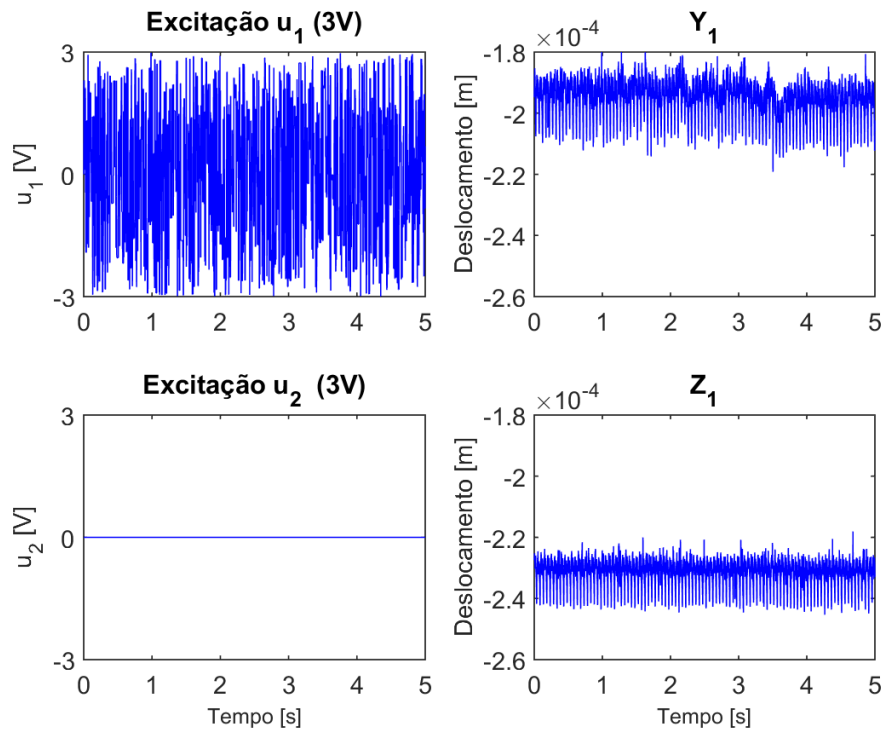


Figura B.3. Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Y_1 (3V) e medição em ambas direções (Y_1 e Z_1).

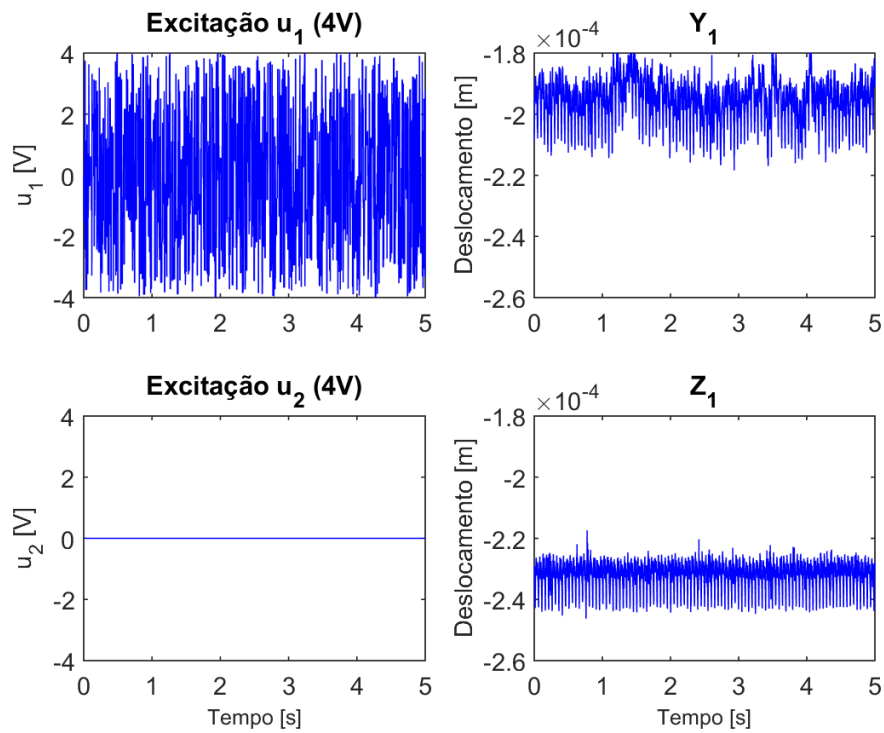


Figura B.4. Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Y_1 (4V) e medição em ambas direções (Y_1 e Z_1).




