

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

MODELAGEM E CONTROLE DE UM SERVOPOSICIONADOR PNEUMÁTICO VIA
REDES NEURAIAS

por

Vitor Irigon Gervini

Tese para obtenção do Título de
Doutor em Engenharia

Porto Alegre, dezembro de 2014

MODELAGEM E CONTROLE DE UM SERVOPOSICIONADOR PNEUMÁTICO VIA
REDES NEURAIAS

por

Vitor Irigon Gervini
Mestre em Engenharia

Tese submetida ao Programa de Pós-Graduação em Engenharia Mecânica, da Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como parte dos requisitos necessários para a obtenção do Título de

Doutor em Engenharia

Área de Concentração: Processos de Fabricação

Orientador: Prof. Dr. Eduardo André Perondi

Aprovada por:

Prof. Dr. Rafael Antônio Comparsi Laranja - UFRGS

Prof. Dr. Victor Juliano De Negri - UFSC

Prof. Dr. Antônio Carlos Valdiero - UNIJUI

Prof. Dr. Rogério José Marczak
Coordenador do PROMEC

Porto Alegre, 3 de dezembro de 2014

Dedico este trabalho ao meu avô Dr. João Martins Gervini, que sempre me apoiou e incentivou na pesquisa acadêmica.

AGRADECIMENTOS

Agradeço aos meus pais Igor e Bebeth, pelo carinho, a minha esposa Vanessa por seu amor, apoio e por ter dado a luz a nossa querida filha Sofia, aos meus irmãos pelos incentivos, carinhos e amizade. Agradeço ao Prof. Sebastião por todos os ensinamentos e apoio que me foram dedicados ao longo de minha vida acadêmica, ao Prof. Perondi pela excelente orientação e paciência ao longo de todo o curso de doutorado, aos membros da banca pelas preciosas colaborações durante a qualificação e fase final de defesa do doutorado. Agradeço a todos os colegas do Laboratório de Mecânica e Controle da UFRGS, pelo coleguismo, em especial ao técnico Éder e colega Alexandre, por suas incontáveis ajudas em todas as fases de meu trabalho. Agradeço a todos os professores do Centro de Ciências Computacionais da FURG por me incentivarem e apoiarem nesta etapa de vida.

RESUMO

Visando apoiar o desenvolvimento de controladores para servoposicionadores pneumáticos, é apresentada no presente trabalho uma proposta de um procedimento baseado no uso de redes neurais para a determinação de modelos matemáticos precisos que possam ser aplicados tanto para a simulação do seu comportamento dinâmico quanto na estrutura de controladores que utilizam estratégias baseadas em modelos. No âmbito do trabalho, esse procedimento foi testado por meio de sua aplicação na identificação das forças de atrito e da relação pressão/vazão mássica nos orifícios de controle da servoválvula (que consistem nas principais não-linearidades envolvidas em tais sistemas). Além disso, determinou-se através de redes neurais a relação inversa entre as vazões desejadas e o sinal de controle da servoválvula (difeomorfismo), a qual é aplicada em técnicas de controle baseadas em modelos. Visando validar o procedimento de modelagem proposto, foram realizadas simulações em malha aberta e malha fechada, cujos resultados são comparados com os de experimentos realizados em uma bancada de testes. Com o intuito de comprovar sua eficácia em aplicações de controle, o modelo baseado em redes neurais foi utilizado no desenvolvimento de um controlador não-linear sintetizado de acordo com uma estratégia em cascata (a qual foi já testada em outros trabalhos, mostrando resultados satisfatórios quando aplicada ao controle de servoposicionadores pneumáticos). No entanto, essa estratégia apresenta dificuldades de implantação em decorrência das dificuldades associadas ao processo de identificação dos parâmetros do sistema, que são especialmente trabalhosos neste caso. As características de estabilidade em malha fechada foram analisadas por meio do segundo método Lyapunov. Os resultados experimentais em malha fechada obtidos atestam a eficácia da estratégia de controle proposta.

Palavras-chave: Sistemas pneumáticos, modelagem, controle cascata; redes neurais.

ABSTRACT

The development of a precise positioning system has motivated several researches in the pneumatic systems control area to overcome the problems caused by these nonlinearities, by appropriate feedback control algorithms. In this work it is proposed a methodology based on neural networks to achieve accurate mathematical models that can be used in simulation as in controllers techniques based on models. This methodology was tested through its application in identifying the phenomenon of friction and the relationship pressure/mass flow through servo valve orifices control holes. Furthermore, using neural networks, the inverse relationship between the desired flow rates and control signal of servo valve (diffeomorphism), which is applied in various control techniques based on models, was determined. To evaluate the proposed modeling methodology, simulations were done in open and closed loop, and the results were compared with experiments conducted on a real pneumatic servo positioning system. A neural network based model was used to develop a nonlinear controller according to a cascade strategy with friction compensation (which has been tested on other studies showing satisfactory results when applied to pneumatic servo positioning control). The cascade control strategy, despite showing a good performance in trajectory tracking, presents significant difficulties in implementation due mainly to difficulties associated with the system parameters identification process, which are especially expensive. The characteristics of the closed loop stability were analyzed by Lyapunov method. The experimental results obtained in closed loop attest the efficiency of the proposed control strategy.

Keywords: Pneumatic, servo positioning systems, modeling, cascade control; neural networks.

ÍNDICE

1	INTRODUÇÃO.....	1
1.1	Estado da Arte	2
1.2	Objetivos do Trabalho.....	12
1.3	Organização do Trabalho	13
2	MODELAGEM DO SISTEMA DINÂMICO	14
2.1	Bancada Experimental para o Servoposicionador Pneumático.....	14
2.2	Modelagem do Servoposicionador Pneumático.....	16
2.3	Dinâmica das Pressões nas Câmaras do Cilindro Atuador	17
2.4	Equilíbrio das Forças no Pistão.....	19
2.5	Modelo Não-Linear de Quarta Ordem	20
2.6	Redes Neurais Artificiais	21
2.7	Identificação da Força de Atrito.....	28
2.8	Identificação das Vazões Mássicas	31
2.9	Validação do modelo obtido	34
2.10	Procedimento para o levantamento do Modelo Pneumático Neural	38
3	SISTEMA DE CONTROLE.....	40
3.1	Seguimento no Subsistema Mecânico.....	41
3.2	Seguimento no Subsistema Pneumático.....	43
3.3	Análise de Estabilidade	44
3.4	Análise de Estabilidade - Caso Ideal.....	46
3.5	Análise de Estabilidade - Caso com Erros Paramétricos e na Estimativa das Perturbações	48
4	RESULTADOS DE SIMULAÇÕES E EXPERIMENTOS.....	52
4.1	Trajetórias de Referência	52
4.2	Comparação entre o modelo pneumático neural e experimento em bancada com ambos em Malha Fechada	53

4.3	Comparação entre experimento em bancada em malha fechada e modelo pneumático neural em malha aberta para referência senoidal.....	57
4.4	Resultados experimentais do controlador PVΔP	60
4.5	Resultados do controlador Cascata Neural com compensação de atrito	64
4.6	Resultados do controlador Cascata Neural sem compensação de Atrito	71
4.7	Resultados do controlador Cascata Neural com compensação de Atrito e adição de massa.....	75
4.8	Resultados do controlador Cascata Neural com compensação de atrito com adição de massa com aumento nos ganhos	78
5	CONCLUSÕES.....	82
	REFERÊNCIAS BIBLIOGRÁFICAS	84
	APÊNDICE I – Parâmetros Físicos do Sistema Servopneumático, Sensores e Atuadores	93
I.1	Parâmetros Físicos.....	93
I.2	Sensores.....	93
I.3	Atuadores	94
I.4	Sistema de Aquisição de Dados e Controle – DSPACE	95
	APÊNDICE II – Caracterização Teórica das Vazões Mássicas na Servoválvula.....	96
	APÊNDICE III – Identificação Neural da derivada da Força de Atrito e da Dinâmica Inversa da Servoválvula (Difeomorfismo).....	103
III.1	Identificação da derivada da Força de Atrito	103
III.2	Identificação da dinâmica inversa da servoválvula.....	104
III.2	Comandos em MatLab para o cálculo da saída de algumas RN	106
	APÊNDICE IV – Resultados com controlador Cascata Neural com compensação de Atrito com utilizando setup do Robô Pneumático.....	108

LISTA DE FIGURAS

Figura 1.1 – Robô Pneumático disponível no LAMECC/UFRGS	3
Figura 1.2 – Atuador pneumático utilizado em [Van Varseveld e Bone, 1997] com baixo atrito	5
Figura 2.1 – Desenho esquemático da bancada experimental e sistema elétrico	15
Figura 2.2 – Fotografia da bancada de testes do atuador pneumático montada no Laboratório de Mecatrônica e Controle da UFRGS (LAMECC).....	16
Figura 2.3 – Volume de controle com domínio variável.....	18
Figura 2.4 – Equilíbrio de forças no êmbolo do cilindro atuador [Perondi, 2002]	20
Figura 2.5 – Estrutura básica de um neurônio	22
Figura 2.6 – Exemplos de funções de ativação utilizadas nos neurônios.....	23
Figura 2.7 – Agrupamento de arquiteturas de redes <i>feed-forward</i> e recorrentes [Jain et. al, 1996].....	23
Figura 2.8 – Topologia típica de uma rede neural MLP <i>feed-forward</i> com três camadas e totalmente conectada	25
Figura 2.9 – Arquitetura da Rede Neural Artificial (RNA) usada para a realização da estimação da força de atrito.....	29
Figura 2.10 – Arquitetura dos neurônios da <i>camada oculta</i> e de <i>saída</i> utilizados para a modelagem do atrito	29
Figura 2.11 – Padrões de treinamento da RN para estimação do atrito.....	30
Figura 2.12 – Força de atrito experimental (preto) e estimada pela rede neural (azul) para $K_p = 8$ e referência senoidal com frequência de 2 rad/s e amplitude de 0,45 m.....	31
Figura 2.13 – Arquitetura da RNA para estimação das vazões mássicas.....	32
Figura 2.14 – Sinais utilizados para o treinamento da RN para estimação das vazões mássicas	33
Figura 2.15 – Vazão mássica experimental da câmara 1 (preto) e estimada pela rede neural (azul).....	34
Figura 2.16 – Vazão mássica experimental da câmara 2 (preto) e estimada pela rede neural (azul).....	34
Figura 2.17 – Velocidade do êmbolo experimental (preto) e modelo (azul).....	36
Figura 2.18 – Trajetórias de atrito idealizadas para representar o fenômeno <i>stick-slip</i>	36
Figura 2.19 – Pressão na câmara 1 experimental (preto) e modelo (azul)	37

Figura 2.20 – Pressão na câmara 2 experimental (preto) e modelo (azul)	37
Figura 3.1 – Interpretação do servoposicionador como dois subsistemas interconectados.....	40
Figura 3.2 – Diagrama em blocos da estratégia de controle em cascata neural proposta.	40
Figura 4.1 – Posição do êmbolo do cilindro atuador e seu respectivo erro em simulação para sinal de controle proporcional (MF) e referência senoidal.....	54
Figura 4.2 – Posição do êmbolo do cilindro atuador e seu respectivo erro experimental para sinal de controle proporcional (MF) e referência senoidal.....	55
Figura 4.3 – Velocidade do êmbolo e sinal de controle em simulação (MF) para referência senoidal.....	55
Figura 4.4 – Velocidade do êmbolo e sinal de controle experimental (MF) para referência senoidal.....	56
Figura 4.5 – Pressões nas câmaras $p1$ e $p2$ em simulação (MF) para referência senoidal	56
Figura 4.6 – Pressões nas câmaras $p1$ e $p2$ experimental (MF) para referência senoidal	56
Figura 4.7 – Sinal de controle calculado em experimento de bancada e aplicado em MF no mesmo experimento, o qual foi salvo em arquivo digital e aplicado como controle em MA na simulação.....	57
Figura 4.8 – Comparação de resultados experimental (MF) e em simulação (MA) para a posição do êmbolo	58
Figura 4.9 – Comparação de resultados experimental (MF) e em simulação (MA) para a velocidade do êmbolo	58
Figura 4.10 – Comparação de resultados experimental (MF) e em simulação do modelo pneumático neural (MA) para a pressão na câmara $p1$	59
Figura 4.11 – Comparação de resultados experimental (MF) e em simulação do modelo pneumático neural (MA) para a pressão na câmara $p2$	59
Figura 4.12 – Comparação entre posições do êmbolo experimental (controle $PV\Delta P$ com trajetória senoidal) e em simulação em malha aberta do modelo, bem como seus respectivos erros	61
Figura 4.13 – Velocidades e sinal de controle experimental $PV\Delta P$ e em simulação em malha aberta para trajetória de referência senoidal	62
Figura 4.14 – Pressões nas câmaras do atuador experimental $PV\Delta P$ e em simulação em malha aberta para trajetória de referência senoidal	62

Figura 4.15 – Comparação entre posições do êmbolo experimental (controle $PV\Delta P$ com trajetória polinomial) e em simulação em malha aberta do modelo, bem como seus respectivos erros	63
Figura 4.16 – Velocidades e sinal de controle experimental $PV\Delta P$ e em simulação em malha aberta para trajetória de referência polinomial	63
Figura 4.17 – Pressões nas câmaras do atuador experimental $PV\Delta P$ e em simulação em malha aberta para trajetória de referência polinomial	64
Figura 4.18 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência senoidal	65
Figura 4.19 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência senoidal	66
Figura 4.20 – Pressões nas câmaras p_1 e p_2 experimental e sinal de erro s para o controlador cascata neural com trajetória de referência senoidal	66
Figura 4.21 – Força desejada calculada pela lei de Slotine e Li em relação à força aplicada e respectivo erro em força experimental para o controlador cascata neural com trajetória de referência senoidal	67
Figura 4.22 – Variáveis \hat{h}_n , \hat{u}_n e \hat{f}_a utilizadas no controlador cascata neural com trajetória de referência senoidal	67
Figura 4.23 – Posição do êmbolo e seu respectivo erro <i>experimental</i> para o controlador cascata neural com trajetória de referência polinomial	68
Figura 4.24 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência polinomial	69
Figura 4.25 – Pressões nas câmaras p_1 e p_2 experimental e sinal de erro s para o controlador cascata neural com trajetória de referência polinomial	69
Figura 4.26 – Força desejada calculada pela lei de Slotine e Li em relação à força aplicada e respectivo erro em força experimental para o controlador cascata neural com trajetória de referência polinomial	70
Figura 4.27 – Variáveis \hat{h}_n , \hat{u}_n e \hat{f}_a utilizadas no controlador cascata neural com trajetória de referência polinomial	70
Figura 4.28 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência senoidal sem compensação de atrito	71

Figura 4.29 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência senoidal sem compensação de atrito.....	72
Figura 4.30 – Força desejada calculada pela lei de Slotine e Li em relação à força aplicada e respectivo erro em força experimental para o controlador cascata neural com trajetória de referência senoidal sem compensação de atrito.....	73
Figura 4.31 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência polinomial sem compensação explícita de atrito.....	73
Figura 4.32 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência polinomial sem compensação de atrito.....	74
Figura 4.33 – Força desejada calculada pela lei de Slotine e Li em relação à força aplicada e respectivo erro em força experimental para o controlador cascata neural com trajetória de referência senoidal sem compensação de atrito.....	74
Figura 4.34 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência senoidal e adição de massa	76
Figura 4.35 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência senoidal e adição de massa	76
Figura 4.36 – Forças e respectivo erro para o controlador cascata neural com trajetória de referência senoidal e adição de massa	76
Figura 4.37 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência polinomial e adição de massa	77
Figura 4.38 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência polinomial e adição de massa	78
Figura 4.39 – Forças e respectivo erro para o controlador cascata neural com trajetória de referência polinomial e adição de massa	78
Figura 4.40 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência senoidal e adição de massa com ganhos modificados	79
Figura 4.41 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência senoidal e adição de massa com ganhos modificados	80

Figura 4.42 – Forças e respectivo erro para o controlador cascata neural com trajetória de referência senoidal e adição de massa com ganhos modificados	81
Figura III.1 – Arquitetura da Rede Neural Artificial (RNA) usada para a realização da estimação da derivada da força de atrito	103
Figura III.2 – Derivada da força de atrito experimental (preto) e estimada pela rede neural (azul) para $Kp = 8$ e referência senoidal com frequência de 2 rad/s e amplitude de 0,45 m.....	104
Figura III.3 – Arquitetura da RNA para estimação da tensão de controle	105
Figura III.4 – Tensão de controle experimental (preto) e estimada pela rede neural (azul)...	106
Figura IV.1 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência senoidal.	109
Figura IV.2 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência senoidal.	109
Figura IV.3 – Forças e respectivo erro para o controlador cascata neural com trajetória de referência senoidal.....	109

LISTA DE TABELAS

Tabela 2.1 – Exemplo de padrões de treinamento para a operação lógica XOR com duas entradas.....	26
Tabela 2.2 – Parâmetros dos experimentos selecionados para o treinamento da rede neural ..	31
Tabela 2.3 – Resultados das simulações usando o modelo proposto segundo critério IAE.....	36
Tabela 4.1 – Ganhos utilizados no controlador PV Δ P	60
Tabela 4.2 – Ganhos utilizados no controlador Cascata Neural.....	64
Tabela 4.3 – Ganhos modificados utilizados no controlador Cascata Neural	79
Tabela I.1 – Valores numéricos dos parâmetros do sistema físico.....	93
Tabela I.2 – Características técnicas dos sensores de pressão.....	93
Tabela I.3 – Características técnicas da régua potenciométrica.	94
Tabela I.4 – Características técnicas da servoválvula direcional.	94
Tabela I.5 – Características técnicas do atuador pneumático linear.....	94
Tabela I.6 – Características da placa de aquisição e processamento de dados.....	95

LISTA DE SÍMBOLOS

A	área do êmbolo, m^2
b	termo de bias da rede neural
C_p	calor específico do ar a pressão constante, J/kg K
C_v	calor específico do ar a volume constante, J/kg K
c_d	velocidade do som a jusante, m/s
e	erro
e_i	iésima entrada da rede neural
f_a	força de atrito, N
\hat{f}_a	estimativa da força de atrito, N
\tilde{f}_a	erro da estimativa do atrito, N
f_e	força externa aplicada, N
\hat{f}_e	estimativa da força externa aplicada, N
\tilde{f}_e	erro da estimativa da força externa, N
F_a	vetor composição da força de atrito
F_e	vetor composição da força externa aplicada sobre a massa
g_d	força desejada, N
h_n	parcela dinâmica do sistema que independe da tensão de controle
\hat{h}_n	estimativa da parcela dinâmica do sistema h_n
\tilde{h}_n	erro da estimativa da parcela dinâmica do sistema h_n
K_D	constante positiva do controlador para s
K_P	constante positiva do controlador para pressão
L	comprimento útil do cilindro atuador, m
m	massa de ar contida no volume de controle, kg
M	massa deslocada, kg
N_1	matriz da função Lyapunov
N_2	matriz da derivada da função Lyapunov
p_i	pressão absoluta na câmara i , Pa
p_d	pressão a jusante, Pa
p_u	pressão a montante, Pa

p_{Δ}	diferença das pressões, Pa
$p_{\Delta d}$	diferença de pressão desejada, Pa
\tilde{p}_{Δ}	erro no seguimento da diferença de pressão, Pa
P_{sup}	pressão de suprimento, Pa
P_{atm}	pressão atmosférica, Pa
q_{mi}	vazão mássica que entra ou sai da câmara i , kg/s
\hat{q}_{mi}	estimativa neural da vazão mássica que entra ou sai da câmara i , kg/s
Q	energia calorífica, J
\dot{Q}	potência calorífica, J/s
r	relação entre os calores específicos
R	constante do gás, kg J/K
s	combinação linear dos erros de seguimento de posição e de velocidade
t	tempo, s
T	temperatura do ar de suprimento, K
T_u	temperatura do ar a montante, K
T_d	temperatura do ar a jusante, K
u	tensão aplicada à servoválvula, V
u_n	sinal de controle auxiliar
\hat{u}	Estimativa neural da tensão aplicada à servoválvula, V
v_d	velocidade do ar a jusante, m/s
v_u	velocidade do ar a montante, m/s
V	função Lyapunov
V_i	volume na câmara i , m ³
V_{i0}	<i>volume morto</i> na câmara i , m ³
\dot{V}_i	vazão volumétrica na câmara i , m ³ /s
w_i	iésimo peso da rede neural
x	deslocamento do carretel da servoválvula, m
y	deslocamento do êmbolo, m
\dot{y}	velocidade do êmbolo, m/s
\ddot{y}	aceleração do êmbolo, m/s ²

y_d	posição desejada, m
y_r	posição de referência, m
\dot{y}_r	velocidade de referência, m/s
\ddot{y}_r	aceleração de referência, m/s ²
ρ	massa específica do ar, kg/m ³
ρ_d	massa específica do ar a jusante, kg/m ³
ρ_u	massa específica do ar a montante, kg/m ³
$\boldsymbol{\rho}$	vetor de erros da função Lyapunov
λ	constante positiva do controlador
$\underline{\lambda}_i$	iésimo autovalor mínimo
$\overline{\lambda}_i$	iésimo autovalor máximo
γ	relação entre autovalores máximos e mínimos
η	fator de aprendizado da rede neural

1 INTRODUÇÃO

Os servoposicionadores pneumáticos são relativamente baratos, leves e de fácil instalação, apresentando também uma relação de força de saída por unidade de peso que os tornam muito atraentes em aplicações na indústria. Por outro lado, os servoposicionadores pneumáticos possuem características altamente não-lineares e uma grande dificuldade em se obter modelos matemáticos precisos, o que dificulta que se consiga um desempenho adequado no controle do seguimento de trajetórias.