Figura B.5. Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Y_1 (5V) e medição em ambas direções (Y_1 e Z_1).

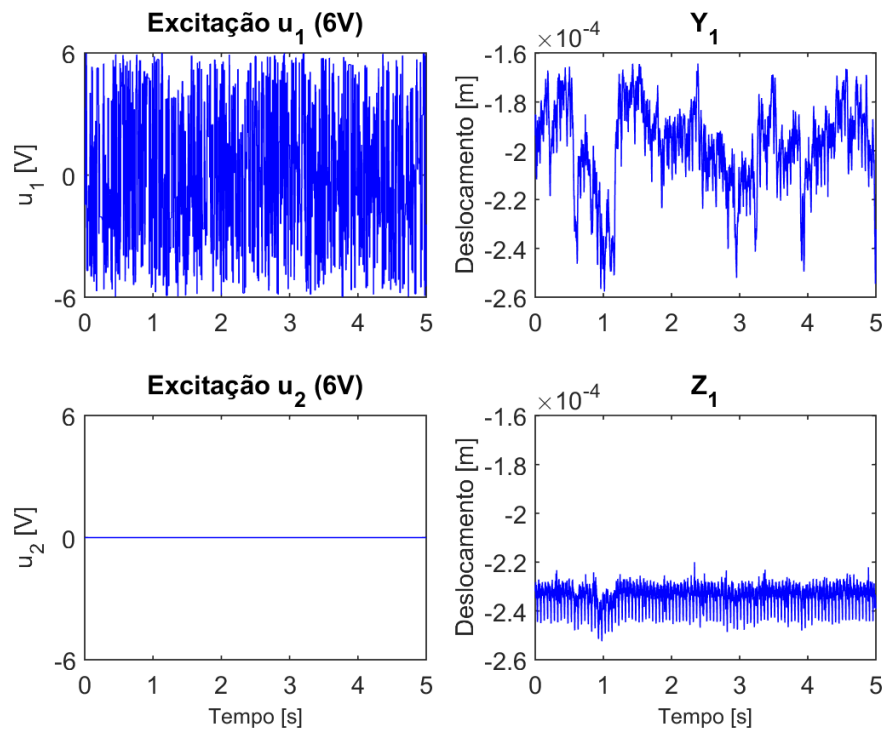


Figura B.6. Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Y_1 (6V) e medição em ambas direções (Y_1 e Z_1).

EXCITAÇÃO NA DIREÇÃO Z_1 : Atuadores 2-4 e excitação com distúrbio não medido (desbalanço).




Figura B.7. Sistema rotor-mancal híbrido com excitação em u_1 na direção Z_1 .