Os atuadores pneumáticos estão sendo cada vez mais utilizados e têm se tornando uma alternativa na automação industrial devido às suas características específicas. Para algumas aplicações, existem vantagens na utilização de atuadores pneumáticos em relação aos atuadores hidráulicos e elétricos. Atuadores pneumáticos utilizam o ar na transmissão de movimento, sendo este de fácil disponibilidade. Os atuadores pneumáticos possuem uma boa relação peso/potência [Messina et al., 2005; Rajendran e Nanda, 2009; Schindele e Aschemann, 2009; Chikh et al, 2010; Ren e Huang, 2013b], além de apresentarem uma capacidade de fornecer maior força e por um período mais longo do tempo do que os aos atuadores elétricos [Schindele e Aschemann, 2009]. Sistemas pneumáticos são fáceis de serem projetados e são muito flexíveis quanto às suas aplicações [Shaojuan et al., 2008; Ramirez, 2013], propiciando condições de operações limpas [Messina et al., 2005; Niiyama, 2012; Chen e Shih, 2013]. Além disso, ao contrário dos sistemas elétricos, os sistemas pneumáticos não emitem faíscas, fazendo com que sejam seguros e facilmente adaptáveis para utilização em ambientes classificados.

Por outro lado, atuadores pneumáticos têm aplicação restrita em problemas onde alta precisão é requisitada. As dificuldades estão associadas a características tais como: difícil identificação dos parâmetros do sistema dinâmico, efeitos da compressibilidade do ar, presença de atrito com comportamento altamente não-linear entre as superfícies de contato nas vedações do cilindro, tanto no êmbolo quanto na haste; fortes não-linearidades associadas à relação entre a vazão de ar através do orifício da servoválvula e as pressões nas câmaras do cilindro. Esses fatores dificultam a obtenção de um modelo dinâmico preditivo e desempenho adequado do sistema de controle. Assim, para a implantação de controladores de sistemas pneumáticos baseados em modelos matemáticos, é necessário que vários parâmetros sejam

levantados e identificados para que seja possível a aplicação destes sistemas de controle nos sistemas reais.

Na presente tese é realizada uma pesquisa sobre servoatuadores pneumáticos, englobando aspectos tanto de modelagem dinâmica quanto de controle. É feito um desenvolvimento teórico dos dois principais módulos que compõem a tese: modelagem dinâmica e controle de servoatuadores pneumáticos. Este desenvolvimento teórico foi validado a partir de resultados experimentais, obtidos em uma bancada experimental que se encontra fisicamente no LAMECC (Laboratório de Mecatrônica e Controle) da UFRGS.

1.1 Estado da Arte

A demanda pela automação industrial iniciou-se entre a década de 1950 e 1960 [Broadbent, 1950; Tappan et al., 1960], bem como a pesquisa sobre atuadores pneumáticos. Um dos primeiros estudos publicados sobre modelagem de atuadores pneumáticos é o de Shearer, 1956, no qual é apresentado um modelo dinâmico não-linear, o modelo não-linear obtido é então linearizado, visando à aplicação em projeto de controladores baseados em técnicas lineares [Virvalo, 1995; Li et al., 2011]. De forma geral, os modelos matemáticos encontrados na bibliografia seguem as mesmas hipóteses e procedimentos gerais do equacionamento proposto por Shearer, 1956.

Na literatura são encontradas aplicações para servoposicionadores pneumáticos, algumas das quais são aqui descritas. Em Wang et al., 1999a, por exemplo, é apresentada uma estratégia de controle pneumático baseada em um controlador PID para um sistema de embalagem de alimentos. Experimentos para um cilindro pneumático de 30 cm de curso total são apresentados para o controle ponto a ponto. Os resultados apresentam um erro máximo de 1 mm na precisão do posicionamento do cilindro com uma massa de 1,7 kg. O controlador se mostrou robusto a variações no suprimento de pressão de até 2 bar. Em Choi et al., 2003, está descrito o desenvolvido de um robô híbrido acionado por atuadores pneumáticos e servomotores utilizado para aplicações de colocações de vidro, robô este que possui 4 graus de liberdade e uma resolução na posição máxima de 3 mm. O controlador utilizado foi o controle por modos deslizantes. O autor salienta que não se consegue uma alta precisão e que o intuito é utilizar o robô como suporte para trabalhadores humanos na montagem de painéis em construções. Além das aplicações industriais, atuadores pneumáticos têm sido utilizados

também como interface física humana. Por exemplo, em Faudzi et al., 2008, uma cadeira inteligente foi projetada, de modo a se ajustar de acordo com a curvatura lombar de um ser humano, com o intuito de minimizar o desconforto e a fadiga. Resultados experimentais no seguimento de força e de trajetória são apresentados graficamente, sem detalhar o desempenho do sistema de controle proposto. Em Sang-Eun et al., 2010, atuadores pneumáticos foram utilizados em aplicações na área médica de Ressonância Magnética por Imagem (MRI) para a biópsia da próstata. Foram, no entanto, apresentados problemas devido ao limitado espaço de trabalho. Atualmente, encontra-se em desenvolvimento no Laboratório de Mecânica e Controle (LAMECC) da Universidade Federal do Rio Grande do Sul (UFRGS) um robô pneumático com cinco graus de liberdade, conforme apresentado na Figura 1.1 [Rijo, 2013].



Figura 1.1 – Robô Pneumático disponível no LAMECC/UFRGS

O desenvolvimento de um posicionador rápido e preciso tem motivado diversos trabalhos na área de controle de atuadores pneumáticos, buscando superar os problemas ocasionados pelas não-linearidades através do uso de algoritmos de controle adequados. O estudo do controle no seguimento de trajetória em sistemas pneumáticos vem tendo um

significativo crescimento desde 1990. Muitas abordagens vêm sendo investigadas na tentativa de superar as dificuldades do controle de sistemas pneumáticos. As investigações das estratégias de sistemas de controle vão desde técnicas de controle PID [Varseveld e Bone, 1997; Fok e Ong, 1999; Wang, et al., 1999a; Lee et al., 2002; Rahmat et al., 2012; Aliff et al., 2013] até técnicas avançadas de controle, como o controle por modos deslizantes [Song e Ishida, 1997b; Richer e Hurmuzlu, 2000; Tsai e Huang, 2008; Meng et al., 2014; Hodgson et al., 2015], controle adaptativo [Smaoui et al., 2006; Schindele e Aschemann, 2009; Ren e Huang, 2013a; Na et al., 2014] e as combinações de diversas técnicas de controle [Chiang et al., 2005; Shu e Bone, 2005; Zhu et al., 2009; Han e Lee, 2013]. Esses algoritmos, muitas vezes, necessitam de modelos para a sua síntese, enquanto outros utilizam estratégias que não necessitam de sinais nominais calculados a partir do modelo dinâmico do servoposicionador [Surgenor et al., 1995; Perondi e Guenther, 2000]. Neste caso, o modelo é útil para a realização de simulação, através das quais os ganhos e parâmetros do controlador são ajustados a partir da avaliação dos resultados obtidos.

A combinação de um controlador convencional com a compensação de atrito foi investigada por diversos pesquisadores. Em 1997, uma combinação de um controlador PID com uma estratégia de compensação de atrito foi implementado utilizando válvulas solenóides tipo *on/off* visando ao posicionamento preciso [Van Varseveld e Bone, 1997]. O método de compensação de atrito foi baseado no modelo de atrito simplificado de Coulomb e os resultados mostram que o controlador apresenta comportamento robusto quanto à variação da massa da carga. Os resultados experimentais apresentam erro de no máximo 0,21 mm para deslocamento ponto a ponto e de 2 mm no seguimento de trajetórias com baixas velocidades (50 mm/s). A carga de trabalho utilizada foi de 0,94 kg e o curso total do cilindro de 15,2 cm. O tipo de cilindro utilizado possui baixo atrito, segundo o autor, e é apresentado na Figura 1.2.

Um controle robusto por modos deslizantes foi proposto em Song e Ishida, 1997b. O projeto do controlador é derivado da teoria de *Lyapunov*, utilizando uma região de convergência para a dinâmica do erro quando o tempo $t \rightarrow \infty$. A estratégia de controle investigada apresenta rejeição a incertezas paramétricas na modelagem. Nos experimentos são utilizados valores de massa de carga de 30 a 100 kg. Erros de seguimento de trajetória inferiores a 0,1 cm são apresentados para curvas de referência de baixa amplitude (5 cm), para um cilindro pneumático com comprimento total de 30 cm.




Figura 1.2 – Atuador pneumático utilizado em [Van Varseveld e Bone, 1997] com baixo atrito

Em Wang e Moore, 1999b, é investigado um controlador *PID* de posição com a adição de uma realimentação de aceleração visando a melhorar as características de estabilidade do sistema de controle. Nesta estratégia de controle, são também utilizados esquemas de compensação de duas não-linearidades: atraso de tempo (*time-delay*), que ocorre devido à compressibilidade do ar e zona morta de controle, que é ocasionada pelo sobrepassamento (*overlapping*) do carretel de controle da servoválvula. São apresentados resultados gráficos no seguimento de trajetórias de baixas velocidades para o controlador proposto sem o detalhamento de desempenho do sistema de controle proposto. Nesse artigo não são apresentados resultados de controle ponto a ponto e de seguimento de trajetória para a posição.

Em Saleem et al., 2009, é proposto um controlador *PID* de velocidade com compensação de atrito (no caso do controlador *PID* em velocidade, o retorno do ganho proporcional opera a velocidade, ficando a ação integral com o retorno de posição e a ação derivativa com o retorno de aceleração). Foi proposto um procedimento para a identificação *online* do atrito utilizando a diferença entre o comportamento do sistema experimental e o fornecido pelo modelo matemático. O artigo não apresenta detalhes para o resultado do erro de posicionamento da estratégia de controle proposta.

Os sistemas de servoposicionamento pneumático geralmente dispõem de sensores de posição a partir dos quais, através da derivação no tempo do sinal por eles fornecido, obtêm-se as curvas de velocidade. Um dos problemas do controle de velocidade está em se obter essas derivadas temporais. Para evitar essa dificuldade, que é associada à utilização da

velocidade na estratégia de controle, alguns autores preferem uma abordagem com utilização do sinal de força, como, por exemplo, [Ilchmann et al., 2006], que apresenta um controlador proporcional estável com realimentação do erro em força. Resultados experimentais do controlador em aplicações de seguimento de força apresentam erros de cerca de 4 N para trajetórias de referência constituídas por degraus de diferentes amplitudes, restritas entre ± 40 N. Outros autores, porém, se utilizam de observadores de estados para as estimativas dos sinais desejados [Salgado e Chairez, 2013] ou de fenômenos não-lineares tais como o atrito [Rahman e Sepehri, 2013].

A utilização de redes neurais artificiais (*RNA*) em robótica tem sido realizada, principalmente, como ferramenta de identificação de modelos estáticos e dinâmicos para a posterior compensação de não-linearidades, objetivando tornar a planta o mais linear possível, facilitando assim o bom desempenho da lei de controle. A *RNA* atua como um modelo matemático com que pode reproduzir características de algum sistema físico previamente selecionado, como, por exemplo, o atrito ou a função inversa da servoválvula. Algumas vantagens no uso de *RNA* são a facilidade e a rapidez na identificação de sistemas físicos em comparação com os métodos tradicionais de identificação (levantamentos de pontos e aproximações de curvas, método usualmente utilizado na identificação do modelo da inversa da servoválvula).

Em Lee et al., 2002, é apresentado um controle *PID* de posição com compensação de atrito via rede neural e um observador não-linear para a força de atrito baseado no modelo simplificado de Coulomb descrito através da equação, $f_a(a, \dot{y}) = a \text{sign}(\dot{y})$, onde \dot{y} é a velocidade do êmbolo e a é um parâmetro a ser estimado utilizando um observador não-linear de ordem reduzida, tal que \hat{a} (estimativa do valor ideal a) é função de um estado observável z associado a uma dinâmica interna escolhida de modo que se possa provar a convergência assintótica do erro em posição para zero. O atuador utilizado é do tipo linear com curso total de 20 cm e uma massa na carga de 2,7 kg. A rede neural proposta possui duas entradas (velocidade e aceleração), uma camada escondida com três neurônios e uma saída para a estimativa do atrito. O treinamento da rede neural foi feito de forma *offline* utilizando-se padrões de treinamentos levantados previamente. O algoritmo de adaptação escolhido foi o método clássico de retropropagação do erro (*backpropagation*), onde o treinamento supervisionado das redes neurais é baseado no uso de padrões de treinamento de entrada e saída para uma dada rede neural que propaga os erros de suas saídas para os pesos mais

internos na rede [Fausett, 1994]. Os resultados experimentais são apresentados utilizando, respectivamente, amplitudes e frequências de 7 cm e 0,5 Hz para a referência de posição. Os resultados experimentais utilizando o *PID* com compensação neural apresentaram um erro de seguimento de trajetória máximo de 1,5 cm, enquanto com o observador de estados o erro máximo foi de 2,0 cm. Entretanto, o controle utilizando o uso do observador de estados mostrou-se mais fácil de ser ajustado.

Outra abordagem sobre a utilização de redes neurais para o controle de sistemas pneumáticos é relativa ao ajuste de ganhos de um controlador *PI* com realimentação de posição via redes neurais [Kothapalli e Hassan, 2008]. Os ganhos proporcional e integral do controlador são ajustados através do uso de uma rede neural que possui duas entradas: erro em posição e força externa aplicada à carga movimentada. Para treinamento é utilizada a técnica da retropropagação do erro com momento (*momentum*), via método do gradiente descendente. A função utilizada na camada escondida foi a tangente sigmoideal. Os autores apresentaram apenas resultados de simulação, os quais não são conclusivos quanto à robustez do controle proposto.

A maioria dos trabalhos sobre o equacionamento do atrito entre o êmbolo e a camisa do pistão utiliza o modelo conhecido como *LuGre* [Canudas de Wit et al., 1995], que, além de levar em conta as principais não-linearidades macroscópicas do atrito, têm-se mostrado bastante adequado para o uso em esquemas de observação e compensação do atrito [Lischinsky, 1999; Perondi, 2002; Guenther et al., 2006; Sobczyk et al., 2012; Feyel et al., 2013; Meng et al., 2014]. Para aplicações em controle, este modelo apresenta limitações associadas a dificuldades referentes à obtenção dos seus parâmetros. No presente trabalho, como será visto no Capítulo 2, redes neurais foram utilizadas para obtenção de estimativas da força de atrito a partir da diferença de pressão no êmbolo do cilindro atuador e da sua velocidade.

Em Carneiro e Almeida, 2011, é investigada a modelagem de servoposicionadores pneumáticos utilizando redes neurais. O modelo dinâmico global é formado por dois tipos de redes neurais: o primeiro é utilizado na identificação do modelo direto das servoválvulas proporcionais, enquanto o segundo tipo é aplicado na identificação do atrito. As redes neurais usadas para a identificação da dinâmica direta das servoválvulas possuem quatro camadas: uma de entrada com dois neurônios (tensão de comando e pressão a jusante); duas camadas escondidas (com dez neurônios na primeira e seis na segunda) e uma camada de saída com

um neurônio (estimativa neural da vazão mássica da servoválvula). A rede neural para a identificação do atrito possui também quatro camadas: uma de entrada com dois neurônios (velocidade e aceleração do êmbolo); duas camadas escondidas (com dez e seis neurônios) e outra de saída, com um neurônio (estimativa neural da força de atrito). Como função de ativação foi utilizada a tangente hiperbólica sigmoidal (*tansig*). O treinamento dos pesos para ambos os tipos de rede neural foi feito de forma *offline* sobre um padrão de treinamento previamente obtido a partir de resultados experimentais, utilizando o método de *Levenberg-Marquardt (LM)* para a minimização do erro. O método de *Levenberg-Marquardt* é uma variação do método de convergência de *Newton*, tratando-se de um algoritmo de otimização efetivo com uma convergência rápida e robusta [Marquardt, 1963; Hagan et al., 1996; Nergaard et al., 2000; Ham e Kostanic, 2001]. Resultados de simulação utilizando o modelo proposto são comparados com dados experimentais e atestam uma boa concordância da estratégia de modelagem proposta. Os resultados foram validados para excitação tipo pulso e por sinal de referência harmônico de amplitude 0,1 m com frequência de 1 Hz.

Em Carneiro e Almeida, 2012, é apresentado o projeto de um controlador neural para o seguimento de trajetória de um servoposicionador pneumático. Nesse trabalho, o controle de força com compensação de atrito via redes neurais é estudado. Duas redes neurais são utilizadas para realizar a identificação do modelo inverso das servoválvulas de controle. O modelo inverso, conceito também utilizado na estratégia de controle em cascata [Perondi, 2002], permite obter o valor necessário da tensão aplicada a servoválvula a partir do valor desejado da sua variável de saída. O cilindro pneumático estudado possui comprimento total de 40 cm, sendo as amplitudes utilizadas nos seguimentos das trajetórias senoidais abaixo de 16 cm (32 cm de curso total). A maior frequência das trajetórias seguida é de π rad/s e a massa da carga testada variou entre de 2,69 e 13,1 kg. Para a menor massa e frequência máxima da trajetória, o erro de pico ficou em torno de 7,5 mm. Em Carneiro e Almeida, 2013 é apresentado como melhorar o desempenho no controle de força em cilindros industriais utilizando duas servoválvulas pneumáticas. Carneiro e Almeida, 2014, apresentam o desempenho de seu controlador neural em um servoatuador pneumático portátil, onde todos os sensores, servoválvula, cilindro de atuação, tratamento de ar, estão dentro de uma maleta portátil também chamado de sistema *on-the-shelf*.

Em Al-Shabi et al., 2011, é apresentado um filtro preditor (*Smooth Variable Structure Filter - SVSF*) para a modelagem de sistemas pneumáticos baseado no conceito de modos

deslizantes. O filtro preditor é utilizado para que a estimação dos parâmetros e dos estados do modelo desloquem-se em direção à superfície de um hiperplano previamente definido. O desempenho do filtro preditor é comparado a partir de resultados de simulações com estimações realizadas por uma rede neural *feed-forward* de quatro camadas, com uma entrada, duas camadas escondidas e uma saída, utilizando o algoritmo de treinamento por retropropagação de *Levenberg-Marquardt*.

Hesselroth et al., 1994, utilizaram redes neurais para o controle de um manipulador de cinco graus de liberdade com músculos pneumáticos. Foram utilizadas duas câmeras digitais para medir as posições. A topologia escolhida para a rede neural é do tipo *Kohonen* tridimensional. Os mapas auto-organizáveis de *Kohonen* fazem parte de um grupo de redes neurais baseadas em modelos de competição, ou simplesmente redes competitivas [Fausett, 1994]. Nestes mapas não existe a necessidade do treinamento tradicional supervisionado, pois a própria rede busca encontrar similaridades baseando-se apenas nos padrões de entrada. O artigo mostra que com pouco mais de 200 passos de adaptação é possível se obter um erro máximo de 3 mm para o controle ponto a ponto.

Gross e Rattan, 1997, apresentaram um controle de velocidade de um cilindro pneumático. O controle apresentado é composto de uma realimentação do erro de velocidade e de uma rede neural multicamadas para a compensação das não-linearidades do sistema. Para o treinamento da rede neural foi utilizada a técnica de *backpropagation* com *momentum*. O trabalho apresenta resultados de simulação para o erro de velocidade em cilindros pneumáticos, mostrando que ocorre uma redução de 93,7% do erro no seguimento de velocidade quando é utilizada a compensação por redes neurais.

Song et al., 1997a, propuseram um controlador de posição para um cilindro pneumático utilizando redes neurais multicamadas. Como regra de treinamento, utilizou-se um algoritmo baseado no *Filtro de Kalman Estendido (EKF)*, que é uma versão não-linear do estimador quadrático linear conhecido como *Filtro de Kalman (KF)* [Kalman, 1960] e é considerado como um padrão na teoria de estimação de estados de sistemas não-lineares [Einicke e White, 1999]. A rede neural é responsável por todo o cálculo do controle, tendo sido necessário realizar um treinamento prévio da rede. Não são apresentados detalhes do erro do seguimento de trajetória, mas resultados visuais dos gráficos mostram erros inferiores a 1 mm em problema de deslocamento ponto a ponto para uma massa na carga de 10 kg.

Choi et al., 1998, utilizaram uma rede neural *feed-forward* com três camadas (uma camada de entrada, uma camada escondida e uma camada de saída) para controlar um servoposicionador pneumático linear com 20 cm de comprimento. Como técnica de aprendizagem foi utilizada a retropropagação do erro. Foi utilizado um algoritmo *PID* para o controle do sistema. Resultados experimentais são apresentados utilizando-se trajetórias senoidais de frequência de 0,5 Hz. A estratégia de controle proposta apresenta erros inferiores a 2,2 mm no seguimento de trajetória para curvas harmônicas com amplitudes de 7 cm.

Ahn et al., 2003, utilizaram um algoritmo de seleção de ganhos através de rede neural para controlar um sistema pneumático com carga variável. De acordo com a estratégia proposta, a rede neural escolhe um conjunto de ganhos apropriados para diferentes valores de carga. Resultados experimentais sem carga apresentaram erros inferiores a 0,5 mm no controle ponto a ponto.

Song e Liu, 2006, utilizaram uma rede neural *feed-forward* para obter um modelo completo de um sistema pneumático. A rede neural utilizada foi treinada utilizando o método de convergência de *Levenberg-Marquardt* [Song e Liu, 2006]. O modelo obtido é transformado em um modelo ARX (modelo auto-regressivo, ou seja que depende dos estados anteriores e possui entradas externas) de terceira ordem. A partir do modelo ARX foi projetado um controlador digital para o sistema. O artigo apresenta resultados experimentais com erro no seguimento de trajetórias harmônicas de, no máximo, 3,27 mm. O cilindro utilizado possui comprimento total de 10 cm, tendo sido utilizados na geração das harmônicas amplitudes de aproximadamente 4 cm, resultando em 8 cm de curso total. Trung et al., 2011, é feita a identificação de um atuador pneumático utilizando redes neurais, tendo como técnica de adaptação dos pesos também o método de convergência de *Levenberg-Marquardt*. Resultados experimentais atestam a estratégia de modelagem proposta.

Alguns trabalhos anteriormente desenvolvidos no LAMECC/UFRGS serviram de base inicial para o desenvolvimento deste trabalho, principalmente associados a Dissertações de Mestrado e Teses de Doutorado já desenvolvidas nesse tema [Perondi, 2002; Sobczyk, 2005; Kunz, 2006; Sobczyk, 2009; Suzuki, 2010; Sobczyk et al., 2012]. Além disso, serviram como base trabalhos anteriores na área de inteligência artificial como auxílio ao controle de sistemas mecânicos [Gervini et al., 2008; Gomes et al., 2006; Gervini et al., 2003; Gervini et al., 2001].

O projeto, análise, implantação experimental e teste de um controlador para seguimento de trajetórias precisas de servoposicionadores pneumáticos, constituem a

principal contribuição da presente tese de doutorado. Desta forma, o controlador deverá ser capaz de compensar as não-linearidades e variações paramétricas da dinâmica de servoatuadores pneumáticos, de forma a garantir estabilidade e precisão no problema de seguimento de trajetórias de referência.

Quando se objetiva utilizar um modelo matemático de um atuador em síntese de algoritmos de controle, é importante que o mesmo apresente relações que possam ser invertidas. Isto permite que muitos controladores, como os baseados na interpretação do sistema como subsistemas concatenados e os baseados em linearização por realimentação possam ser desenvolvidos usando esse modelo. No caso dos servoposicionadores pneumáticos, é importante que o modelo da servoválvula apresente essa característica, de modo que possa ser utilizado na compensação das não-linearidades em algoritmos de controle, como em Bobrow e McDonell, 1998 e Guenther e Perondi, 2002. Deste modo, o modelo dinâmico do servoposicionador proposto neste trabalho foi elaborado com a possibilidade de inversão da relação entre a vazão de ar e a tensão de controle, adotando também uma modelagem do atrito que permite sua compensação. Conforme mencionado, a utilização de redes neurais também tem auxiliado na obtenção da inversa das relações da dinâmica da servoválvula [Carneiro, 2011].

O presente trabalho, através da apresentação do desenvolvimento de um modelo dinâmico para um servoposicionador pneumático, aborda a proposição de um procedimento para a determinação de modelos baseada no uso de redes neurais para identificar as principais não-linearidades envolvidas na modelagem de tais sistemas. A identificação dos parâmetros associados a essas não-linearidades é geralmente difícil e trabalhosa de ser realizada a partir de métodos tradicionais. Os ensaios experimentais para a validação do modelo foram realizados utilizando-se a bancada experimental descrita no Capítulo 2.

A modelagem desenvolvida utiliza a estrutura matemática clássica para este tipo de sistema [Vieira, 1998; Perondi e Guenther, 1999; Perondi e Guenther, 2000; Guenther e Perondi, 2002; Weist et al., 2011], empregando, porém, redes neurais para as estimativas das vazões mássicas e das forças de atrito.

Nos modelos tradicionais, a vazão mássica é geralmente equacionada a partir de relações obtidas experimentalmente entre a área efetiva de abertura de passagem do fluido na servoválvula com a razão entre as pressões a montante e a jusante em relação ao orifício, resultando em curvas tridimensionais, tendo como entradas as relações de pressão e o sinal de

controle da válvula (ao qual a abertura dos orifícios é proporcional) e, como saída, a vazão mássica que atravessa os orifícios da servoválvula [Scavarda e Thomasset, 1996; McDonell, 1996; Maré, 2000; Perondi, 2002; Korondi e Gyeviki, 2006; Rapp et al., 2012].

No presente caso, as vazões mássicas da servoválvula são obtidas através do uso de uma rede neural que tem como entradas a tensão de controle e a diferença das pressões nas câmaras e como saída a estimativa das vazões mássicas. O treinamento da rede neural é feito de forma supervisionada a partir de dados de experimentos. No treinamento supervisionado, as entradas da rede neural, bem como as saídas desejadas são fornecidas (chamadas de padrões de treinamento), e então, utilizando-se a retropropagação do erro e com o método do gradiente descendente os pesos da rede são minimizados de forma a ‘aprender’ os padrões de treinamento.

1.2 *Objetivos do Trabalho*

O objetivo geral do presente trabalho consiste no desenvolvimento de um controlador do tipo cascata utilizando redes neurais para um servoatuador pneumático. De forma que o mesmo consiga seguir trajetórias de referência e possua robustez a variações na massa da carga.

Os objetivos específicos do presente trabalho são:

- i) a proposição de um procedimento para a obtenção de modelos matemáticos inversíveis de servoposicionadores pneumáticos de forma rápida e eficiente, utilizando redes neurais para identificação das não-linearidades e;
- ii) o desenvolvimento de uma lei de controle para seguimento preciso de trajetória baseada em uma estratégia em cascata com compensação de atrito via redes neurais;
- iii) implementação do controlador proposto em um sistema físico real disponível em uma bancada no *LAMECC*;
- iv) realização de testes a fim de verificar/validar o desempenho e robustez do sistema de controle proposto.

1.3 Organização do Trabalho

O trabalho está organizado da seguinte forma, no Capítulo 2 é apresentado a descrição e modelagem do sistema físico de um servoatuador pneumático. No Capítulo 3 um controlador tipo cascata com compensação de atritos é projetado, e sua análise de estabilidade é estudada. No Capítulo 4 resultados do modelo e experimentais do controlador proposto são comparados e analisados de forma a se verificar o desempenho no seguimento de trajetórias e robustez a variações da massa terminal. No Capítulo 5 são apresentadas as conclusões do presente trabalho.

2 MODELAGEM DO SISTEMA DINÂMICO

O modelo geralmente utilizado para descrever o comportamento dinâmico de um servoposicionador pneumático é constituído basicamente pelas relações entre as vazões mássicas que entram ou saem das câmaras do cilindro atuador, passando pelos orifícios de controle da servoválvula e pela equação da dinâmica do pistão. Neste capítulo é descrita a sequência de procedimentos necessária para a obtenção de um modelo não-linear para um servoposicionador pneumático. O comportamento dinâmico das pressões das câmaras é modelado por meio da equação da continuidade. A dinâmica do pistão é equacionada por meio da 2ª Lei de Newton. Para a obtenção do modelo das vazões mássicas da servoválvula e do atrito presente no êmbolo são utilizadas duas redes neurais supervisionadas, cujo treinamento é feito de maneira *offline* com padrões de treinamentos adquiridos na bancada experimental descrita na Seção 2.1.

2.1 Bancada Experimental para o Servoposicionador Pneumático

Os parâmetros físicos e geométricos do sistema, bem como as características técnicas dos elementos elétricos e mecânicos envolvidos (sensores, atuadores e sistema de aquisição de dados) estão apresentados no Apêndice I.

A bancada experimental é composta de uma servoválvula (*Festo MPYE 5-1/8*) que possui um sistema de realimentação interno garantindo um comportamento aproximadamente linear de abertura e fechamento em função da tensão elétrica aplicada. Perondi, 2002, verificou que esse tipo de válvula pode apresentar um sobrepassamento (*overlap*) que ocasiona uma zona morta de cerca de até 8% da tensão máxima. O êmbolo móvel do cilindro é conectado a um sensor linear (*Festo POT-1000-TFL*) de curso semelhante ao do cilindro atuador (1 m). Dois sensores eletro-resistivos (*HubaControl – 510*) medem a pressão manométrica em cada câmara do cilindro. O mecanismo de controle e aquisição de dados consiste de uma placa de controle (*dSPACE – DS1104*) acoplada a um computador pessoal. Para as conversões analógico-digital (AD) e digital-analógica (DA), a placa de controle *dSPACE* utilizada apresenta programas computacionais auxiliares para gerenciamento da aquisição de dados e módulos de acoplamento para o software *MatLab/Simulink*. Assim, os algoritmos em tempo real de medições e controle programados em *MatLab/Simulink* são compilados e enviados para a placa de controle *dSPACE* conectada ao PC. Os dados

adquiridos pela placa de controle *dSPACE* são enviados para um software supervisorío (*ControlDesk*), que permite a exportação dos mesmos para o software *MatLab/Simulink*, onde os dados são pós-processados. O tempo de amostragem escolhido na aquisição de dados e controle do sistema físico é de 1 ms. Esse tempo de amostragem é suficiente visto que a servoválvula direcional MPYE 5-1/8 FESTO possui tempo resposta de até 5 ms.

O sistema em estudo está ilustrado na Figura 2.1. Uma servoválvula proporcional 5/3 vias comanda um cilindro de dupla ação sem haste com diâmetro interno de 0,025 m e curso 1 m. Uma fotografia da bancada experimental é apresentada na Figura 2.2. Nesta são apresentados os sensores de pressão e posição, o cilindro de atuação, a servoválvula direcional e os vasos de pressão utilizados, para que a pressão de suprimento seja o mais constante possível.

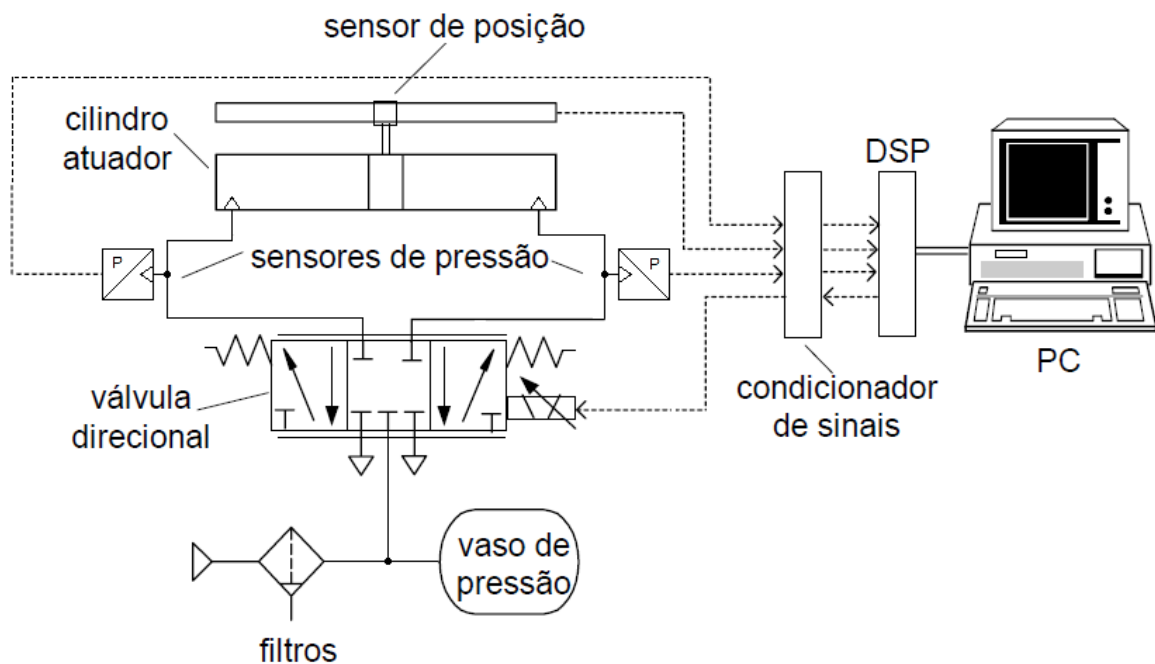


Figura 2.1 – Desenho esquemático da bancada experimental e sistema elétrico




Figura 2.2 – Fotografia da bancada de testes do atuador pneumático montada no Laboratório de Mecatrônica e Controle da UFRGS (LAMECC)

2.2 Modelagem do Servoposicionador Pneumático

Nesta seção são descritos os principais procedimentos utilizados para a obtenção do modelo matemático para o servoposicionador pneumático. A descrição da vazão mássica de ar na servoválvula é feita usando o princípio de conservação da energia, enquanto o equilíbrio de forças no pistão do cilindro é estabelecido através da Segunda Lei de Newton.

No presente contexto, a modelagem consiste na obtenção de um conjunto de equações que representa o comportamento dinâmico do sistema que, além de auxiliar no conhecimento da natureza dos fenômenos físicos envolvidos, fornece informações úteis ao projeto dos controladores. A modelagem foi desenvolvida de acordo com o método da continuidade [Fox e McDonald, 1981]. Para que modelo resultante seja tratável numericamente de acordo com a abordagem da continuidade, são adotadas algumas hipóteses simplificativas. Neste trabalho, as principais hipóteses são:

- a energia cinética do gás é desprezada;
- os efeitos dissipativos (perdas de carga) nas tubulações e conexões são desprezados;
- o ar se comporta como um gás perfeito (a lei geral de estados dos gases é válida);
- os calores específicos a pressão e volume constantes não se alteram ao longo dos processos;
- os vazamentos nos dutos, servoválvula e no êmbolo do cilindro são considerados insignificantes;
- a dinâmica da servoválvula não é considerada e
- os processos nas câmaras são considerados isentrópicos.

2.3 Dinâmica das Pressões nas Câmaras do Cilindro Atuador

A Figura 2.3 apresenta um esquema do volume de controle com domínio variável que representa o atuador pneumático. Onde p é a pressão, V o volume, e T a temperatura do volume de controle, Q a energia calorífica, y a posição do êmbolo e p_u e p_d as pressões a montante e jusante, respectivamente.

Considerando o volume de controle apresentado na Figura 2.3, emprega-se a hipótese de conservação da energia para realizar o balanço energético entre a energia interna da massa de fluido que entra no volume de controle, a potência associada ao movimento do pistão e a variação da energia interna no volume de controle ao longo do tempo. Como as transformações de compressão e expansão das câmaras e consequentes trocas de calor internas são processos que ocorrem com velocidade relativamente rápida em relação ao fluxo de calor através das paredes do cilindro, as trocas de calor são reduzidas, podendo-se utilizar a hipótese de comportamento adiabático para esses processos. Acrescentando-se ainda a

hipótese de que os processos são reversíveis, resulta em um sistema caracterizado com comportamento isentrópico.

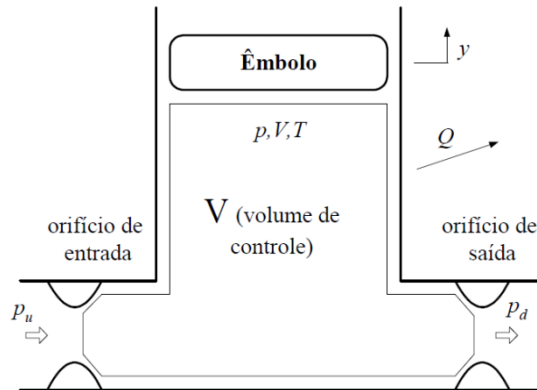


Figura 2.3 – Volume de controle com domínio variável

Uma medida da energia contida na massa que entra no volume de controle da câmara 1 do cilindro pode ser expressa por $C_p q_{m1} T$, onde C_p é o calor específico do ar a pressão constante, T é a temperatura do ar de suprimento e $q_{m1} = dm_1/dt$ é a vazão mássica que entra ou sai da câmara 1. Essa vazão mássica depende da relação p_1/P_{sup} ou p_1/P_{atm} conforme descrito no Apêndice II, onde p_1 é a pressão na câmara 1, P_{sup} é a pressão de suprimento e P_{atm} é a pressão atmosférica.

A potência associada ao movimento do pistão é expressa por $p_1 \dot{V}_1$, onde \dot{V}_1 é a derivada do volume de controle V_1 . A variação na energia interna do volume de controle pode ser expressa por $d(C_v \rho_1 V_1 T)/dt$, onde C_v é o calor específico do ar a volume constante e ρ_1 é a massa específica do ar. Definindo a relação entre os calores específicos $r = C_p/C_v$ e lembrando que, para um gás ideal, a equação da massa específica é $\rho_1 = p_1/(RT)$, sendo R a constante do gás, pode-se realizar o balanço energético, do qual resulta

$$q_{m1} T - \frac{p_1}{C_p} \frac{dV_1}{dt} = \frac{1}{rR} \frac{d}{dt} (p_1 V_1) \quad (2.1)$$

onde a potência calorífica dissipada através das paredes do cilindro (\dot{Q}) é desprezada. O volume total na câmara 1 é expresso por $V_1 = A \left(\frac{L}{2} + y \right) + V_{10}$, onde A é a área do êmbolo, y é o deslocamento do êmbolo e V_{10} é o *volume morto* na câmara 1, incluindo as tubulações. A taxa de variação deste volume é $\dot{V}_1 = A \dot{y}$, onde $\dot{y} = dy/dt$ é a velocidade do êmbolo. Resolvendo a Equação (2.1) para \dot{p}_1 , após efetuar a derivada do termo da direita, chega-se então a

$$\dot{p}_1 = -\frac{Ar\dot{y}}{A\left(\frac{L}{2} + y\right) + V_{10}}p_1 + \frac{RrT}{A\left(\frac{L}{2} + y\right) + V_{10}}q_{m1} \quad (2.2)$$

onde q_{m1} é a vazão mássica que sai da servoválvula para a câmara 1. Sendo q_{m2} a vazão mássica que sai da servoválvula para a câmara 2, V_{20} o *volume morto* na câmara 2 e L o comprimento útil do cilindro atuador, tem-se para a câmara 2,

$$\dot{p}_2 = \frac{Ar\dot{y}}{A\left(\frac{L}{2} - y\right) + V_{20}}p_2 + \frac{RrT}{A\left(\frac{L}{2} - y\right) + V_{20}}q_{m2} \quad (2.3)$$

Assumindo que as vazões mássicas são funções das pressões no cilindro e da tensão u aplicada à servoválvula, ou seja, $q_{m1} = q_{m1}(p_1, u)$ e $q_{m2} = q_{m2}(p_2, u)$, as expressões (2.2) e (2.3) podem ser reescritas como

$$\dot{p}_1 = -\frac{Ar\dot{y}}{A\left(\frac{L}{2} + y\right) + V_{10}}p_1 + \frac{RrT}{A\left(\frac{L}{2} + y\right) + V_{10}}q_{m1}(p_1, u) \quad (2.4)$$

$$\dot{p}_2 = -\frac{Ar\dot{y}}{A\left(\frac{L}{2} - y\right) + V_{20}}p_2 + \frac{RrT}{A\left(\frac{L}{2} - y\right) + V_{20}}q_{m2}(p_2, u) \quad (2.5)$$

2.4 Equilíbrio das Forças no Pistão

O equilíbrio dinâmico de forças no êmbolo é obtido através da aplicação da 2ª lei de Newton, e resulta:

$$M\ddot{y} + f_a + f_e = A(p_1 - p_2) \quad (2.6)$$

onde M é a massa deslocada, f_a é a força de atrito, f_e é uma força externa aplicada sobre a massa M e $A(p_1 - p_2)$ é a força de atuação associada à diferença de pressão entre as câmaras (Figura 2.4).