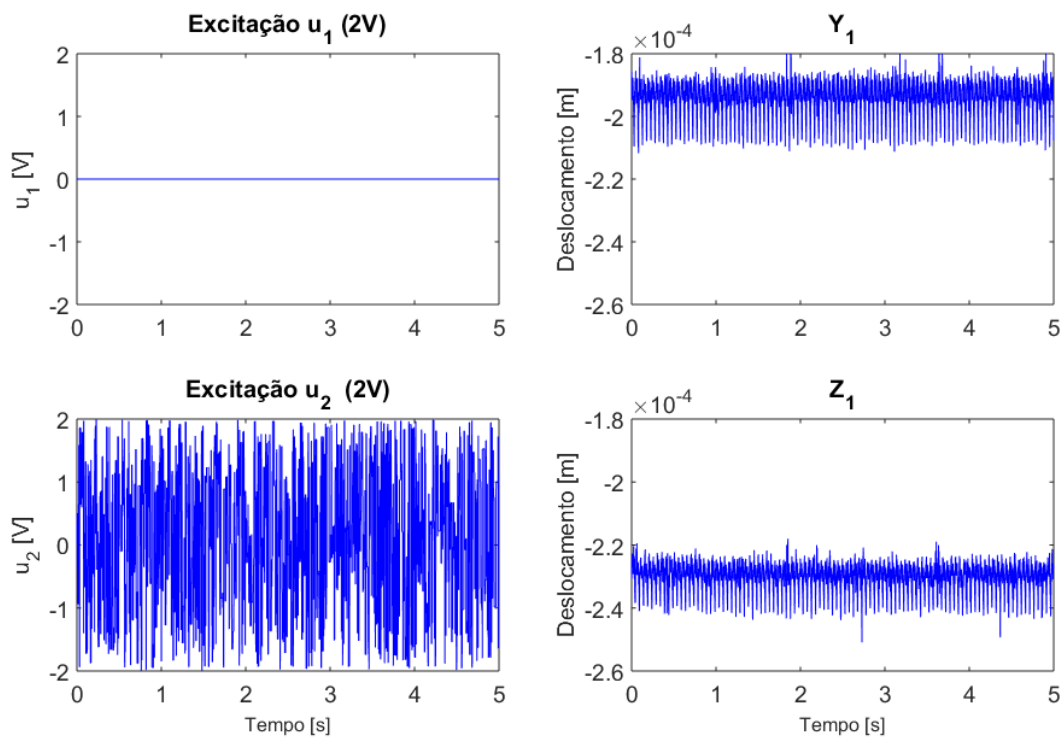


Figura B.8. Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Z_1 (2V) e medição em ambas direções (Y_1 e Z_1).

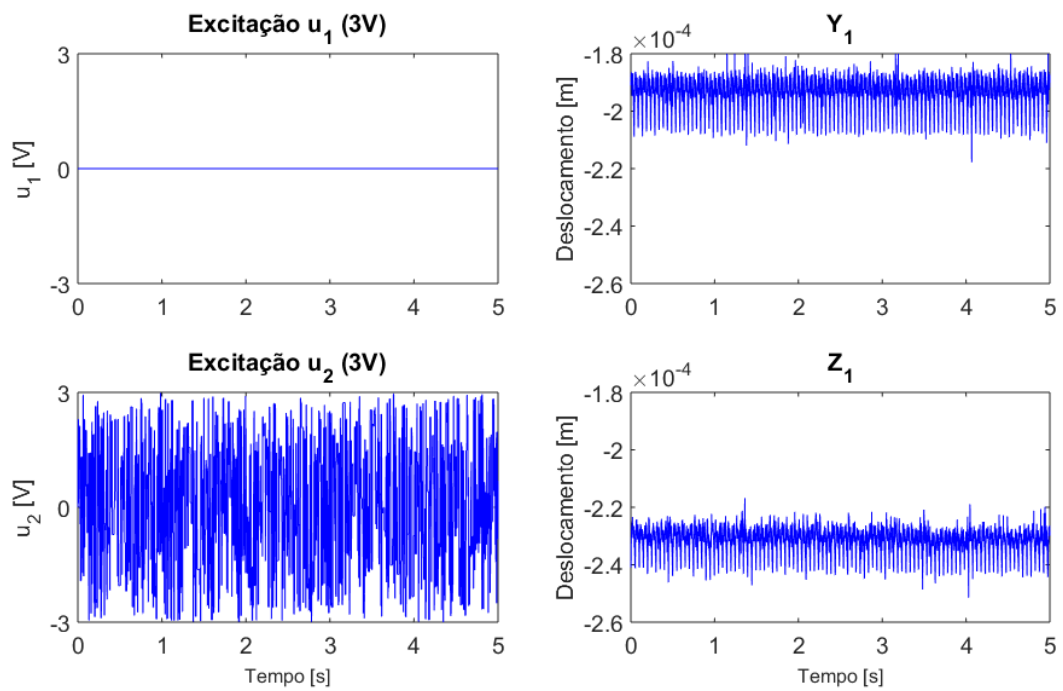


Figura B.9. Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Z_1 (3V) e medição em ambas direções (Y_1 e Z_1).