Figura 2.4 – Equilíbrio de forças no êmbolo do cilindro atuador [Perondi, 2002]

As equações (2.4) a (2.6) constituem um modelo dinâmico de quarta ordem do sistema pneumático de posicionamento, cujas variáveis de estado podem ser $x = [y \ \dot{y} \ p_1 \ p_2]^T$. Este modelo inclui as não-linearidades caracterizadas pelo produto e quociente de variáveis de estado presentes nas relações (2.4) e (2.5), pela parcela de atrito não viscoso incluída em f_a e pelas relações (2.7) e (2.8) que descrevem as vazões mássicas na servoválvula.

$$q_{m1} = q_{m1}(p_1, u) \quad (2.7)$$

$$q_{m2} = q_{m2}(p_2, u) \quad (2.8)$$

2.5 Modelo Não-Linear de Quarta Ordem

Definindo $p_\Delta = p_1 - p_2$ como a diferença de pressão entre as câmaras 1 e 2, a expressão (2.6) resulta:

$$M\ddot{y} + f_a + f_e = Ap_\Delta \quad (2.9)$$

Utilizando as expressões (2.4) e (2.5), pode-se escrever a derivada da diferença de pressão em relação ao tempo como:

$$\dot{p}_\Delta = RrT \left[\frac{q_{m1}(p_1, u)}{A \left(\frac{L}{2} + y \right) + V_{10}} - \frac{q_{m2}(p_2, u)}{A \left(\frac{L}{2} - y \right) + V_{20}} \right] - rA\dot{y} \left[\frac{p_1}{A \left(\frac{L}{2} + y \right) + V_{10}} + \frac{p_2}{A \left(\frac{L}{2} - y \right) + V_{20}} \right] \quad (2.10)$$

Dessa forma é possível agrupar os termos que dependem da tensão na servoválvula u em uma função $u_n = u_n(p_1, p_2, y, u)$, e os termos que independem da tensão em uma função $h_n = h_n(p_1, p_2, y, \dot{y})$, ou seja:

$$u_n(p_1, p_2, y, u) = RrT \left[\frac{q_{m1}(p_1, u)}{A \left(\frac{L}{2} + y \right) + V_{10}} - \frac{q_{m2}(p_2, u)}{A \left(\frac{L}{2} - y \right) + V_{20}} \right] \quad (2.11)$$

$$h_n(p_1, p_2, y, \dot{y}) = -rA\dot{y} \left[\frac{p_1}{A \left(\frac{L}{2} + y \right) + V_{10}} + \frac{p_2}{A \left(\frac{L}{2} - y \right) + V_{20}} \right] \quad (2.12)$$

Com isso, a expressão (2.13) resulta:

$$\dot{p}_\Delta = h_n(p_1, p_2, y, \dot{y}) + u_n(p_1, p_2, y, u) \quad (2.13)$$

As expressões (2.9) e (2.13) constituem uma forma compacta de descrever o sistema não-linear de quarta ordem.

2.6 Redes Neurais Artificiais

A mais de 50 anos foram desenvolvidos o algoritmo de treinamento Mínimos Quadrados Médios (*Least Mean Squares - LMS*) [Widrow e Hoff, 1960] e a Regra Perceptron [Rosenblatt, 1962], ambos publicados pela primeira vez no início da década de 60 e que foram de fundamental importância para o desenvolvimento das Redes Neurais Artificiais (RNA), chamadas também de apenas Redes Neurais (RN) [Haykin, 1999]. A estrutura básica do neurônio (*perceptron de Rosenblatt*, [Arbib, 2003]) é apresentada na Figura 2.5. O neurônio é basicamente composto por suas entradas (e_1, e_2, \dots, e_n), pelos ganhos nos pesos das entradas (w_1, w_2, \dots, w_n), uma entrada de polarização (*bias*), a função de ativação e a saída do neurônio.

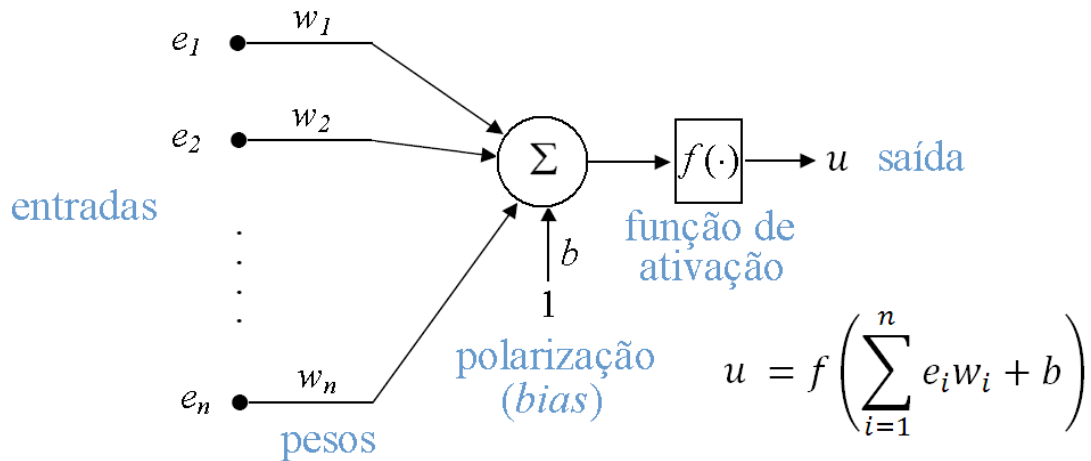


Figura 2.5 – Estrutura básica de um neurônio

O neurônio pode ser visto como uma soma ponderada de todas as entradas somada a um termo de *bias* (polarização) aplicada a uma função de ativação. A função de ativação é uma função matemática linear ou não-linear e seu uso surgiu baseado no comportamento do neurônio biológico [McCulloch e Pitts, 1943], que ora transmitia os sinais elétricos recebido pelos dendritos em direção ao axônio e ora não, como se houvesse uma função de um limiar matemático. Na Figura 2.6 são apresentadas as principais funções de ativações utilizadas nos neurônios em RN.

Em [Jain et. al, 1996] são descritas muitas formas de conectar os neurônios entre si. A Figura 2.7 apresenta um possível agrupamento destas formas. Por não possuírem realimentação, as redes *feed-forward* apresentam uma maior facilidade na prova da sua estabilidade em relação às redes recorrentes. Por outro lado, por apresentarem uma ou mais realimentações, as redes recorrentes, acabam adicionando estados internos ao sistema o que dificulta a prova da sua estabilidade.

Em [Jain et. al, 1996] são descritas muitas formas de conectar os neurônios entre si. A Figura 2.7 apresenta um possível agrupamento destas formas. Por não possuírem realimentação, as redes *feed-forward* apresentam uma maior facilidade na prova da sua estabilidade em relação às redes recorrentes. Por outro lado, por apresentarem uma ou mais realimentações, as redes recorrentes, acabam adicionando estados internos ao sistema o que dificulta a prova da sua estabilidade.

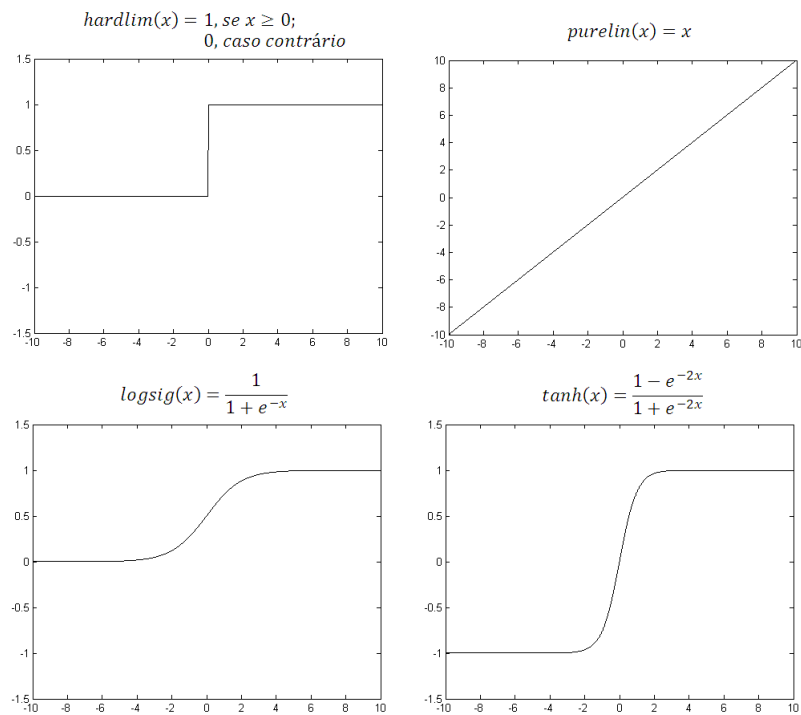


Figura 2.6 – Exemplos de funções de ativação utilizadas nos neurônios

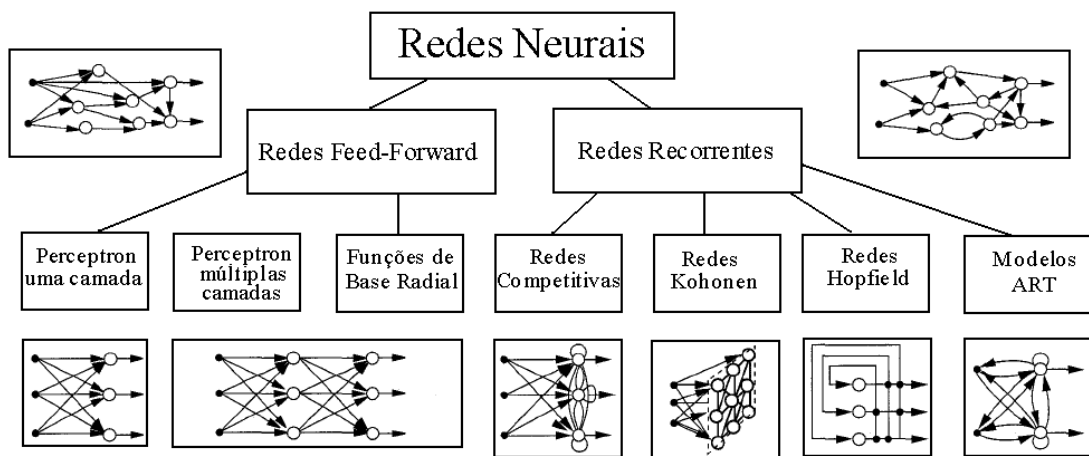


Figura 2.7 – Agrupamento de arquiteturas de redes *feed-forward* e recorrentes [Jain et. al, 1996]

De forma genérica, podem-se separar as redes neurais em dois grupos: as redes *feed-forward* (propagação para frente) e as redes recorrentes (com algum tipo de realimentação ou dinâmica interna). As redes *feed-forward* não possuem dinâmica interna enquanto as redes recorrentes possuem de alguma forma uma dinâmica interna em sua topologia. Portanto, quando as redes recorrentes são utilizadas no controle de sistemas dinâmicos, a prova de estabilidade do sistema em malha fechada apresenta um grau de dificuldade mais elevado.

Apesar desse fato, as redes *feed-forward* poderão acabar possuindo uma dinâmica interna caso o treinamento da rede seja feito de forma *online* (isto é, durante o controle em malha fechada do sistema), este não será o caso de estudo na presente tese. Todas as redes utilizadas neste trabalho são do tipo *feed-forward* e foram treinadas de forma *offline* (isto é, antes de serem utilizadas no controle em malha fechada).

As redes de base radial são muito semelhantes às redes com perceptrons de múltiplas camadas com a diferença básica que as funções de ativações são funções de base radial, são funções sobre números reais cujos valores dependem apenas da distância a partir da origem (por exemplo: função Gaussiana). As redes competitivas são aquelas em que os neurônios competem com os seus vizinhos para continuar funcionando, um exemplo para este tipo de rede é quando neurônios que não estão contribuindo adequadamente para o resultado desejado são podados. O fato de se eliminar um neurônio faz com que a estrutura da rede seja mudada, adicionando a rede uma dinâmica interna. As redes de Kohonen, que são um tipo especial de redes competitivas são também chamadas de Mapas Auto-Organizáveis (SOM - *Self-Organizing Maps*), que é um método de aprendizado não supervisionado (isto é, não existem padrões de treinamento). Seu desenvolvimento foi baseado em uma característica distinta do cérebro onde os neurônios transformam os sinais de entrada em uma distribuição de probabilidade codificada pela sua localização. As redes de Hopfield são redes neurais com realimentação de múltiplos laços com atrasos unitários. As redes ART (*Adaptive Resonance Theory*) foram baseadas na análise da literatura experimental em visão, fala e desenvolvimento do córtice. A característica principal de uma rede ART é seu processo de casamento de padrões que compara uma entrada externa com um estado interno da rede neural, este estado interno pode se modificar de acordo com as entradas apresentadas [Haykin, 1999].

Neste trabalho é utilizada uma rede neural com propagação para frente (*feed-forward*) com múltiplas camadas de perceptrons (*multilayer perceptrons* - MLP) totalmente conectada (*fully connected*). A Figura 2.8 apresenta uma topologia típica de uma rede neural MLP *feed-forward* totalmente conectada com três camadas. O termo perceptron foi utilizado pela primeira vez em [Rosenblatt, 1958] como sendo um modelo matemático para a representação de um neurônio. A primeira camada é chamada de *camada de entrada*, utilizando-se, normalmente, uma função de ativação linear (*purelin*), a última camada é chamada de *camada de saída*, enquanto a camada intermediária é chamada de *camada oculta* ou *escondida* ou

intermediária. A principal ideia é a de fazer com que as entradas dos neurônios de uma camada sejam as saídas dos neurônios das camadas anteriores. Quando uma rede neural é dita completamente conectada, isso significa que todos os neurônios (perceptrons de Rosenblatt) de uma camada anterior estão conectados por pesos com cada neurônio da camada posterior. Uma rede MLP pode conter um número arbitrário de camadas (*camada de entrada*, uma ou mais *camadas ocultas* e uma *camada de saída*). No entanto, deve-se evitar um grande número de *camadas ocultas*, pois essa configuração pode levar a rede a apresentar um comportamento inadequado, com uma memorização dos dados de treinamento (*overfitting*) ao invés de uma generalização (predizer corretamente dados ou padrões não treinados).

Assim, neste trabalho utilizaram-se redes MLP com apenas uma *camada oculta*, conforme apresentado na Figura 2.8. Além disso, foi utilizada uma de ativação linear (*purelin*) para os neurônios da primeira camada e funções de ativação baseada em tangente hiperbólica (*tanh*) para os neurônios das demais camadas. Este padrão de configuração das funções de ativação para a primeira e segunda camada é clássico na literatura, apenas o uso de uma função baseado na tangente hiperbólica para a saída não o é. Geralmente, utilizam-se funções de ativações do tipo lineares na *camada de saída*. Neste trabalho optou-se por utilizar funções baseadas em tangente hiperbólica na *camada de saída*, pois como a função matemática da tangente hiperbólica é limitada todas as saídas das redes neurais deste trabalho também o serão.

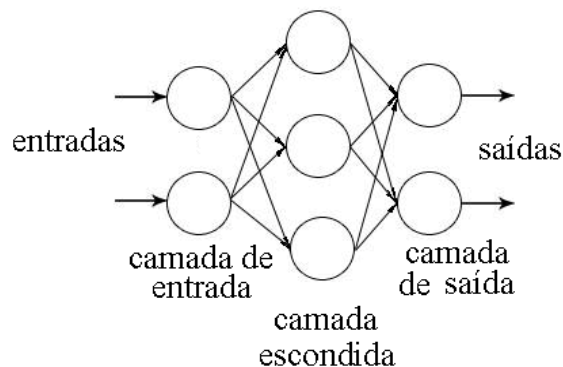


Figura 2.8 – Topologia típica de uma rede neural MLP *feed-forward* com três camadas e totalmente conectada

As redes MLP utilizam uma técnica de aprendizado supervisionado chamada de retropropagação (*backpropagation*). O aprendizado da RN ocorre por meio de um processo de adaptação dos pesos das conexões entre os neurônios baseado no cálculo do erro entre as saídas desejadas (esperadas) e as saídas fornecidas pela rede. No aprendizado supervisionado,

primeiramente são levantados os padrões de treinamento da rede. Estes padrões são compostos por entradas típicas do sistema cujo comportamento se deseja reproduzir e respectivas saídas desejadas. Por exemplo, no treinamento de uma função XOR (ou exclusivo) os padrões de treinamento seriam as entradas e respectivas saídas da operação lógica, conforme a Tabela 2.1.

Tabela 2.1 – Exemplo de padrões de treinamento para a operação lógica XOR com duas entradas

Entradas		Saída
0	0	0
0	1	1
1	0	1
1	1	0

No algoritmo de *backpropagation*, geram-se valores aleatórios para o vetor de pesos w_i dos neurônios próximos a zero. Na primeira fase do treinamento os valores típicos dos padrões das entradas são aplicados nos neurônios da *camada de entrada*. Em seguida, é realizada a propagação das entradas (fase *feed-forward*) até a obtenção das saídas da RN, as quais são, então, comparadas com as saídas esperadas, resultando nos valores dos erros associados a cada neurônio da camada de saída. Com este erro, é possível recalcular (adaptar) os pesos que conectam a última camada intermediária com a camada de saída.

O algoritmo *backpropagation* pode ser de colocado de uma forma simplificada conforme o Quadro 1.

Quadro 1 - Algoritmo Backpropagation [Jain *et al.*, 1996].

1. Inicializa-se todos os pesos da RN com valores aleatórios próximos de zero;
2. Escolhe-se um padrão de entrada x^u e aplica-se nos neurônios das camadas de entrada da rede;

$$y_i^1 = x^u$$

onde y_i^1 é a saída do i -ésimo neurônio da camada de entrada (denominada pelo índice '1') e x^u é o u -ésimo padrão de entrada da rede.

3. Propaga-se o sinal para frente (*forward*) na rede neural;

$$y_j^l = f \left(\sum_i (y_i^{l-1} w_{ij}^l) \right)$$

para todas as camadas posteriores, ou seja: $l = 2, \dots, L$

onde L é o número da camada de saída, $f(\cdot)$ é a aplicação da função de ativação, y_i^{l-1} é a saída do i -ésimo neurônio da camada $l-1$ e w_{ij}^l é o peso que conecta o i -ésimo neurônio da camada $l-1$ ao j -ésimo neurônio da camada l ;

4. Calcula-se δ_i^L para cada i -ésimo neurônio na camada de saída L

$$\delta_i^L = f'(h_i^L) [d_i^u - y_i^L]$$

onde $f'(\cdot)$ é a derivada da função de ativação $f(\cdot)$, h_i^L representa o somatório das entradas para do i -ésimo neurônio na camada de saída L , d_i^u é a saída desejada do padrão u para o i -ésimo neurônio e y_i^L é a saída atual do i -ésimo neurônio da camada de saída L ;

5. Calculam-se todos os deltas δ_j^l para cada j -ésimo neurônio das l camadas anteriores utilizando a retropropagação do erro:

$$\delta_j^l = f'(h_j^l) \sum_j (w_{ij}^{l+1} \delta_j^{l+1})$$

para todas as camadas anteriores, ou seja: $l = L - 1, \dots, 1$

onde h_j^l representa o somatório das entradas para do j -ésimo neurônio na camada l , w_{ij}^{l+1} é o peso que conecta o i -ésimo neurônio da camada l ao j -ésimo neurônio da camada $l + 1$ e δ_j^{l+1} é o delta do j -ésimo neurônio da camada $l + 1$;

6. Adaptam-se os pesos da rede utilizando:

$$\Delta w_{ji}^l = \eta \delta_j^l y_i^{l-1}$$

onde η é o fator de aprendizado da rede neural, y_j^{l-1} é a saída do j -ésimo neurônio da camada $l - 1$;

Volte para o passo 2 e repita para o próximo padrão de treinamento até que se obtenha um erro na saída menor que o desejado, ou que até que o máximo número de iterações tenha sido atingido, ou caso exista perda de generalização da rede.

2.7 Identificação da Força de Atrito

Para o caso de forças externas nulas, conhecendo-se a aceleração e as pressões nas câmaras, é possível calcular o valor aproximado da força de atrito, o qual pode ser utilizado como saída desejada (*target output*) de uma rede neural, de acordo com a Equação (2.14)

$$f_a = A(p_1 - p_2) - M\ddot{y} \quad (2.14)$$

No projeto desenvolvido, as variáveis escolhidas como entradas na rede neural são a diferença de pressão entre as câmaras do cilindro atuador (p_1 e p_2) e a velocidade do êmbolo do pistão (\dot{y}).

A arquitetura de rede neural adotada para a identificação da força de atrito foi a MLP com aprendizagem supervisionada do tipo *backpropagation* [Jain *et al.*, 1996], [Haykin, 1999]. Optou-se por esta arquitetura por ela ter apresentado resultados na identificação de atrito em servoatuadores robóticos tipo *Harmonic Drive* [Gervini, et al., 2003]. A camada de entrada é composta de dois neurônios associados à diferença das pressões nas câmaras e à velocidade do êmbolo e a camada de saída por um neurônio associado à força de atrito estimado. Decidiu-se, inicialmente, utilizar somente uma camada intermediária (por ser a representação mais simples de uma rede MLP).

Foram testados diferentes números neurônios na camada intermediária (1,2 3,4, 5,...), sendo os resultados com quatro neurônios considerados mais adequados. Números menores de neurônios na camada intermediária causaram dificuldade de estimação da força de atrito, devido a dificuldade de convergência dos parâmetros da rede e números maiores de neurônios na camada intermediária obtiveram incremento de desempenho muito pouco significativo com relação aos resultados obtidos com apenas quatro neurônios. Na Figura 2.9 é ilustrada a arquitetura da rede neural adotada com dois neurônios de entrada (associados à diferença das pressões nas câmaras e velocidade do êmbolo), quatro neurônios na *camada oculta* e um neurônio na *camada de saída* (associado à força de atrito estimado). Esta arquitetura de rede neural já havia sido utilizada em [Machado, 2003] a qual foi baseada em uma rede neural para identificação de atrito de atuadores robóticos [Gervini, 2001].




Figura 2.9 – Arquitetura da Rede Neural Artificial (RNA) usada para a realização da estimação da força de atrito

A arquitetura dos neurônios está de acordo com [Beale e Jackson, 1990] e é mostrada na Figura 2.10. Conforme explicado anteriormente, foi escolhida a função *tangente hiperbólica* para ativação da *camada oculta* e de *saída*.




Figura 2.10 – Arquitetura dos neurônios da *camada oculta* e de *saída* utilizados para a modelagem do atrito

Após o treinamento utilizando a técnica clássica da retropropagação do erro (*backpropagation*), a rede apresentou uma taxa de erro de aproximadamente de 0,02 dos padrões apresentados à rede (este valor equivale a um erro médio de 1% do valor desejado, pois a saída da rede pode variar apenas entre -1 e 1). O erro e de uma rede neural pode ser calculado conforme Equação (2.15).

$$e = \frac{1}{N_p N_s} \sum_{u=1, \dots, N_p} \sum_{i=1, \dots, N_s} |d_i^u - y_i^L| \quad (2.15)$$

com N_p o número de padrões a serem testados, N_s o número de neurônios na camada de saída, d_i^u é a saída desejada do padrão u para o i -ésimo neurônio e y_i^L é a saída atual do i -ésimo neurônio da camada de saída L ;

Na Figura 2.11 são apresentados alguns resultados experimentais utilizados como padrões de treinamento da rede neural para a modelagem do atrito.




Figura 2.11 – Padrões de treinamento da RN para estimação do atrito

As entradas da rede neural são a velocidade e a diferença de pressões nas câmaras, enquanto a saída é a força de atrito, conforme ilustrado anteriormente na Figura 2.9. Os padrões de treinamento foram obtidos através de uma série de ensaios experimentais. Esses ensaios constituíram-se da aplicação de um controlador proporcional para o seguimento de trajetória de posição utilizando como referência sinais do tipo degrau e também sinais do tipo senoidal.

Os valores dos parâmetros utilizados nos experimentos selecionados para a identificação do atrito estão apresentados na Tabela 2.2.

Na Figura 2.12 é apresentada uma curva da força de atrito estimada pela rede neural após o treinamento sobreposta com a força de atrito calculada através da Equação (2.14) para o caso de uma referência senoidal de amplitude de 0,45 m e frequência de 2 rad/s, com o

controlador proporcional com ganho $K_p = 8$. Cabe salientar que a rede neural para a estimativa do atrito não foi treinada para um experimento com este ganho para o controlador proporcional, mesmo assim a rede conseguiu uma estimativa adequada para este novo conjunto de entradas, que não foram treinadas. Isto indica que a rede neural para a estimativa do atrito possui uma satisfatória generalização (termo comumente utilizado em redes neurais para uma extrapolação adequada dos dados de treinamento).

Tabela 2.2 – Parâmetros dos experimentos selecionados para o treinamento da rede neural

Intervalo	Ganho proporcional em posição	Referência
0 s-10 s	2	degrau (0,45 m a -0,45 m)*
10 s-20 s	4	degrau (0,45 m a -0,45 m)*
20 s-30 s	10	degrau (0,45 m a -0,45 m)*
30 s-40 s	4	$0,45 \text{ sen}(2t)$ m
40 s-50 s	10	$0,45 \text{ sen}(2t)$ m

* Obs.: a referência tipo degrau aplicada possui um período de 2 rad/s.




Figura 2.12 – Força de atrito experimental (preto) e estimada pela rede neural (azul) para $K_p = 8$ e referência senoidal com frequência de 2 rad/s e amplitude de 0,45 m

2.8 Identificação das Vazões Mássicas

Nesta seção é apresentada a estratégia de identificação das vazões mássicas das câmaras através de redes neurais. Utilizando as Equações (2.4) e (2.5), é possível isolar as vazões mássicas q_{m1} e q_{m2} , conforme as Equações (2.16) e (2.17):

$$q_{m1} = \frac{\left(A \left(\frac{L}{2} + y\right) + V_{10}\right) \dot{p}_1 + Ar\dot{y}p_1}{RrT} \quad (2.16)$$

$$q_{m2} = \frac{\left(A \left(\frac{L}{2} - y\right) + V_{20}\right) \dot{p}_2 - Ar\dot{y}p_2}{RrT} \quad (2.17)$$

A rede neural proposta para a realização da identificação das vazões mássicas das câmaras 1 e 2 é apresentada na Figura 2.13. Visto que as vazões mássicas sofrem influência direta da tensão de controle e pressões nas câmaras, bem como pressão de suprimento (considerada como constante).




Figura 2.13 – Arquitetura da RNA para estimação das vazões mássicas

A rede neural possui três entradas (tensão elétrica de controle aplicada a servoválvula, pressões nas câmaras 1 e 2) e duas saídas (vazões mássicas nas câmaras 1 e 2). Após diferentes testes de treinamento, foram escolhidos quatro neurônios na camada intermediária, tendo a rede neural, com esse número, apresentado aprendizado dos padrões considerado satisfatório e uma boa generalização. Após o treinamento a rede apresentou uma taxa de erro de aproximadamente 1,5% (0,03) de erro em relação ao valor desejado. O erro e de uma rede neural foi calculado de acordo com a Equação (2.15).

Os dados utilizados como padrões de treinamento para a identificação das vazões mássicas estão apresentados na Figura 2.14. Os experimentos utilizados para a identificação da vazão mássica possuem as mesmas especificações dos realizados para o treinamento da rede neural de identificação do atrito, conforme apresentado na Seção 2.7. Na Figura 2.14 estão apresentados alguns resultados experimentais representativos das curvas utilizadas no treinamento da rede neural de identificação das vazões mássicas.




Figura 2.14 – Sinais utilizados para o treinamento da RN para estimação das vazões mássicas

Após a fase de treinamento, foram realizados alguns testes visando avaliar o desempenho da rede neural treinada na predição das vazões mássicas em experimentos que não foram utilizados no treinamento com ganho proporcional igual 8 e com referência senoidal, de acordo com a Tabela 2.2. Resultados desses testes estão apresentados na Figuras 2.15 e 2.16. É possível perceber que por meio do uso da rede neural foi possível estimar adequadamente as vazões mássicas de um experimento para o qual a rede não foi treinada.




Figura 2.15 – Vazão mássica experimental da câmara 1 (preto) e estimada pela rede neural (azul)




Figura 2.16 – Vazão mássica experimental da câmara 2 (preto) e estimada pela rede neural (azul)

2.9 Validação do modelo obtido

Para validar os resultados do modelo proposto, formado pelas Equações (2.4) a (2.6) e pelas duas redes neurais treinadas descritas nas seções 2.6 e 2.7, foram realizadas simulações da resposta dinâmica do sistema em malha aberta. Para tanto, adotou-se o procedimento descrito a seguir.

Implantou-se inicialmente um controlador proporcional (com $K_p = 6$), o qual foi utilizado para a realização de experimentos em malha fechada. O sinal de controle calculado e os resultados desses testes foram armazenados em arquivos digitais para uso posterior nas comparações entre os resultados experimentais e os das simulações. As simulações foram

realizadas em malha aberta utilizando-se as curvas do sinal de controle calculadas durante os experimentos. Foi escolhida a utilização em malha aberta na simulação, pois as respostas em malha fechada tendem a mascarar as diferenças entre experimento e simulação. Para tanto, para que essas curvas pudessem ser utilizadas como entrada do modelo, o valor do passo de integração adotado é o mesmo do período de amostragem dos experimentos (1 ms). Assim, as simulações, apesar de serem realizadas em malha aberta, respondem a um sinal de controle calculado experimentalmente em malha fechada. Com isso, as respostas dos experimentos realizados em malha fechada podem ser comparadas com as respostas das simulações realizadas, por sua vez, em malha aberta.

Na Figura 2.17 está apresentada a curva de velocidade obtida experimentalmente através da derivada do sinal de posição sobreposta com a velocidade prevista pelo modelo desenvolvido.

Percebe-se que o modelo consegue, a baixas velocidades, reproduzir o comportamento associado ao fenômeno de *stick-slip* (adere-desliza). Este fenômeno ocorre quando a força resultante no êmbolo é menor do que o atrito seco e a velocidade menor do que um determinado limite próximo do zero, definido como a velocidade de quebra (\dot{y}_{st}), que corresponde ao menor valor da velocidade encontrado em respostas em malha aberta. Em [Gomes *et al.*, 2006], onde é apresentado um estudo do fenômeno de atrito em atuadores robóticos, é demonstrado que existe uma velocidade limite (\dot{y}_{lim}), abaixo da qual o comportamento do tipo *stick-slip* pode ocorrer. O comportamento *stick* ocorre quando a velocidade do elemento que se desloca é menor do que a velocidade limite ao mesmo tempo que o equilíbrio de torque (ou força) resultante é menor do que o atrito seco (f_{at}). Essas condições inicializam o modo *stick*, ou seja, a velocidade vai a zero sobre as trajetórias C e D da Figura 2.18, onde é apresentado um gráfico das trajetórias de atrito. Segundo esse modelo, o movimento só volta a ocorrer quando o torque (ou força) resultante voltar a ser superior ao atrito estático e o efeito Stribeck faz com que a trajetória *slip* (trajetória B da Figura 2.18) seja menos amortecida do que a trajetória *stick*. Comutações entre os modos *stick* e *slip* podem acontecer antes de se configurar uma velocidade nula, ocorrendo em transições verticais da trajetória B para as trajetórias C ou D, quando um modo *slip* se transforma em um *stick*, passando da curva C ou D para a B, quando um comportamento *stick* se transforma em um *slip* [Gomes *et al.*, 2006].




Figura 2.17 – Velocidade do êmbolo experimental (preto) e modelo (azul)




Figura 2.18 – Trajetórias de atrito idealizadas para representar o fenômeno *stick-slip*.

Nas Figuras 2.19 e 2.20 são apresentadas sobrepostas as pressões da câmara 1 e câmara 2 obtidas experimentalmente e através das simulações referente ao enchimento e esvaziamento das câmaras em experimento e em simulação. É possível verificar a ocorrência de uma concordância entre os valores das pressões calculados através do modelo com os obtidos experimentalmente, salientando-se que os resultados obtidos por meio das simulações foram calculados utilizando os mesmos valores dos sinais de controle aplicados experimentalmente em malha fechada.

O desempenho das variáveis analisadas do modelo foi avaliado segundo critério Integral do Erro Absoluto (IAE - *Integral of Absolute Error*), e os respectivos valores estão apresentados na Tabela 2.3.

Tabela 2.3 – Resultados das simulações usando o modelo proposto segundo critério IAE

Critério	\dot{y}	p_1	p_2
$IAE = \int e dt$	1,42	$1,13 \times 10^5$	$1,16 \times 10^5$

O critério IAE estabelece um procedimento de avaliação do desempenho do modelo descrito por meio da Equação (2.18).

$$\text{IAE} = \int |e| dt \quad (2.18)$$




Figura 2.19 – Pressão na câmara 1 experimental (preto) e modelo (azul)




Figura 2.20 – Pressão na câmara 2 experimental (preto) e modelo (azul)

Para o treinamento das redes neurais no presente trabalho utilizou-se o fator de aprendizagem $\eta = 0,025$. A condição de parada utilizada para o treinamento backpropagation foi de um erro de 0,01 (equivalente a 0,5%) ou no máximo 30 iterações para cada conjunto de padrões, sendo que cada conjunto possui 50.000 amostras (equivalente 50 s com uma amostragem de 1 ms) conforme apresentado, por exemplo, na Figura 2.14. Foi utilizado

também um filtro *butterworth* de 2ª ordem *offline* sem atraso, para os três sinais de sensores (posição do êmbolo e pressões nas câmaras) com um corte de frequências superiores a 100 Hz, com o objetivo de eliminar ruídos de mais alta frequência.

2.10 Procedimento para o levantamento do Modelo Pneumático Neural

Nesta seção será apresentado um procedimento para a obtenção de um modelo pneumático neural. Para o levantamento do modelo pneumático neural é proposto um procedimento, composto por uma sequência de passos da seguinte forma:

1. Levantamento de todas as constantes e parâmetros do sistema, tais como: constantes de calores específicos (C_p e C_v), temperatura de trabalho (T), relação dos calores específicos (r), massa deslocada (M), comprimento útil do cilindro (L), área útil da seção interna do cilindro (A), etc.
2. Realização em bancada de experimentos em malha fechada com realimentação em posição, variando-se os ganhos do controlador proporcional, bem como o tipo de referência (senoidal, polinomial, degrau, etc.). Salvando os dados de posição do êmbolo (y), sinais dos sensores de pressões nas câmaras (p_1 e p_2) e tensão elétrica de controle calculada em malha fechada e aplicada a servoválvula (u) para cada experimento realizado.
3. Com os dados obtidos no passo 2, obter de forma *offline* as seguintes derivadas: velocidade do êmbolo (\dot{y}), aceleração do êmbolo (\ddot{y}), derivada das pressões nas câmaras 1 e 2 (\dot{p}_1 e \dot{p}_2).
4. Calcular a força de atrito do sistema real (f_a) através da Equação (2.14), as vazões mássicas que entram e saem das câmaras 1 e 2 (q_{m1} e q_{m2}) utilizando as Equações (2.16) e (2.17), a variável h_n através da Equação (2.12) e u_n pela Equação (2.13).

5. Implementa-se uma rede neural para identificação do atrito conforme Seção 2.7, tendo como entradas a diferença das pressões (p_{Δ}) e velocidade do êmbolo (\dot{y}) e como saída da rede a estimativa da força de atrito (\hat{f}_a). Treina-se a rede neural para a estimação do atrito utilizando o algoritmo de treinamento do Quadro 1, tendo como padrões de treinamento a velocidade \dot{y} , a diferença das pressões p_{Δ} e a força de atrito (f_a). Ao final do treinamento a rede neural deverá ser capaz de fornecer uma estimativa para o atrito (\hat{f}_a).
6. Implementa-se uma rede neural para a identificação das vazões mássicas conforme Seção 2.8, tendo como entradas a tensão elétrica aplicada na servoválvula (u) e pressões nas câmaras 1 e 2 (p_1 e p_2) e como saída e estimativa das vazões mássicas das câmaras 1 e 2 (\hat{q}_{m1} e \hat{q}_{m2}). Treina-se a rede neural para a estimação das vazões mássicas utilizando o algoritmo de treinamento do Quadro 1, tendo como padrões de treinamento a tensão elétrica aplicada na servoválvula (u), pressões nas câmaras 1 e 2 (p_1 e p_2), as vazões mássicas calculadas nas câmaras 1 e 2 (q_{m1} e q_{m2}). Ao final do treinamento a rede neural deverá ser capaz de fornecer uma estimativa para as vazões mássicas das câmaras 1 e 2 (\hat{q}_{m1} e \hat{q}_{m2}).
7. Um modelo matemático para o sistema pneumático pode ser obtido utilizando-se as Equações (2.2)-(2.4), substituindo-se as variáveis F_a , q_{m1} , q_{m2} por suas estimativas \hat{F}_a , \hat{q}_{m1} e \hat{q}_{m2} fornecidas pelas redes neurais treinadas.

Ao final do procedimento obtém-se um modelo matemático não-linear de quarta ordem com as seguintes variáveis de estado y , \dot{y} , p_1 e p_2 .

3 SISTEMA DE CONTROLE

A estratégia do controle em cascata foi desenvolvida a partir da metodologia de redução de ordem com desacoplamento de sistemas proposta inicialmente em [Utkin, 1987]. Esta estratégia vem sendo utilizada com sucesso no controle de robôs acionados eletricamente [Guenther e Hsu, 1993], no controle de acionamentos hidráulicos [Guenther e De Pieri, 1997] e pneumáticos [Perondi, 2002; Sobczyk, 2009]. A principal característica da estratégia em cascata consiste em escrever o equacionamento do sistema na forma de dois (ou mais) subsistemas de forma que diferentes esquemas de controle possam ser aplicados a cada um deles de forma independente.

Assim, de acordo com a estratégia em cascata, pode-se realizar a divisão do sistema de servoposicionamento pneumático em dois subsistemas, de forma que um subsistema mecânico seja acionado por uma força gerada em um subsistema pneumático, como apresentado na Figura 3.1.

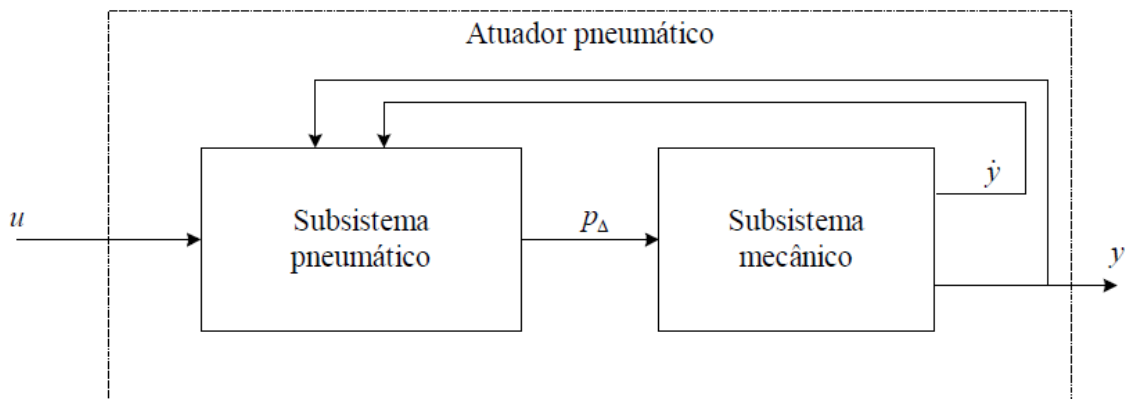


Figura 3.1 – Interpretação do servoposicionador como dois subsistemas interconectados

Um diagrama de blocos do sistema de controle é apresentado na Figura 3.2.

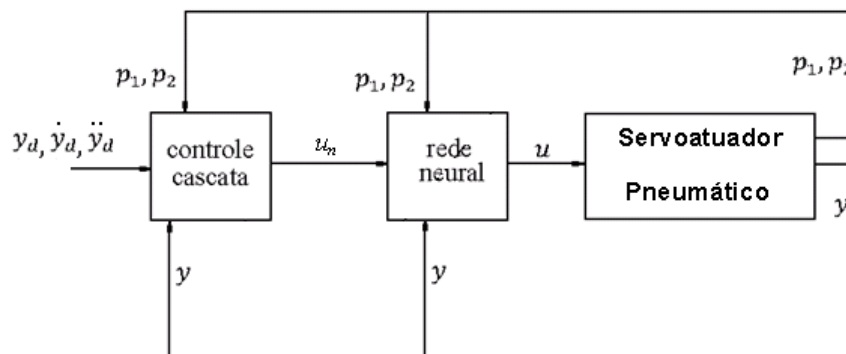


Figura 3.2 – Diagrama em blocos da estratégia de controle em cascata neural proposta.

Considerando, de acordo com a Equação (2.13), a dinâmica do subsistema pneumático escrita na forma

$$\dot{p}_\Delta = h_n + u_n \quad (3.1)$$

E, de acordo com a Equação (2.9), a do subsistema mecânico como

$$M\dot{y} = Ap_\Delta - f_a - f_e \quad (3.2)$$

pode-se equacionar a estratégia de controle em cascata por meio dos procedimentos apresentados nas seções que seguem.

3.1 Seguimento no Subsistema Mecânico

A Lei de Controle de Slotine e Li para Robôs, apresentada aqui em uma versão escalar, mostra-se apropriada para aplicação na estratégia em cascata, pois permite calcular para o caso ideal (com parâmetros conhecidos) o valor do sinal de força a ser aplicado no subsistema mecânico para que ocorra seguimento de trajetória com convergência do erro tendendo a zero, à medida que o tempo avança (Slotine e Li, 1998). Além disso, como será mostrada adiante, a estratégia em cascata permite a avaliação da robustez do sistema quanto à presença de erros nas estimativas de parâmetros e de perturbações. Assim, de acordo com a lei de Slotine e Li, para se obter o seguimento de trajetória no subsistema mecânico pode ser utilizada a seguinte expressão:

$$g_d = M\ddot{y}_r + K_D s + \hat{f}_a + \hat{f}_e \quad (3.3)$$

onde, g_d é a força que deve ser fornecida pelo sistema pneumático de atuação, K_D é uma constante positiva, \hat{f}_a é uma estimativa para a força de atrito, \hat{f}_e é uma estimativa para a força externa aplicada, e \ddot{y}_r e s , são, respectivamente, uma aceleração de referência e uma medida dos erros de seguimento de posição e velocidade.