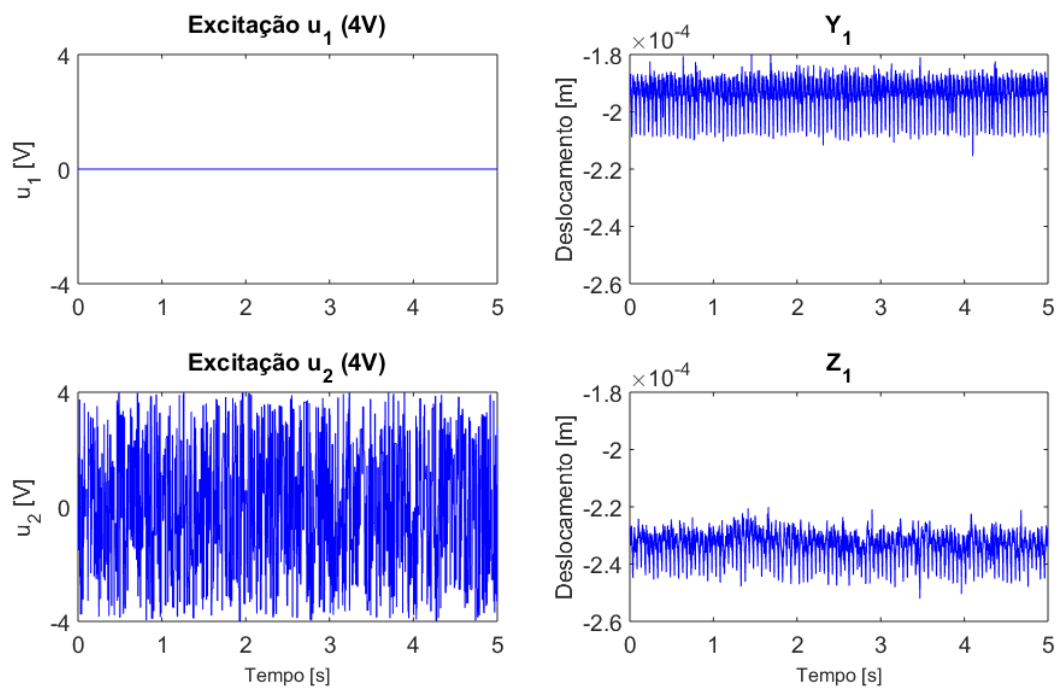


Figura B.10. Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Z_1 (4V) e medição em ambas direções (Y_1 e Z_1).

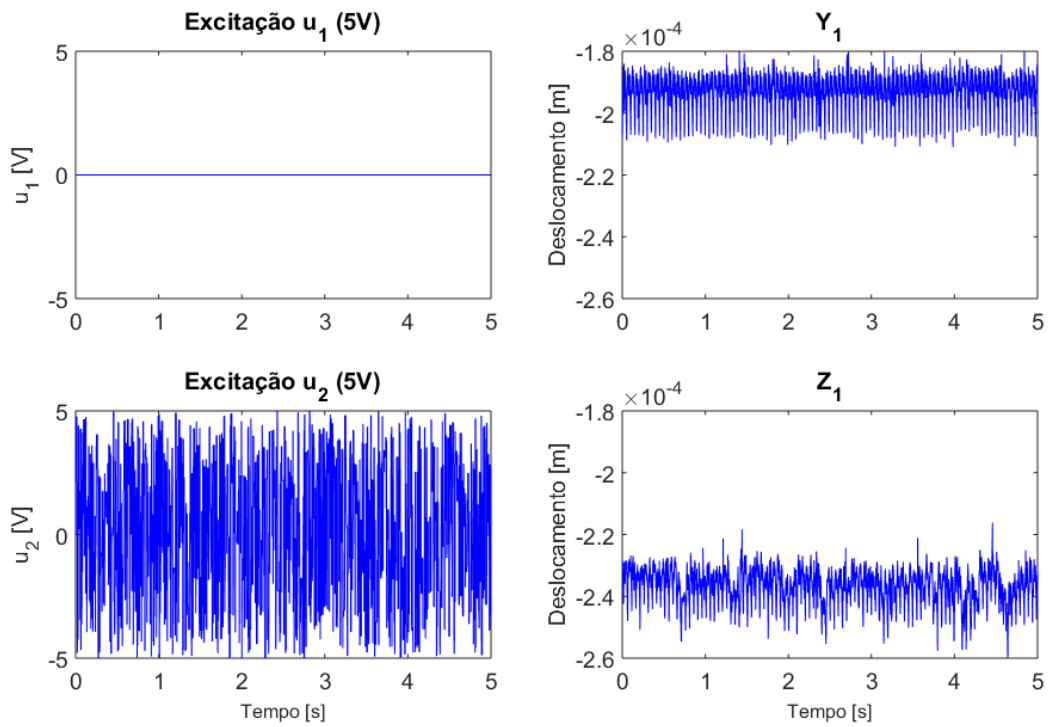


Figura B.11. Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Z_1 (5V) e medição em ambas direções (Y_1 e Z_1).