Definem-se agora os erros de seguimento de posição, velocidade e aceleração, respectivamente, como:

$$\tilde{y} = y - y_d, \quad \dot{\tilde{y}} = \dot{y} - \dot{y}_d, \quad \ddot{\tilde{y}} = \ddot{y} - \ddot{y}_d \quad (3.4)$$

onde, y_d é a posição desejada ao longo do tempo, enquanto sua derivada primeira e segunda são, respectivamente, a velocidade e a aceleração desejadas. A velocidade e a aceleração de referência são, por sua vez, definidas como:

$$\dot{y}_r \triangleq \dot{y}_d - \lambda \tilde{y} \quad (3.5)$$

$$\ddot{y}_r \triangleq \ddot{y}_d - \lambda \dot{\tilde{y}} \quad (3.6)$$

sendo λ uma constante positiva. A combinação linear dos erros de seguimento de posição e de velocidade é definida como:

$$s \triangleq \dot{\tilde{y}} + \lambda \tilde{y} \quad (3.7)$$

e, conseqüentemente, sua derivada primeira pode ser expressa por:

$$\dot{s} = \ddot{\tilde{y}} + \lambda \dot{\tilde{y}} = \ddot{y} - \ddot{y}_r \quad (3.8)$$

Isolando a aceleração na Equação (3.8) e substituindo na (3.2), obtém-se a expressão para o equilíbrio dinâmico em função da combinação linear dos erros de seguimento de posição e velocidade:

$$M\dot{s} = -M\ddot{y}_r + Ap_\Delta + f_a + f_e \quad (3.9)$$

Substituindo \ddot{y}_r (definida na Equação (3.6)) na Equação (3.9), resulta

$$M\dot{s} = -M\ddot{y}_d + M\lambda\dot{\tilde{y}} + Ap_\Delta + f_a + f_e \quad (3.10)$$

Define-se agora o erro no seguimento da diferença de pressão:

$$\tilde{p}_\Delta \triangleq p_\Delta - p_{\Delta d} \quad (3.11)$$

onde $p_{\Delta d}$ é a diferença de pressão desejada, a ser definida com base na força desejada g_d :

$$p_{\Delta d} = \frac{g_d}{A} \quad (3.12)$$

Através das Equações (3.3), (3.11) e (3.12) pode-se expressar diferença em pressão p_Δ como

$$p_\Delta = \frac{M\ddot{y}_r - K_D s + \hat{f}_a + \hat{f}_e}{A} - \tilde{p}_\Delta \quad (3.13)$$

que, substituída em (3.10), fornece

$$M\dot{s} = -M\ddot{y}_r - K_D s - A\tilde{p}_\Delta + M\ddot{y}_r + f_a - \hat{f}_a + f_e - \hat{f}_e \quad (3.14)$$

a qual, simplificada, resulta,

$$M\dot{s} = -K_D s - A\tilde{p}_\Delta + \tilde{f}_a + \tilde{f}_e \quad (3.15)$$

onde \tilde{f}_a é o erro da estimativa da função do atrito, definido por

$$\tilde{f}_a \triangleq f_a - \hat{f}_a \quad (3.16)$$

e \tilde{f}_e é o erro na compensação da força externa aplicada, definido como

$$\tilde{f}_e \triangleq f_e - \hat{f}_e \quad (3.17)$$

A Equação (3.15) representa a dinâmica da combinação linear dos erros de seguimento de posição e velocidade, a qual será utilizada na prova de estabilidade do sistema global de controle.

3.2 Seguimento no Subsistema Pneumático

Para que se consiga alcançar o seguimento da força no subsistema pneumático foi proposto em [Perondi, 2002], o controle da seguinte forma

$$u_n = \dot{p}_{\Delta d} - A s - K_P \tilde{p}_\Delta + \hat{h}_n \quad (3.18)$$

com $\dot{p}_{\Delta d}$ a derivada em função do tempo da diferença de pressão desejada, K_P uma constante positiva para o ganho do erro na diferença de pressão e \hat{h}_n a estimativa na reconstrução da

função h_n . O desenvolvimento de uma função inversa (difeomorfismo) para a reconstrução do sinal de controle $u = u(p_1, p_2, y, u_n)$ é proposto no Apêndice III.

Para se obter a dinâmica do erro da diferença das pressões substitui-se a equação (3.18) em (3.1)

$$\dot{\tilde{p}}_{\Delta} = -K_p \tilde{p}_{\Delta} - As + \tilde{h}_n \quad (3.19)$$

onde \tilde{h}_n é o erro na reconstrução da função h_n pela estimativa \hat{h}_n devido a incertezas paramétricas.

A Equação (3.19) representa a dinâmica do erro da diferença das pressões nas câmaras a qual será utilizada na prova de estabilidade do sistema global de controle.

3.3 Análise de Estabilidade

Nesta seção será apresentada a análise de estabilidade via Lyapunov. Seja a função candidata a Lyapunov

$$2V = Ms^2 + P\tilde{y}^2 + \tilde{p}_{\Delta}^2 \quad (3.20)$$

V representa a função candidata Lyapunov onde s é a combinação linear dos erros de seguimento de posição e de velocidade, \tilde{y} o erro em posição, \tilde{p}_{Δ} erro da diferença das pressões, M a massa total deslocada e P uma constante positiva a ser definida.

Substituindo a combinação linear dos erros de seguimento de posição e velocidade expressa por meio da Equação (3.7) na (3.20), resulta:

$$2V = (\lambda^2 M + P)\tilde{y}^2 + 2\lambda M \dot{\tilde{y}}\tilde{y} + M\dot{\tilde{y}}^2 + \tilde{p}_{\Delta}^2 \quad (3.21)$$

Pode-se, então, reescrever a Equação (3.21) na forma quadrática matricial:

$$2V = \boldsymbol{\rho}^T N_1 \boldsymbol{\rho} \quad (3.22)$$

onde se utilizam as seguintes definições

$$\boldsymbol{\rho} \triangleq \begin{bmatrix} \tilde{\mathbf{y}} \\ \dot{\tilde{\mathbf{y}}} \\ \tilde{\mathbf{p}}_{\Delta} \end{bmatrix} \quad (3.23)$$

$$N_1 = \begin{bmatrix} \lambda^2 M + P & \lambda M & 0 \\ \lambda M & M & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3.24)$$

A derivada em função do tempo da função candidata a Lyapunov é expressa por

$$\dot{V} = M\dot{s}s + P\dot{\tilde{\mathbf{y}}}\tilde{\mathbf{y}} + \dot{\tilde{\mathbf{p}}}_{\Delta}\tilde{\mathbf{p}}_{\Delta}. \quad (3.25)$$

Substituindo agora as Equações (3.15) e (3.19) na (3.25), resulta

$$\dot{V} = (-K_D s - A\tilde{\mathbf{p}}_{\Delta} + \tilde{f}_a + \tilde{f}_e)s + P\dot{\tilde{\mathbf{y}}}\tilde{\mathbf{y}} + (-K_P\tilde{\mathbf{p}}_{\Delta} + As + \tilde{h}_n)\tilde{\mathbf{p}}_{\Delta} \quad (3.26)$$

que, simplificada, pode ser reescrita como:

$$\dot{V} = -K_D s^2 + P\dot{\tilde{\mathbf{y}}}\tilde{\mathbf{y}} - K_P\tilde{\mathbf{p}}_{\Delta}^2 + \tilde{f}_a s + \tilde{f}_e s + \tilde{h}_n\tilde{\mathbf{p}}_{\Delta} \quad (3.27)$$

Utilizando a combinação linear do erro de posição e velocidade (Equação (3.7)) obtém-se

$$\dot{V} = -K_D(\dot{\mathbf{y}} - \dot{\mathbf{y}}_r)^2 + P\dot{\tilde{\mathbf{y}}}\tilde{\mathbf{y}} - K_P\tilde{\mathbf{p}}_{\Delta}^2 + \tilde{f}_a s + \tilde{f}_e s + \tilde{h}_n\tilde{\mathbf{p}}_{\Delta} \quad (3.28)$$

Substituindo a expressão para a velocidade de referência (Equação (3.5)) na Equação (3.28), resulta

$$\dot{V} = -K_D(\dot{\mathbf{y}} - \dot{\mathbf{y}}_d + \lambda\tilde{\mathbf{y}})^2 + P\dot{\tilde{\mathbf{y}}}\tilde{\mathbf{y}} - K_P\tilde{\mathbf{p}}_{\Delta}^2 + \tilde{f}_a s + \tilde{f}_e s + \tilde{h}_n\tilde{\mathbf{p}}_{\Delta} \quad (3.29)$$

Usando agora a expressão para a derivada primeira no tempo do erro de posição (Equação (3.4)), tem-se:

$$\dot{V} = -K_D(\dot{\tilde{y}} + \lambda\tilde{y})^2 + P\dot{\tilde{y}}\tilde{y} - K_P\tilde{\rho}_\Delta^2 + \tilde{f}_a s + \tilde{f}_e s + \tilde{h}_n \tilde{\rho}_\Delta \quad (3.30)$$

$$\dot{V} = -K_D\dot{\tilde{y}}^2 + (P - 2K_D\lambda)\dot{\tilde{y}}\tilde{y} - \lambda^2 K_D\tilde{y}^2 - K_P\tilde{\rho}_\Delta^2 + \tilde{f}_a s + \tilde{f}_e s + \tilde{h}_n \tilde{\rho}_\Delta \quad (3.31)$$

Para simplificar a Equação (3.31) pode-se definir a constante P como:

$$P \triangleq 2K_D\lambda \quad (3.32)$$

resultando

$$\dot{V} = -K_D\dot{\tilde{y}}^2 - \lambda^2 K_D\tilde{y}^2 - K_P\tilde{\rho}_\Delta^2 + \tilde{f}_a s + \tilde{f}_e s + \tilde{h}_n \tilde{\rho}_\Delta \quad (3.33)$$

que está na forma

$$\dot{V} = -\boldsymbol{\rho}^T N_2 \boldsymbol{\rho} + \boldsymbol{\rho}^T \tilde{F}_a + \boldsymbol{\rho}^T \tilde{F}_e + \boldsymbol{\rho}^T \tilde{H}_n \quad (3.34)$$

com

$$N_2 \triangleq \begin{bmatrix} \lambda^2 K_D & 0 & 0 \\ 0 & K_D & 0 \\ 0 & 0 & K_P \end{bmatrix} \quad (3.35)$$

$$\tilde{F}_a \triangleq \begin{bmatrix} \tilde{f}_a \\ \lambda \tilde{f}_a \\ 0 \end{bmatrix} \quad (3.36)$$

$$\tilde{F}_e \triangleq \begin{bmatrix} \tilde{f}_e \\ \lambda \tilde{f}_e \\ 0 \end{bmatrix} \quad (3.37)$$

$$\tilde{H}_n \triangleq \begin{bmatrix} 0 \\ 0 \\ \tilde{h}_n \end{bmatrix} \quad (3.38)$$

3.4 Análise de Estabilidade - Caso Ideal

Considere o caso ideal, com o erro paramétrico nulo para a reconstrução da função h_n , bem como nulas as estimativas das forças externas e do atrito, tem-se:

$$\tilde{F}_a = \tilde{F}_e = \tilde{H}_n = \vec{0} \quad (3.39)$$

Desta forma, a Equação (3.34) resulta:

$$\dot{V} = -\rho^T N_2 \rho \quad (3.40)$$

Considerando agora o seguinte teorema do coeficiente de Rayleigh [Noble e Daniel, 1986]:

Teorema do coeficiente de Rayleigh (Rayleigh coefficient): Seja $A \in \mathbb{R}^{n \times n}$ uma matriz simétrica, positiva semi-definida com os seguintes autovalores $\lambda_1 \geq \dots \geq \lambda_n \geq 0$. Então, para todo $x \in \mathbb{R}^n$, $\lambda_n \leq \frac{x^T A x}{x^T x} \leq \lambda_1$, onde λ_i são os autovalores de A ordenados em ordem decrescente. Além disso, o lado direito se tornará uma igualdade, caso x seja o autovetor u_1 de A , correspondente ao maior autovalor λ_1 .

Então, segundo o teorema de Rayleigh

$$\underline{\lambda}_1 \rho^T \rho \leq \rho^T N_1 \rho \leq \overline{\lambda}_1 \rho^T \rho \quad (3.41)$$

$$\underline{\lambda}_2 \rho^T \rho \leq \rho^T N_2 \rho \leq \overline{\lambda}_2 \rho^T \rho \quad (3.42)$$

$$\underline{\lambda}_2 \rho^T \rho \leq \rho^T N_2 \rho \quad (3.43)$$

$$\rho^T N_1 \rho \leq \overline{\lambda}_1 \rho^T \rho \quad (3.44)$$

sendo $\underline{\lambda}_1$ e $\underline{\lambda}_2$ os menores autovalores e $\overline{\lambda}_1$ e $\overline{\lambda}_2$ os maiores autovalores de N_1 e N_2 , respectivamente. Definindo-se agora, a seguinte relação entre autovalores:

$$\gamma \triangleq \frac{\underline{\lambda}_2}{\underline{\lambda}_1} \quad (3.45)$$

A partir de (3.43),(3.44) e (3.45), tem-se:

$$\gamma \leq \frac{\boldsymbol{\rho}^T N_2 \boldsymbol{\rho}}{\boldsymbol{\rho}^T N_1 \boldsymbol{\rho}} \quad (3.46)$$

ou ainda,

$$\gamma \boldsymbol{\rho}^T N_1 \boldsymbol{\rho} \leq \boldsymbol{\rho}^T N_2 \boldsymbol{\rho} \quad (3.47)$$

Além disso, de (3.22) e (3.40), tem-se:

$$2\gamma V \leq -\dot{V} \quad (3.48)$$

$$\dot{V}(t) + 2\gamma V(t) \leq 0 \quad (3.49)$$

Considerando agora o Lema da simples convergência [Slotine e Li, 1991]

Lema da simples convergência: Se uma função real $W(t)$ satisfaz a inequação $\dot{W}(t) + \alpha W(t) \leq 0$ onde α é um número real, então $W(t) \leq W(0)e^{-\alpha t}$.

Pode-se escrever:

$$V(t) \leq V(0)e^{-2\gamma t} \quad (3.50)$$

A Equação (3.50) nos informa que a função $V(t)$ converge para exponencialmente para zero a uma taxa maior do que 2γ .

3.5 *Análise de Estabilidade - Caso com Erros Paramétricos e na Estimativa das Perturbações*

Para o caso em que as estimativas das forças externas e do atrito são não nulas bem como erro paramétrico para a reconstrução da função h_n , da Equação (3.34) tem-se:

$$\dot{V} = -\boldsymbol{\rho}^T N_2 \boldsymbol{\rho} + \boldsymbol{\rho}^T \tilde{F}_a + \boldsymbol{\rho}^T \tilde{F}_e + \boldsymbol{\rho}^T \tilde{H}_n \quad (3.51)$$

Como $\boldsymbol{\rho}^T \tilde{F}_a$, $\boldsymbol{\rho}^T \tilde{F}_e$ e $\boldsymbol{\rho}^T \tilde{H}_n$ são escalares, pode-se escrever:

$$-|\boldsymbol{\rho}^T \tilde{F}_a| \leq \boldsymbol{\rho}^T \tilde{F}_a \leq |\boldsymbol{\rho}^T \tilde{F}_a| \quad (3.52)$$

$$-|\boldsymbol{\rho}^T \tilde{F}_e| \leq \boldsymbol{\rho}^T \tilde{F}_e \leq |\boldsymbol{\rho}^T \tilde{F}_e| \quad (3.53)$$

$$-|\boldsymbol{\rho}^T \tilde{H}_n| \leq \boldsymbol{\rho}^T \tilde{H}_n \leq |\boldsymbol{\rho}^T \tilde{H}_n| \quad (3.54)$$

Considerando agora a inequação de Cauchy-Schwarz, enunciada como [Noble e Daniel, 1986]:

Inequação de Cauchy-Schwarz: Para todo x e $y \in \mathbb{R}^{n \times 1}$

$$|x^T y| \leq \|x\|_2 \|y\|_2$$

Pode-se escrever:

$$-\|\boldsymbol{\rho}\|_2 \|\tilde{F}_a\|_2 \leq |\boldsymbol{\rho}^T \tilde{F}_a| \leq \|\boldsymbol{\rho}\|_2 \|\tilde{F}_a\|_2 \quad (3.55)$$

$$-\|\boldsymbol{\rho}\|_2 \|\tilde{F}_e\|_2 \leq |\boldsymbol{\rho}^T \tilde{F}_e| \leq \|\boldsymbol{\rho}\|_2 \|\tilde{F}_e\|_2 \quad (3.56)$$

$$-\|\boldsymbol{\rho}\|_2 \|\tilde{H}_n\|_2 \leq |\boldsymbol{\rho}^T \tilde{H}_n| \leq \|\boldsymbol{\rho}\|_2 \|\tilde{H}_n\|_2 \quad (3.57)$$

Substituindo as inequações (3.55) a (3.57) nas inequações (3.52) a (3.54), tem-se:

$$-\|\boldsymbol{\rho}\|_2 \|\tilde{F}_a\|_2 \leq -|\boldsymbol{\rho}^T \tilde{F}_a| \leq \boldsymbol{\rho}^T \tilde{F}_a \leq |\boldsymbol{\rho}^T \tilde{F}_a| \leq \|\boldsymbol{\rho}\|_2 \|\tilde{F}_a\|_2 \quad (3.58)$$

$$-\|\boldsymbol{\rho}\|_2 \|\tilde{F}_e\|_2 \leq -|\boldsymbol{\rho}^T \tilde{F}_e| \leq \boldsymbol{\rho}^T \tilde{F}_e \leq |\boldsymbol{\rho}^T \tilde{F}_e| \leq \|\boldsymbol{\rho}\|_2 \|\tilde{F}_e\|_2 \quad (3.59)$$

$$-\|\boldsymbol{\rho}\|_2 \|\tilde{H}_n\|_2 \leq -|\boldsymbol{\rho}^T \tilde{H}_n| \leq \boldsymbol{\rho}^T \tilde{H}_n \leq |\boldsymbol{\rho}^T \tilde{H}_n| \leq \|\boldsymbol{\rho}\|_2 \|\tilde{H}_n\|_2 \quad (3.60)$$

Portanto:

$$\boldsymbol{\rho}^T \tilde{F}_a \leq \|\boldsymbol{\rho}\|_2 \|\tilde{F}_a\|_2 \quad (3.61)$$

$$\boldsymbol{\rho}^T \tilde{F}_e \leq \|\boldsymbol{\rho}\|_2 \|\tilde{F}_e\|_2 \quad (3.62)$$

$$\boldsymbol{\rho}^T \tilde{H}_n \leq \|\boldsymbol{\rho}\|_2 \|\tilde{H}_n\|_2 \quad (3.63)$$

Agora, usando novamente o teorema de Rayleigh, tem-se:

$$\boldsymbol{\rho}^T N_2 \boldsymbol{\rho} \geq \underline{\lambda}_2 \boldsymbol{\rho}^T \boldsymbol{\rho} \quad (3.64)$$

ou

$$-\boldsymbol{\rho}^T N_2 \boldsymbol{\rho} \leq -\underline{\lambda}_2 \boldsymbol{\rho}^T \boldsymbol{\rho} \quad (3.65)$$

Utilizando agora as inequações (3.61)-(3.63) e aplicando a inequação (3.65) em (3.51), resulta na seguinte inequação para a derivada da função candidata Lyapunov

$$\dot{V} \leq -\underline{\lambda}_2 \boldsymbol{\rho}^T \boldsymbol{\rho} + \|\boldsymbol{\rho}\|_2 \|\tilde{F}_a\|_2 + \|\boldsymbol{\rho}\|_2 \|\tilde{F}_e\|_2 + \|\boldsymbol{\rho}\|_2 \|\tilde{H}_n\|_2 \quad (3.66)$$

Supondo que exista um limite superior $\|\tilde{F}_a\|_2 \leq \bar{F}_a$, $\|\tilde{F}_e\|_2 \leq \bar{F}_e$, $\|\tilde{H}_n\|_2 \leq \bar{H}_n$ para a norma dos vetores \tilde{F}_a , \tilde{F}_e e \tilde{H}_n , tem-se, portanto:

$$\dot{V} \leq -\underline{\lambda}_2 \boldsymbol{\rho}^T \boldsymbol{\rho} + \bar{F}_a \|\boldsymbol{\rho}\|_2 + \bar{F}_e \|\boldsymbol{\rho}\|_2 + \bar{H}_n \|\boldsymbol{\rho}\|_2 \quad (3.67)$$

E, a partir da definição de norma euclidiana de dois vetores

$$\|\boldsymbol{\rho}\|_2 = (\boldsymbol{\rho}^T \boldsymbol{\rho})^{\frac{1}{2}} \quad (3.68)$$

ou

$$\boldsymbol{\rho}^T \boldsymbol{\rho} = \|\boldsymbol{\rho}\|_2^2 \quad (3.69)$$

Aplicando agora a equação (3.69) na (3.67), tem-se:

$$\dot{V} \leq -\underline{\lambda}_2 \|\boldsymbol{\rho}\|_2^2 + \bar{F}_a \|\boldsymbol{\rho}\|_2 + \bar{F}_e \|\boldsymbol{\rho}\|_2 + \bar{H}_n \|\boldsymbol{\rho}\|_2 \quad (3.70)$$

ou

$$\dot{V} \leq \left(-\underline{\lambda}_2 \|\boldsymbol{\rho}\|_2 + \bar{F}_a + \bar{F}_e + \bar{H}_n \right) \|\boldsymbol{\rho}\|_2 \quad (3.71)$$

Assim, para que \dot{V} seja negativa, i.e. $\dot{V} < 0$, basta que:

$$\dot{V} \leq \left(-\underline{\lambda}_2 \|\boldsymbol{\rho}\|_2 + \bar{F}_a + \bar{F}_e + \bar{H}_n \right) \|\boldsymbol{\rho}\|_2 < 0, \quad (3.72)$$

ou seja:

$$-\underline{\lambda}_2 \|\boldsymbol{\rho}\|_2 + \bar{F}_a + \bar{F}_e + \bar{H}_n < 0 \quad (3.73)$$

Assim, uma condição suficiente para que \dot{V} seja negativa definida é

$$\|\boldsymbol{\rho}\|_2 > \frac{\bar{F}_a + \bar{F}_e + \bar{H}_n}{\underline{\lambda}_2} \quad (3.74)$$

A inequação (3.74) indica que existe uma região compacta para a norma do vetor dos erros $\boldsymbol{\rho}$, fora da qual a derivada da função Lyapunov se torna negativa, fazendo com que o vetor dos erros convirja novamente para dentro desta região compacta. O tamanho desta região depende diretamente dos erros das estimativas das forças de atrito e externa, do erro paramétrico na estimação da função h_n e inversamente dos ganhos λ , K_d e K_p que compõem os termos da matriz N_2 .