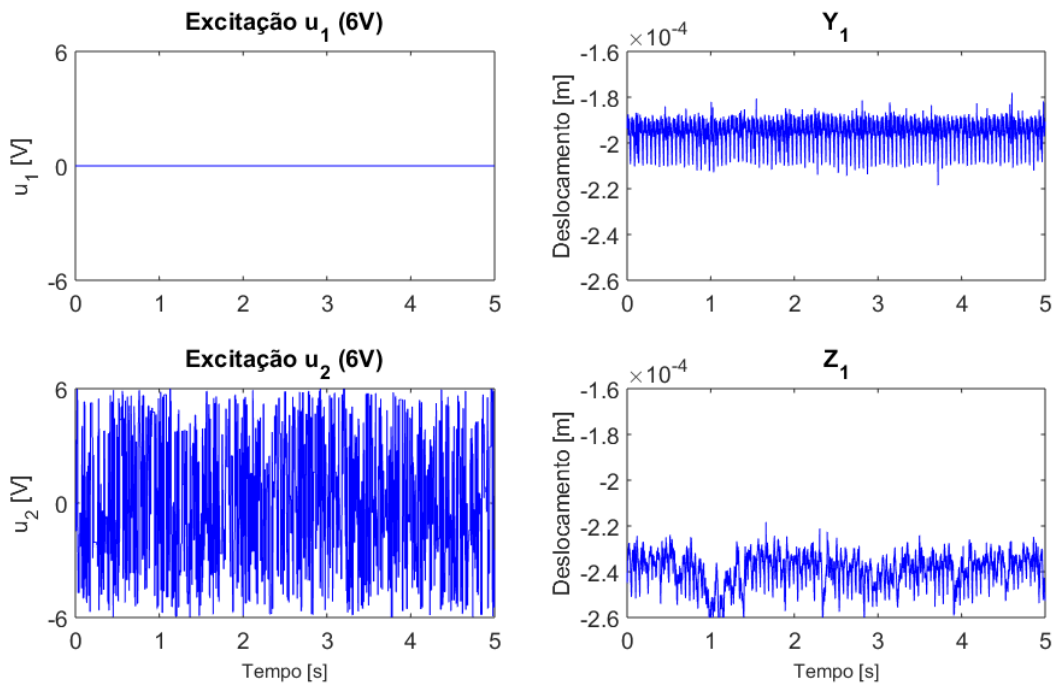


Figura B.12. Dados experimentais do sistema rotor-mancal híbrido para frequência de 20 Hz - Excitação na direção Z_1 (6V) e medição em ambas direções (Y_1 e Z_1).

APÊNDICE C – RESULTADOS DA IDENTIFICAÇÃO DO SISTEMA DINÂMICO PARA A ESTRATÉGIA 1: ENTRADAS, 2V, 3V, 4V, 5V E 6V

Tabela C.1 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (Tensão de entrada 2V).

Algoritmo treinamento	K	$MSE_{treinamento}$	MSE_{teste}
Levenberg-Marquardt	10	9,2995e-3	6,4617e-1
Regularização Bayesiana	10	9,5258e-3	5,9491e-1
Gradiente Conjugado Escalonado	10	1,2215e-2	5,2967e-1
Levenberg-Marquardt	15	9,0585e-3	5,6241e-1
Regularização Bayesiana	15	9,4490e-3	3,5763e-1
Gradiente Conjugado Escalonado	15	1,1453e-2	6,6879e-1
Levenberg-Marquardt	20	9,1579e-3	5,1040e-1
Regularização Bayesiana	20	8,9520e-3	6,0443e-1
Gradiente Conjugado Escalonado	20	1,1482e-2	5,9452e-1