4 RESULTADOS DE SIMULAÇÕES E EXPERIMENTOS

Neste capítulo são apresentados resultados obtidos por meio de simulações e de testes realizados na bancada experimental. As simulações foram realizadas utilizando o modelo pneumático neural descrito no Capítulo 2, enquanto os experimentos foram realizados na bancada experimental descrita na Seção 2.1. O tempo de ciclo de controle utilizado em ambos os casos é de 1 ms.

4.1 Trajetórias de Referência

As trajetórias de referências utilizadas nas simulações e testes experimentais dos controladores em malha fechada estão descritas nesta seção. Estas trajetórias foram selecionadas de forma que os resultados do presente estudo possam ser comparados com os de trabalhos prévios realizados em bancadas semelhantes [Perondi, 2002; Sobczyk, 2009; Suzuki, 2010].

Assim, foram utilizadas duas trajetórias distintas: uma senoidal descrita por

$$y_r(t) = Y_{max} \text{sen}(\omega t) \quad (4.1)$$

onde Y_{max} é uma constante com o valor da amplitude máxima da trajetória em cada direção e ω é a sua frequência. Os valores numéricos utilizados são $Y_{max} = 0,45$ m e $\omega = 2$ rad/s.

Outra trajetória utilizada é a formada por segmentos polinomiais de 7ª ordem, com a seguinte estrutura:

$$y_r(t) = \begin{cases} y_{aux}(t/2) - 0,4 & 0 \leq t < 2 \\ 0,4 & 2 \leq t < 4 \\ -y_{aux}((t-4)/2) + 0,4 & 4 \leq t < 6 \\ -0,4 & 6 \leq t < 8 \end{cases} \quad (4.2)$$

onde,

$$y_{aux}(t) = -16t^7 + 56t^6 - 67,2t^5 + 28t^4 \quad (4.3)$$

A função de referência senoidal permite avaliar o erro no seguimento de trajetórias, enquanto a referência polinomial permite tanto uma avaliação das características do

controlador aplicado ao seguimento da trajetória quanto do seu erro de regime. Cabe salientar que o seguimento suave das trajetórias de referência, consiste em um grande desafio no controle de sistemas pneumáticos, principalmente quando é utilizado para pequenas cargas. Esta condição será discutida ao longo deste trabalho, à medida que os resultados forem sendo apresentados.

4.2 Comparação entre o modelo pneumático neural e experimento em bancada com ambos em Malha Fechada

Primeiramente serão apresentados os resultados de comparações em malha fechada para o modelo pneumático por serem considerados de menor importância para a validação do modelo em relação aos resultados de simulações em malha aberta para o modelo. Pois resultados em malha fechada tendem esconder defeitos na modelagem.

Nesta seção são apresentados e discutidos os resultados em malha fechada para uma referência senoidal, obtidos por meio de simulações utilizando o modelo pneumático neural e os resultados experimentais obtidos na bancada para o caso de aplicação de uma estratégia de controle proporcional para a posição.

Em todos os experimentos, foram utilizados filtros *butterworth* passa-baixas de primeira ordem nos sinais dos sensores de posição do êmbolo e de pressões nas câmaras p_1 e p_2 com um corte de frequência de 250 rad/s, 150 rad/s, 150 rad/s respectivamente.

A estratégia de controle utilizada tanto em simulação quanto para a obtenção dos resultados experimentais foi, portanto

$$u(t) = -K_p(y_r(t) - y(t)) \quad (4.4)$$

onde $u(t)$ é a tensão elétrica de controle, $y_r(t)$ é a trajetória de referência, $y(t)$ é a posição do êmbolo e K_p a constante de ganho de controle com valor $K_p = 6$. Este controlador possui limitações para a aplicação proposta, sendo estes testes realizados principalmente para permitir a avaliação da capacidade das redes neurais em prever (generalizar ou extrapolar em linguagem de redes neurais) resultados ainda não treinados. Esse valor de ganho não foi utilizado para a obtenção dos padrões de treinamentos das redes neurais, principalmente para

verificar o desempenho da rede na generalização de padrões não treinados. Nos treinamentos os valores usados foram $K_p = 4$ e $K_p = 10$.

A Figura 4.1 apresenta uma simulação em malha fechada realizada com o modelo pneumático neural. O objetivo desta simulação é verificar se os resultados obtidos para as amplitudes das variáveis são semelhantes as dos experimentos práticos realizados na bancada utilizando o mesmo ganho de controle.

Na Figura 4.1 é apresentado o resultado das simulações para a posição do êmbolo do cilindro atuador e seu erro com relação à referência senoidal. Na Figura 4.2 é apresentado o resultado obtido na bancada experimental para a posição do êmbolo (y) e seu respectivo erro com relação à mesma referência senoidal. Analisando ambos os gráficos, verifica-se que tanto a simulação como o resultado experimental possuem valores de amplitudes máximas semelhantes, resultando em um erro de seguimento de trajetória de aproximadamente 15 cm nos valores de pico.




Figura 4.1 – Posição do êmbolo do cilindro atuador e seu respectivo erro em simulação para sinal de controle proporcional (MF) e referência senoidal

A Figura 4.3 apresenta o resultado de simulação para a velocidade do êmbolo do cilindro atuador e o sinal calculado por meio da lei de controle em malha fechada na simulação. Já, na Figura 4.4 é apresentado o resultado obtido na bancada experimental para a velocidade do êmbolo (\dot{y}) e o sinal calculado por meio da lei de controle (u) em malha fechada nos experimentos. Verifica-se novamente que as amplitudes dos sinais de velocidade

e de controle são compatíveis, pois o modelo pneumático neural consegue representar o comportamento do sistema físico real.




Figura 4.2 – Posição do êmbolo do cilindro atuador e seu respectivo erro experimental para sinal de controle proporcional (MF) e referência senoidal




Figura 4.3 – Velocidade do êmbolo e sinal de controle em simulação (MF) para referência senoidal

Os gráficos apresentando as curvas das pressões nas câmaras do cilindro do atuador (p_1 e p_2) podem ser visualizados na Figura 4.5, enquanto os resultados obtidos nos experimentos estão na Figura 4.6. Verificou-se que os sinais de pressão apresentam amplitudes com valores semelhantes para ambas as câmaras.




Figura 4.4 – Velocidade do êmbolo e sinal de controle experimental (MF) para referência senoidal




Figura 4.5 – Pressões nas câmaras p_1 e p_2 em simulação (MF) para referência senoidal




Figura 4.6 – Pressões nas câmaras p_1 e p_2 experimental (MF) para referência senoidal

4.3 Comparação entre experimento em bancada em malha fechada e modelo pneumático neural em malha aberta para referência senoidal

Tendo em vista que simulações em malha fechada podem compensar e assim encobrir possíveis erros na modelagem, serão apresentados a seguir resultados de simulações em malha aberta, utilizando como sinal de controle os mesmos sinais aplicados na bancada experimental e salvos em arquivo. Desta forma, a simulação será agora realizada em malha aberta e o modelo pneumático neural terá como sinal de entrada os mesmos valores numéricos gerados pelo controlador P nos experimentos realizados na bancada pneumática em malha fechada. Assim, as simulações, apesar de serem realizadas em malha aberta, respondem a um sinal de controle calculado experimentalmente em malha fechada. Com isso, as respostas dos experimentos realizados em malha fechada podem ser comparadas com as respostas das simulações realizadas, por sua vez, em malha aberta.

A Figura 4.7 apresenta o sinal de controle calculado no experimento realizado na bancada e salvo em arquivo digital. Esse sinal foi posteriormente aplicado como controle em malha aberta na realização de simulação.




Figura 4.7 – Sinal de controle calculado em experimento de bancada e aplicado em MF no mesmo experimento, o qual foi salvo em arquivo digital e aplicado como controle em MA na simulação

A Figura 4.8 apresenta os resultados de posição do atuador pneumático do experimento na bancada em malha fechada sobrepostos com o das simulações do modelo em malha aberta usando os valores de controle calculados em tempo real na bancada pneumática. Verifica-se que o modelo consegue reproduzir de forma adequada os resultados obtidos

experimentalmente, podendo-se concluir que o modelo consegue ter prever uma estimativa da resposta em posição do êmbolo do cilindro pneumático experimental.




Figura 4.8 – Comparação de resultados experimental (MF) e em simulação (MA) para a posição do êmbolo

Os resultados obtidos por meio de simulação e de experimentos para a velocidade do êmbolo do cilindro são apresentados na Figura 4.9. Com base nestes resultados verifica-se uma semelhança entre os valores numéricos das mesmas bem como nas frequências de oscilação.




Figura 4.9 – Comparação de resultados experimental (MF) e em simulação (MA) para a velocidade do êmbolo

As Figuras 4.10 e 4.11 apresentam os resultados de simulação e experimento para as pressões nas câmaras do cilindro atuador (p_1 e p_2). Verifica-se que os gráficos apresentam resultados com amplitudes de ordem semelhante de grandeza para as pressões nas câmaras.




Figura 4.10 – Comparação de resultados experimental (MF) e em simulação do modelo pneumático neural (MA) para a pressão na câmara p_1




Figura 4.11 – Comparação de resultados experimental (MF) e em simulação do modelo pneumático neural (MA) para a pressão na câmara p_2

Conforme anteriormente afirmado, o ganho do sinal de controle escolhido para comparar os resultados não foi utilizado no treinamento das redes neurais, mostrando a capacidade de generalização das redes neurais treinadas e utilizadas nas simulações (atrito e vazões mássicas). A mesma rede neural treinada para a identificação do atrito e utilizada no

modelo foi aplicada no esquema de compensação do mesmo em tempo real no algoritmo de controle Cascata Neural.

Com base nos resultados apresentados nas Figuras 4.8 a 4.11, pode-se concluir que o modelo neural do atuador pneumático apresenta resultados satisfatórios na reprodução por simulação do comportamento do sistema real, podendo, portanto, ser usada na determinação inicial dos ganhos dos controladores utilizados nos experimentos, conforme apresentados nas seções que seguem.

4.4 Resultados experimentais do controlador $PV\Delta P$

Nesta seção são analisados e comparados os resultados experimentais em malha fechada com os de simulações realizadas por meio do modelo neural em malha aberta utilizando uma estratégia de controle $PV\Delta P$.

A estratégia de controle tipo $PV\Delta P$ é apresentada por meio da Equação (4.5)

$$u(t) = -K_p(y_r(t) - y(t)) - K_v(\dot{y}_r(t) - \dot{y}(t)) - K_{p\Delta}(p_{\Delta r}(t) - p_{\Delta}(t)) \quad (4.5)$$

onde \dot{y}_r é a velocidade de referência, \dot{y} é a velocidade do êmbolo, $p_{\Delta r}$ é a diferença de pressão desejada calculada por meio da lei de Slotine e Li (Equação 3.12), p_{Δ} é a diferença entre as pressões nas câmaras, K_p é a constante de ganho em posição, K_v é a constante de ganho em velocidade e $K_{p\Delta}$ é a constante de ganho em diferença de pressão. Os ganhos utilizados estão apresentados na Tabela 4.1.

Tabela 4.1 – Ganhos utilizados no controlador $PV\Delta P$

K_p	K_v	$K_{p\Delta}$
65	2	4×10^{-5}

As Figuras 4.12 a 4.14 apresentam os resultados em malha fechada para uma referência senoidal usando a estratégia de controle $PV\Delta P$ sobrepostos com os resultados da simulação usando o modelo neural em malha aberta.

Para a obtenção desses resultados procedeu-se da mesma forma que na Seção 4.3. Primeiramente foram realizados os experimentos em bancada usando o controle $PV\Delta P$ em malha fechada. Os valores numéricos dos sinais de controle aplicados nos experimentos foram salvos e aplicados posteriormente em malha aberta como sinal de entrada no modelo neural.

A Figura 4.12 apresenta a curva de posição obtida experimentalmente em malha fechada para uma referência senoidal sobreposta com a curva de posição fornecida pelo modelo em malha aberta. Os gráficos apresentam valores de pico de aproximadamente 3 cm para o experimental erro de posição. A sobreposição dos resultados do experimento em malha fechada com os da simulação em malha aberta serve, mais uma vez, para avaliar o modelo neural apresentado no Capítulo 2.




Figura 4.12 – Comparação entre posições do êmbolo experimental (controle $PV\Delta P$ com trajetória senoidal) e em simulação em malha aberta do modelo, bem como seus respectivos erros

A Figura 4.13 apresenta os gráficos para as velocidades e sinal de controle aplicado em experimento e simulação. No gráfico das velocidades verifica-se uma boa semelhança entre as frequências da curva experimental e da obtida na simulação. Os ganhos do controlador foram escolhidos de forma que o sinal de controle não apresentasse comportamentos de alta frequência que excitassem as dinâmicas (não modeladas) da válvula de controle. Em resultados experimentais realizados com valores de ganhos maiores verificou-se a presença de oscilações com maiores amplitudes principalmente no sinal de velocidade.




Figura 4.13 – Velocidades e sinal de controle experimental $PV\Delta P$ e em simulação em malha aberta para trajetória de referência senoidal

Os gráficos com a sobreposição dos resultados de experimento e do modelo para as pressões nas câmaras são apresentados na Figura 4.14.




Figura 4.14 – Pressões nas câmaras do atuador experimental $PV\Delta P$ e em simulação em malha aberta para trajetória de referência senoidal

As Figuras 4.15 a 4.17 apresentam resultados experimentais em malha fechada para uma referência polinomial utilizando a estratégia de controle $PV\Delta P$, sobrepostos com os resultados obtidos em simulação por meio do modelo neural em malha aberta.

A Figura 4.15 apresenta a trajetória de posição obtida experimentalmente em malha fechada para uma referência polinomial juntamente com a trajetória de posição obtida por meio de simulação em malha aberta.




Figura 4.15 – Comparação entre posições do êmbolo experimental (controle $PV\Delta P$ com trajetória polinomial) e em simulação em malha aberta do modelo, bem como seus respectivos erros

A Figura 4.16 apresenta os gráficos para as velocidades e para o sinal de controles no experimento e na simulação.




Figura 4.16 – Velocidades e sinal de controle experimental $PV\Delta P$ e em simulação em malha aberta para trajetória de referência polinomial

Os gráficos com a sobreposição dos resultados experimentais e de simulações para as pressões nas câmaras são apresentados na Figura 4.17. Pode-se notar através das curvas das pressões nas câmaras, quando o êmbolo está parado, que ocorre um esvaziamento das câmaras

por efeito principalmente de vazamentos na servoválvula. A ocorrência deste fenômeno também nas simulações indica que o modelo pneumático neural conseguiu através do treinamento, considerar este efeito, mesmo sem ter sido realizado qualquer procedimento específico para a identificação deste efeito




Figura 4.17 – Pressões nas câmaras do atuador experimental $PV\Delta P$ e em simulação em malha aberta para trajetória de referência polinomial

Com base nas Figuras 4.12 e 4.15 percebe-se a ocorrência de um erro máximo de aproximadamente 3 cm no seguimento de trajetórias e menores que 2 cm no erro ponto a ponto para a estratégia de controle $PV\Delta P$.

Nas próximas seções serão apresentados apenas os resultados experimentais obtidos através da aplicação do controlador cascata neural proposto no Capítulo 3.

4.5 Resultados do controlador Cascata Neural com compensação de atrito

Nesta seção são apresentados os resultados experimentais, utilizando o controlador Cascata Neural descrito no Capítulo 3, o qual realiza a compensação do atrito por meio de estimativas realizadas por redes neurais. Os ganhos utilizados nos testes com o controlador Cascata Neural estão apresentados na Tabela 4.2.

Tabela 4.2 – Ganhos utilizados no controlador Cascata Neural

K_p	K_d	λ
180	10	36

Esses ganhos foram obtidos através simulações em experimentos com diferentes tipos de trajetórias. É possível verificar com base na Figura 4.18 que o erro no seguimento de trajetória mantém-se inferior a 1,5 cm. É importante salientar que o atuador opera sem massa na carga, ou seja, sua massa total é de 293,15 g, que corresponde ao êmbolo do pistão. Esta situação dificulta o seguimento de trajetórias, principalmente em baixas velocidades, estando, provavelmente, associada à relação entre a força de atrito e a força inercial, resultando no fato de que a força aplicada apresentar valores próximos aos da força estimada de atrito (como será mostrado na Figura 4.21), o que, devido à sua natureza (altamente não-linear), com fatos estocásticos e variantes no tempo, é difícil de controlar. Esta afirmação pode ser comprovada na Seção 4.8, onde são apresentados os resultados com a adição de massa de 5 kg.




Figura 4.18 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência senoidal

A Figura 4.19 apresenta os gráficos da velocidade e do sinal de controle aplicado. Destaca-se o baixo nível de sinais de altas frequências tanto na velocidade quanto no controle, permitindo que o movimento seja suave.




Figura 4.19 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência senoidal

A Figura 4.20 apresenta as pressões nas câmaras p_1 e p_2 , bem como o sinal s da combinação linear dos erros de posição e velocidade utilizado pelo controlador.




Figura 4.20 – Pressões nas câmaras p_1 e p_2 experimental e sinal de erro s para o controlador cascata neural com trajetória de referência senoidal

Os gráficos sobrepostos do sinal da força desejada calculada pela lei de Slotine e Li (que corresponde à força total desejada incluindo a estimativa neural do atrito), da força aplicada e da estimativa da força de atrito estão apresentados na Figura 4.21.




Figura 4.21 – Força desejada calculada pela lei de Slotine e Li em relação à força aplicada e respectivo erro em força experimental para o controlador cascata neural com trajetória de referência senoidal

Conforme mencionado, o sinal da estimação da força de atrito apresenta valores próximos ao da força aplicada. Verifica-se que o erro no seguimento de força mantém-se abaixo de 10 N. A Figura 4.22 apresenta as estimativas \hat{h}_n e \hat{u}_n e a estimativa da derivada da força de atrito \hat{f}_a via redes neurais alguns dos sinais utilizados pelo controlador Cascata Neural.




Figura 4.22 – Variáveis \hat{h}_n , \hat{u}_n e \hat{f}_a utilizadas no controlador cascata neural com trajetória de referência senoidal

Com base nas Figuras 4.18 a 4.22 é possível verificar que o controlador Cascata Neural consegue seguir seguimentos de trajetórias senoidais com erros inferiores a 1,5 cm de forma suave, isto é, sem excitar altas frequências no sistema.

As Figuras 4.23 a 4.27 apresentam o desempenho da estratégia de controle Cascata Neural para uma referência do tipo polinomial. Essa escolha foi realizada visando facilitar a análise do desempenho do Controlador Neural em uma aplicação que se aproxima de um problema de controle ponto a ponto.

A Figura 4.23 apresenta o resultado de seguimento de trajetória polinomial de sétima ordem, conforme descrito na Seção 4.1. Verifica-se que o controlador apresenta desempenho satisfatório no seguimento da trajetória polinomial, com erro máximo de aproximadamente 1,1 cm no seguimento de trajetórias e menores que 6 mm no erro ponto a ponto. A Figura 4.24 apresenta os gráficos de velocidade e de sinal de controle aplicado. Novamente, a estratégia de controle apresenta baixo nível de sinais de alta frequência no controle e no sinal de velocidade do êmbolo do atuador pneumático. Na Figura 4.25 são apresentadas as pressões nas câmaras p_1 e p_2 , bem como o sinal de combinação linear dos erros de posição e velocidade s utilizado pelo controlador.




Figura 4.23 – Posição do êmbolo e seu respectivo erro *experimental* para o controlador cascata neural com trajetória de referência polinomial




Figura 4.24 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência polinomial




Figura 4.25 – Pressões nas câmaras p_1 e p_2 experimental e sinal de erro s para o controlador cascata neural com trajetória de referência polinomial

A superposição dos sinais da força desejada (calculada pela lei de Slotine e Li) com o da força aplicada está apresentada na Figura 4.26. Verifica-se que o erro do seguimento de força ficou abaixo de 8 N.




Figura 4.26 – Força desejada calculada pela lei de Slotine e Li em relação à força aplicada e respectivo erro em força experimental para o controlador cascata neural com trajetória de referência polinomial

A Figura 4.27 apresenta as estimativas \hat{h}_n e \hat{u}_n e a derivada da força de atrito estimada \hat{f}_a via redes neurais.