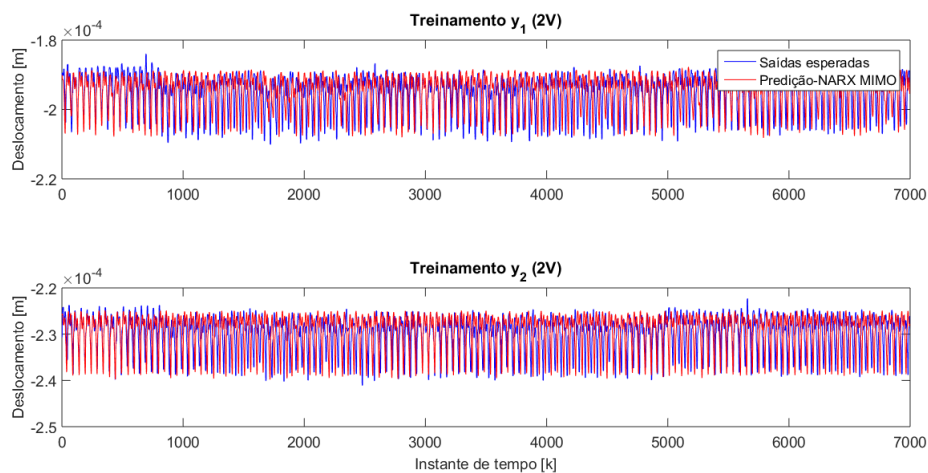


Figura C.1. Melhor treinamento: Regularização Bayesiana com 15 neurônios (2V).




Figura C.2. Melhor teste: Regularização Bayesiana com 15 neurônios (2V).

Tabela C.2 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (Tensão de entrada 3V).

Algoritmo treinamento	K	$MSE_{treinamento}$	MSE_{teste}
Levenberg-Marquardt	10	9,5072e-3	5,1882e-1
Regularização Bayesiana	10	9,1756e-3	5,5710e-1
Gradiente Conjugado Escalonado	10	1,1279e-2	4,4699e-1
Levenberg-Marquardt	15	8,5035e-3	5,7788e-1
Regularização Bayesiana	15	8,4213e-3	5,9240e-1
Gradiente Conjugado Escalonado	15	1,2155e-2	4,6060e-1
Levenberg-Marquardt	20	8,4942e-3	5,9921e-1
Regularização Bayesiana	20	8,1103e-3	5,8045e-1
Gradiente Conjugado Escalonado	20	1,2062e-2	5,2398e-1

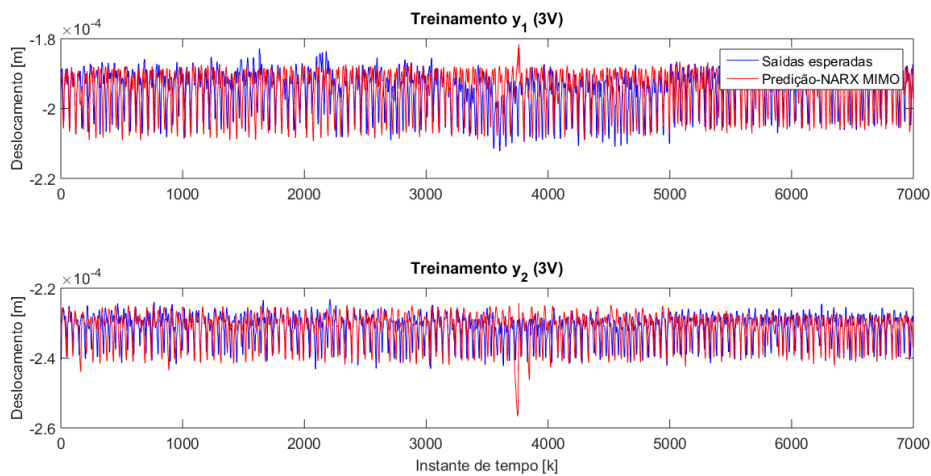


Figura C.3. Melhor treinamento: Regularização Bayesiana com 20 neurônios (3V).




Figura C.4. Melhor teste: Regularização Bayesiana com 20 neurônios (3V).

Tabela C.3 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (Tensão de entrada 4V).

Algoritmo treinamento	K	$MSE_{treinamento}$	MSE_{teste}
Levenberg-Marquardt	10	5,9044e-3	3,3732e-1
Regularização Bayesiana	10	6,0151e-3	3,7814e-1
Gradiente Conjugado Escalonado	10	7,4911e-3	2,4239e-1
Levenberg-Marquardt	15	6,1147e-3	4,1000e-1
Regularização Bayesiana	15	5,9244e-3	3,7375e-1
Gradiente Conjugado Escalonado	15	7,6193e-3	3,8780e-1
Levenberg-Marquardt	20	5,6404e-3	4,3959e-1
Regularização Bayesiana	20	5,9508e-3	4,1331e-1
Gradiente Conjugado Escalonado	20	7,3672e-3	2,7536e-1




Figura C.5. Melhor treinamento: Levenberg-Marquardt com 10 neurônios (4V).

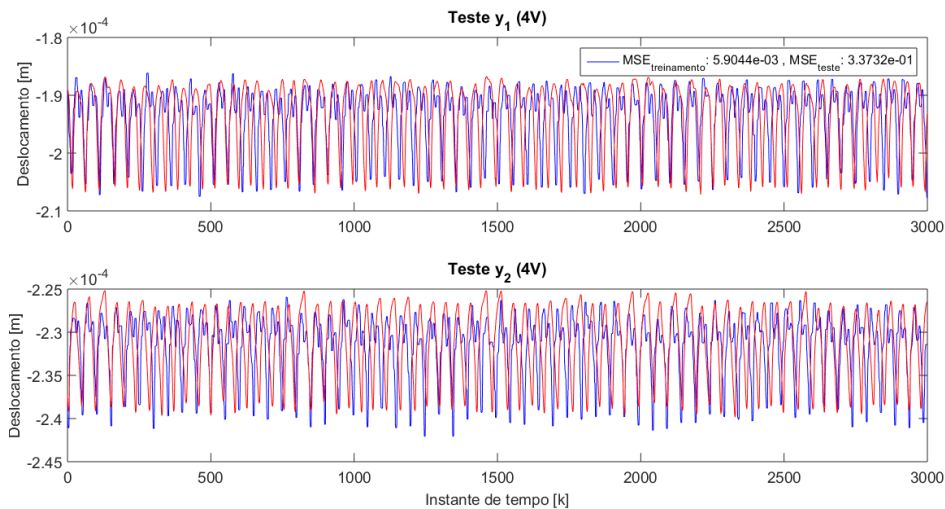


Figura C.6. Melhor teste: Levenberg-Marquardt com 10 neurônios (4V).

Tabela C.4 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (Tensão de entrada 5V).

Algoritmo treinamento	K	$MSE_{treinamento}$	MSE_{teste}
Levenberg-Marquardt	10	3,3690e-3	1,6016e-1
Regularização Bayesiana	10	3,2840e-3	1,4957e-1
Gradiente Conjugado Escalonado	10	4,3352e-3	8,1243e-1
Levenberg-Marquardt	15	3,3488e-3	4,4255e-1
Regularização Bayesiana	15	3,2691e-3	1,4878e-1
Gradiente Conjugado Escalonado	15	3,9230e-3	9,5305e-2
Levenberg-Marquardt	20	3,2555e-3	1,4339e-1
Regularização Bayesiana	20	3,3269e-3	1,1835e-1
Gradiente Conjugado Escalonado	20	4,1705e-3	8,1480e-2




Figura C.7. Melhor treinamento: Regularização Bayesiana com 20 neurônios (5V).

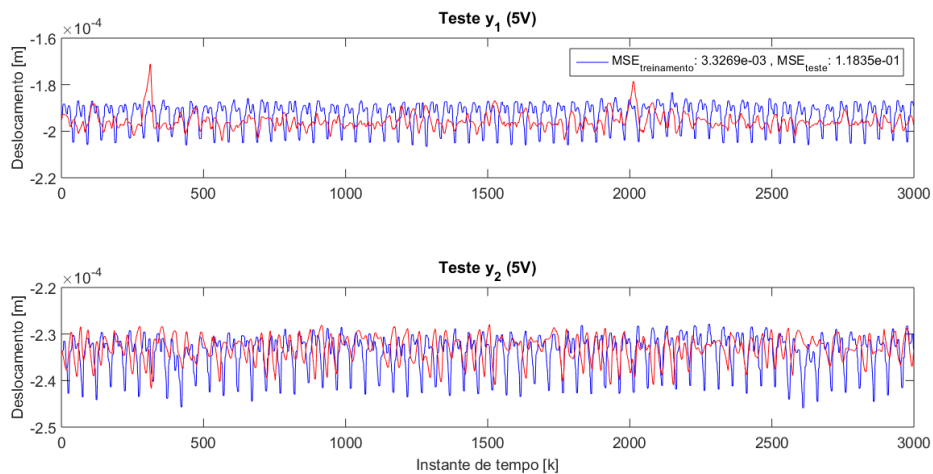


Figura C.8. Melhor teste: Regularização Bayesiana com 20 neurônios (5V).

Tabela C.5 – Resultados da fase de treinamento e teste em função do MSE para os três algoritmos de treinamento propostos (Tensão de entrada 6V).

Algoritmo treinamento	K	$MSE_{treinamento}$	MSE_{teste}
Levenberg-Marquardt	10	2,5949e-3	7,5384e-2
Regularização Bayesiana	10	2,6150e-3	7,7833e-2
Gradiente Conjugado Escalonado	10	3,1610e-3	5,2767e-2
Levenberg-Marquardt	15	2,5897e-3	6,9758e-2
Regularização Bayesiana	15	2,5548e-3	5,9400e-2
Gradiente Conjugado Escalonado	15	3,4811e-3	5,7677e-2
Levenberg-Marquardt	20	2,5591e-3	5,8472e-2
Regularização Bayesiana	20	2,5926e-3	4,9827e-2
Gradiente Conjugado Escalonado	20	5,0128e-3	6,7012e-2

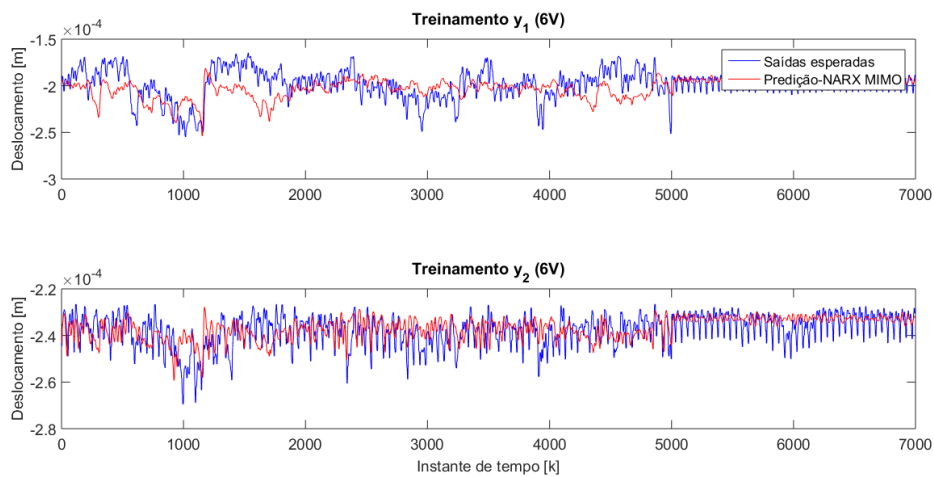


Figura C.9. Melhor treinamento: Regularização Bayesiana com 20 neurônios (6V).

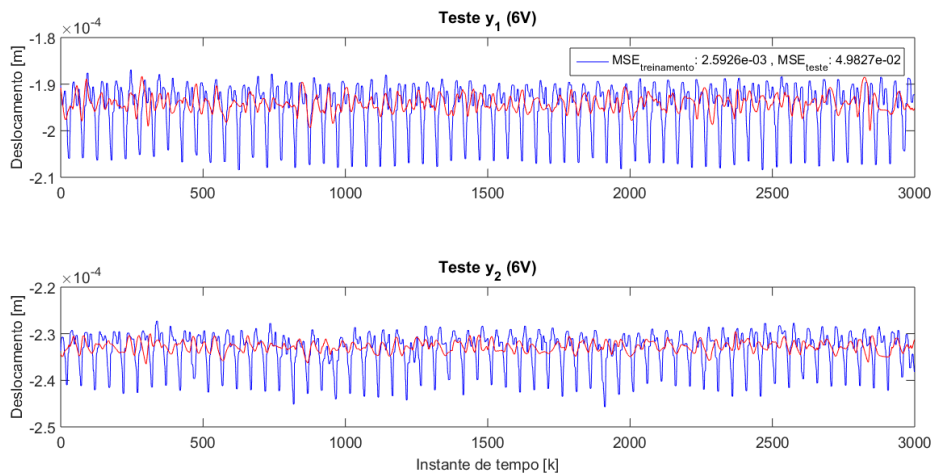


Figura C.10. Melhor teste: Regularização Bayesiana com 20 neurônios (6V).