Figura 4.27 – Variáveis \hat{h}_n , \hat{u}_n e \hat{f}_a utilizadas no controlador cascata neural com trajetória de referência polinomial

Com base nas Figuras 4.23 a 4.27 é possível verificar que o controlador Cascata Neural consegue seguir seguimentos para uma referência tipo polinomial com erros inferiores a 1,2 cm, sem excitar altas frequências no sistema.

4.6 Resultados do controlador Cascata Neural sem compensação de Atrito

Como forma de mostrar a importância da compensação do atrito no desempenho da estratégia de controle serão apresentados a seguir os resultados com o controlador Cascata Neural sem a compensação de atrito. É importante salientar que a estratégia de controle Cascata Neural utiliza três redes neurais, uma para a estimação das forças do atrito, outra para a estimação da derivada do atrito e uma última para o cálculo da inversa do sinal de controle. Os resultados apresentados a seguir são, portanto, referentes à estratégia de controle utilizando uma rede neural, apenas para o cálculo da inversa do sinal de controle.

Os ganhos utilizados são os mesmos que estão apresentados na Tabela 4.2. A Figura 4.28 apresenta o resultado da aplicação da estratégia de controle Cascata Neural sem a compensação de atrito. Pode-se perceber, com base nos resultados apresentados na Figura 4.28, que o erro no seguimento de trajetória resultou mais elevado (na ordem dos 15 cm) do que os obtidos anteriormente. Estes resultados poderiam ser melhores com uma melhor seleção nos ganhos do controlador. Em [Perondi, 2002] após um ajuste de ganhos o controlador cascata sem compensação de atritos apresentou erros na ordem de 10 cm para o seguimento da mesma trajetória senoidal e massa de aproximadamente 3 kg. É importante destacar que o experimento aqui apresentado possui uma carga com cerca de 10% da utilizada em [Perondi, 2002].




Figura 4.28 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência senoidal sem compensação de atrito

A Figura 4.29 apresenta os gráficos para a velocidade e sinal de controle aplicado. Com a retirada da compensação do atrito, pode-se perceber a presença de componentes de altas frequências no sinal de controle, além da ocorrência do fenômeno stick-slip, devido ao atrito, de forma mais acentuada.




Figura 4.29 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência senoidal sem compensação de atrito

Uma comparação entre a força desejada calculada pela lei de Slotine e Li e a força aplicada é feita a partir dos resultados apresentados na Figura 4.30. O erro de seguimento de força ficou abaixo de 6 N, apesar do erro em posição ser elevado. Isto mostra que o controlador cascata possui boa capacidade de seguimento de força, e que o erro de posição ocorre principalmente por conta de a força desejada não garantir uma compensação adequada do atrito.




Figura 4.30 – Força desejada calculada pela lei de Slotine e Li em relação à força aplicada e respectivo erro em força experimental para o controlador cascata neural com trajetória de referência senoidal sem compensação de atrito

O gráfico relativo ao seguimento da trajetória polinomial utilizando a estratégia Cascata Neural sem a compensação explícita do atrito é apresentado na Figura 4.31. Neste caso, as respostas do controlador sem compensação explícita mostram-se com erros maiores do que com compensação. Observa-se que o erro de regime para este tipo de trajetória ficou em torno de 10 cm.




Figura 4.31 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência polinomial sem compensação explícita de atrito

A Figura 4.32 apresenta os gráficos para a velocidade e sinal de controle aplicado. Também é verificado um sinal de controle com maior intensidade de componentes de altas frequências em comparação com o obtido utilizando o controlador Cascata Neural com compensação de atrito.




Figura 4.32 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência polinomial sem compensação de atrito

A superposição das curvas da força desejada calculada pela lei de Slotine e Li e a força aplicada é apresentada na Figura 4.33. Verifica-se que o sinal fica contaminado por componentes de alta frequência, o que é indesejável, pois em situações extremas, estas podem excitar dinâmicas não modeladas, podendo, inclusive, levar o sistema a instabilidade.




Figura 4.33 – Força desejada calculada pela lei de Slotine e Li em relação à força aplicada e respectivo erro em força experimental para o controlador cascata neural com trajetória de referência senoidal sem compensação de atrito

4.7 Resultados do controlador Cascata Neural com compensação de Atrito e adição de massa

Conforme já comentado, visando a avaliar as características do controlador com compensação explícita do atrito proposto foi adicionada uma massa de 5 kg como carga a ser movimentada pelo o êmbolo do cilindro atuador. As respostas apresentadas nas Figuras 4.34 a 4.39, foram obtidas utilizando os valores dos ganhos apresentados na Tabela 4.2. Desta forma, é possível avaliar a robustez da estratégia proposta frente a uma expressiva variação da massa deslocada.

A Figura 4.34 apresenta o resultado experimental da posição do êmbolo do atuador usando o controlador Cascata Neural com compensação de atrito e com a adição de carga com massa de 5 kg, no seguimento de uma referência senoidal. Com base nas Figuras 4.18 e 4.34, é possível concluir que o controlador consegue seguir a trajetória desejada de forma semelhante em ambos os casos, mas com um pequeno incremento do erro de seguimento de trajetória.

A Figura 4.35 apresenta os gráficos da velocidade e do sinal de controle aplicado, os quais apresentam um baixo nível de oscilação de altas frequências.

Com base nos resultados apresentados, é possível afirmar que o controlador desenvolvido apresenta características favoráveis com relação a robustez quanto à variação paramétrica da carga deslocada, sendo esta uma característica muito importante para sistemas robóticos e manipuladores em geral, pois essa variação de carga deslocada é uma situação operacional muito comum nas aplicações industriais.




Figura 4.34 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência senoidal e adição de massa




Figura 4.35 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência senoidal e adição de massa




Figura 4.36 – Forças e respectivo erro para o controlador cascata neural com trajetória de referência senoidal e adição de massa

Resultados com adição de carga e referência polinomial estão apresentados nas Figuras 4.37 a 4.39. Os resultados relativos aos erros de regime mostram-se melhores do que os obtidos nos experimentos sem carga adicional conforme pode ser observado na Figura 4.37, verificando-se que o erro máximo de regime é da ordem de 2 mm.




Figura 4.37 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência polinomial e adição de massa

Observando o gráfico da velocidade apresentado na Figura 4.38 é possível perceber que o movimento é relativamente suave e que o sinal de controle não apresenta componentes significativas de altas frequências. A Figura 4.39 apresenta as curvas de seguimento de força com adição de carga para a trajetória desejada polinomial.

Conforme destacado no início desta seção, os ganhos utilizados nos experimentos apresentados até o momento com carga adicional de 5 kg são os mesmos sintonizados para sistema sem carga adicional. A seguir são apresentados os resultados com carga adicional com os ganhos ajustados para um melhor desempenho nessa situação.




Figura 4.38 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência polinomial e adição de massa




Figura 4.39 – Forças e respectivo erro para o controlador cascata neural com trajetória de referência polinomial e adição de massa

4.8 Resultados do controlador Cascata Neural com compensação de atrito com adição de massa com aumento nos ganhos

Na Seção 4.7 foram apresentados os resultados experimentais referentes à situação de adição de massa de carga de 5 kg sem que houvesse um ajuste nos ganhos do controlador. Nesta seção serão apresentados os resultados referentes à situação em que foi realizado um ajuste de ganhos nos parâmetros do controlador Cascata Neural com a compensação de atrito. O objetivo desta seção é mostrar que o controle de sistemas pneumáticos pode ser favorecido

com o aumento da carga movimentada em problemas de seguimento de trajetória. Os ganhos do controlador utilizados nos experimentos estão apresentados na Tabela 4.3.

Tabela 4.3 – Ganhos modificados utilizados no controlador Cascata Neural

K_p	K_d	λ
250	7	250

A Figura 4.40 apresenta o gráfico da resposta de posição e seu respectivo erro de seguimento de trajetória com o novo ajuste dos ganhos do controlador Cascata Neural com compensação de atrito. Pode-se observar com base nos resultados a ocorrência de uma redução no erro de seguimento de trajetória quando comparados com os da Figura 4.18 referente ao caso sem acréscimo de massa, onde os erros de pico atingiram valores de até 1,4 cm.




Figura 4.40 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência senoidal e adição de massa com ganhos modificados

Os gráficos da velocidade e de sinal de controle estão apresentados na Figura 4.41.




Figura 4.41 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência senoidal e adição de massa com ganhos modificados

Apesar de a velocidade não apresentar oscilações significativas, verifica-se a presença de componentes indesejáveis de altas frequências no sinal de controle, as quais podem excitar dinâmicas não modeladas. As forças calculadas e o respectivo erro são mostrados na Figura 4.42. Da mesma forma que os resultados dos testes anteriormente apresentados, no presente caso os erros máximos de seguimento de força ficaram em cerca de 10 N. Conforme discutido anteriormente, pode-se atribuir as melhorias dos resultados com o aumento de massa ao efeito benéfico da relação força inercial/atrito necessárias para o seguimento de trajetória. Verifica-se que quanto maior a carga transportada, maior essa relação e melhores os resultados, fato este que foi verificado em diferentes testes experimentais para diferentes massas.

No Apêndice IV são ainda apresentados os resultados do controlador Cascata Neural com compensação de atritos aplicado ao controle de seguimento de trajetória do 1º grau de liberdade de um robô cilíndrico pneumático de cinco graus de liberdade acionado pneumáticamente. A descrição detalhada deste robô e do aparato de instrumentação e controle pode ser encontrada em [Rijo, 2013]. Os resultados apresentados no Apêndice IV mostram que a aplicação da estratégia desenvolvida no âmbito desta tese de doutorado é promissora para aplicações em robôs pneumáticos, tendo apresentado erro de seguimento medido no atuador da ordem de 5 mm para um seguimento de referência senoidal de curso de 25 cm (pico a pico) sem carga. Foram obtidos ao longo do trabalho mais de uma centena de resultados experimentais para o Controlador Cascata Neural, em diversas situações (variações

na carga, variações nas pressões de suprimento, variações nas trajetórias de referência em amplitude e frequência, etc.), mantendo sempre o desempenho e robustez.




Figura 4.42 – Forças e respectivo erro para o controlador cascata neural com trajetória de referência senoidal e adição de massa com ganhos modificados

5 CONCLUSÕES

Além dos problemas intrínsecos ao controle dos servoposicionadores pneumáticos, a revisão bibliográfica indicou também que a identificação de parâmetros de características estáticas dos sistemas pneumáticos é também trabalhosa. Para superar essas dificuldades foi proposta um procedimento para identificar as principais não-linearidades do sistema pneumático por meio do uso de redes neurais. Os gráficos obtidos e apresentados comparando resultados de simulação do modelo com os resultados obtidos em experimentos em uma bancada de testes indicam que o modelo obtido através do procedimento proposto é adequado para auxiliar em tarefas como análise do sistema, sintonia dos ganhos dos controladores e aplicação em leis de controle baseadas em modelo. Assim, com base nos resultados obtidos em malha aberta e malha fechada para o modelo neural desenvolvido, pode-se concluir que a estratégia escolhida para a modelagem do sistema pneumático é válida (atingindo, assim, com sucesso um dos principais objetivos específicos propostos).

O controlador em malha fechada baseado em uma estratégia em cascata com compensação e atrito proposto para o sistema pneumático (denominado como Cascata Neural) mostrou resultados promissores no seguimento de trajetórias harmônicas e polinomiais, além de, conforme o resultado da análise de Lyapunov para o controlador proposto, apresentar características de estabilidade, mesmo na presença de erros paramétricos.

As comparações dos resultados do Controlador realizadas com a técnica de controle clássica PVΔP mostraram um melhor desempenho da estratégia de controle proposta. Quando foi adicionada uma massa de 5 kg de carga ao servoposicionador, o controlador Cascata Neural manteve comportamento adequado do sistema com um pequeno aumento no erro de seguimento, mostrando que a estratégia de controle possui relativa robustez a variações na massa da carga. O seguimento de trajetórias pelo sistema pneumático é dificultado quando se opera em baixas velocidades e pouca massa de carga, provavelmente, associada à relação entre a força de atrito e a força inercial. Nesse sentido, os resultados de simulações e de experimentos permitiram concluir que, quanto maior a massa, melhor o desempenho do controlador proposto com um adequado ajuste nos ganhos do controlador. Verificou-se que na literatura a maioria dos artigos privilegia resultados experimentais com massas na carga mais elevadas (5 kg, 10 kg, 30kg), este fato deve-se a dificuldade de se trabalhar em vazio (sem adição da massa da carga), principalmente em baixas velocidades, fazendo com que o

fenômeno de atrito stick-slip se torne significativo e dificulte o controle no seguimento de trajetórias. No presente trabalho resultados para o seguimento de trajetórias sem adição de massa na carga foram obtidos e apresentaram desempenho satisfatório.

Finalmente, pode-se concluir com base nos diversos resultados obtidos na bancada experimental, que o controlador Cascata Neural proposto consegue seguir trajetórias de referência com precisão e com relativa robustez a variações na massa da carga, o que é exatamente o principal objetivo do presente trabalho.

Como principal contribuição do presente trabalho destaca-se a proposição de um procedimento sistemático para a obtenção de modelos de sistemas pneumáticos, incluindo os procedimentos de treinamento da rede adequados para a obtenção de modelos precisos de tais sistemas. Outra contribuição refere-se ao desenvolvimento de uma função inversa (difeomorfismo) para a relação entre as vazões desejadas e o sinal de controle. É importante salientar que quanto melhor essa função inversa representa os fenômenos físicos reais, melhor o resultado obtido através do uso do controlador, pois, a estratégia de controle em cascata utiliza as vazões para obter as forças desejadas calculadas através da Lei de Slotine e Li para garantir o seguimento da trajetória. Assim, controlando as vazões, podem-se controlar as dinâmicas das pressões nas câmaras que fornecem a força desejada a ser aplicada à massa deslocada e que garante, de acordo com a lei de Slotine e Li, o correto seguimento da trajetória.

Como trabalhos futuros propõem-se:

- utilizar a estratégia de controle em um robô pneumático com cinco graus de liberdade atualmente em desenvolvimento no LAMECC/UFRGS;
- realizar a identificação *online* da massa da carga com objetivo de se melhorar o desempenho no seguimento de trajetórias;
- implementação da estratégia de controle Cascata Neural em outros tipos de sistemas, como hidráulicos e mecânicos;
- identificar a zona morta e compensar em separado, ao invés de deixar que a rede neural aprenda o fenômeno;
- verificar o efeito da temperatura na dinâmica do sistema bem como no desempenho e na robustez na estratégia de controle proposta.

REFERÊNCIAS BIBLIOGRÁFICAS

Ahn, K.K.; Pyo, S.M.; Yang, S.Y.; Lee B.R. *Intelligent control of pneumatic actuator using LVQNN*. The 7th Korea-Russia International Symposium on Science and Technology. Proceedings KORUS 2003, v. 1, p. 260-266, 2003.

Aliff, M.; Dohta, S.; Akagi, T. *Trajectory control of simple-structured flexible mechanism using flexible pneumatic cylinders*. IEEE/SICE International Symposium on System Integration (SII), p. 19-24, 2013.

Al-Shabi, M.; Saleem, A.; Tutunji, T.A. *Smooth Variable Structure Filter for pneumatic system identification*. Applied Electrical Engineering and Computing Technologies (AEECT), 2011 IEEE Jordan Conference on 6-8 Dec. 2011.

Arbib M.A. The *Handbook of Brain Theory and Neural Networks*. Second Edition. MIT Press. Cambridge, 2003.

Beale, R.; Jackson, T. *Neural computing: an introduction*. Adam Higler Bristol. 1990.

Bobrow, J.E.; McDonell, W. *Modeling, Identification, and Control of a Pneumatically Actuated, Force Controllable Robot*. IEEE Transactions on Robotics and Automation, v.15, n. 5, p. 732-742, Outubro 1998.

Borgnakke, C. e Sonntag, R.E. *Fundamentos da Termodinâmica*. Editora Blucher, tradução da 8ª Edição. ISBN: 9788521207924. 2013.

Broadbent, H.R. *Electro-pneumatic brakes*. Proceedings of the IEE - Part IA: Electric Railway Traction, v. 97, n. 1, p. 250–261, 1950.

Canudas de Wit, C.; Olsson, H.; Astrom, K.J.; Lischinsky, P. *A New Model for Control Systems with Friction*. IEEE Trans. on Automatic Control, v. 40, n. 3, p. 419-425, 1995.

Carneiro, J.F.; de Almeida, F.G. *A high-accuracy trajectory following controller for pneumatic devices*. The International Journal of Advanced Manufacturing Technology. v. 61, Issue 1-4, p. 253-267. July, 2012.

Carneiro, J.F.; de Almeida, F.G. *A Neural Network Based Nonlinear Model of a Servopneumatic System*. J. Dyn. Sys., Meas., Control, v. 134, n. 2, p. 24502, 2011.

Carneiro, J.F.; de Almeida, F.G. *Micro tracking and positioning using off-the-shelf servopneumatics*. Journal of Robotics and Computer Integrated Manufacturing, v. 30, n. 3, p. 244-255, 2014.

Carneiro, J.F.; de Almeida, F.G. *Using two servovalves to improve pneumatic force control in industrial cylinders*. The International Journal of Advanced Manufacturing Technology, v. 66, n. 1-4, p. 283-301, 2013.

Chen, H.I.; Shih, M.C. *Visual Control of an Automatic Manipulation System by Microscope and Pneumatic Actuator*. IEEE Transactions on Automation Science and Engineering, v. 10, n. 1, p. 215-218, 2013.

Chiang, M. H.; *et al.* *Large stroke and high precision pneumatic-piezoelectric hybrid positioning control using adaptive discrete variable structure control*. Mechatronics, v. 15, p. 523-545, 2005.

Chikh, L.; Poignet, P.; Pierrot, F.; Michelin, M. *A predictive robust cascade position-torque control strategy for Pneumatic Artificial Muscles*. IEEE American Control Conference (ACC), p. 6022-6029, 2010.

Choi, G.S.; Lee, H.K.; Choi, G.H. *A Study on Tracking Position Control of Pneumatic Actuators Using Neural Network*. IEEE Proceedings of Industrial Electronics Society, v. 3, p. 1749-1753, 1998.

Choi, H.S.; *et al.* *Development Of Hybrid Robot For Construction Works With Pneumatic Actuator*. Proceedings of the 20th International Symposium on Automation and Robotics in Construction (ISARC), p. 191-196. Eindhoven, Holland, 2003.

Einicke, G.A.; White, L.B., *Robust Extended Kalman Filtering*. IEEE Trans. Signal Processing 47 (9): 2596–2599. September, 1999.

Faudzi, A.A.M.; *et al.* *Distributed Physical Human Machine Interaction Using Intelligent Pneumatic Cylinders*. International Symposium in Micro-Nano-Mechatronics and Human Science - MHS, p. 249-254, 2008.

Fausett, L. *Fundamentals of neural networks: architectures, algorithms, and applications*. Prentice-Hall, Inc. Upper Saddle River. N.J., USA, 1994.

Feyel, P.; Duc, G.; Sandou, G. *LuGre friction model identification and compensator tuning using a Differential Evolution algorithm*. IEEE Symposium on Differential Evolution (SDE), p. 85-91, 2013.

Fok, S. e Ong, E. ***Position control and repeatability of a pneumatic rodless cylinder system for continuous positioning***. Robotics and Computer-Integrated Manufacturing, v. 15, p. 365-371, 1999.

Fox, R.W. e McDonald, A.T. ***Introdução à Mecânica dos Fluidos***. Editora Guanabara Dois S. A., Rio de Janeiro, 1981

Gervini, V.I.; Hemerly, E.M.; Gomes, S.C.P. ***Controle de Robô com Um Elo Flexível usando Redes Wavelets Neurais***. Congresso Brasileiro de Automática, 2008, Juiz de Fora. Congresso Brasileiro de Automática, 2008.

Gervini, V.I.; Gomes, S.C.P. e Rosa, V.S. ***A New Robotic Drive Joint Friction Compensation Mechanism Using Neural Networks***. Journal of the Brazilian Society of Mechanical Sciences and Engineering, v. 25, p. 135-145, 2003.

Gervini, V.I.; Gomes, S.C.P. ***Identificação e Compensação de Atritos Não Lineares de Atuadores Robóticos Via Redes Neurais Artificiais***. V Congresso Brasileiro de Redes Neurais, p. 475- 480, 2001.

Gomes, S.C.P.; Gervini, V.I.; Guimarães JR, D.S.; Machado, C.C. ***Controle de um manipulador flexível utilizando redes neurais***. Congresso Brasileiro de Automática, 2006, Salvador. Congresso Brasileiro de Automática, 2006.

Gross, D.C.; Rattan, K.S. ***A feedforward MNN controller for pneumatic cylinder trajectory tracking control***. IEEE International Conference on Neural Networks, v.2, p. 794-799, 1997.

Guenther, R.; De Pieri, E.R. ***Cascade Control of the Hydraulic Actuators***. Revista Brasileira de Ciências Mecânicas, v. 19, no 2, p. 108-120, junho 1997.

Guenther, R.; Hsu, L. ***Variable Structure Adaptive Cascade Control of Rigid-Link Electrically Driven Robot Manipulators***. Proc. IEEE 32nd CDC, San Antonio, Texas, dezembro, p.2137-2142, 1993.

Guenther, R.; Perondi, E.A. ***O Controle em Cascata de um Sistema Pneumático de Posicionamento***. Anais do XVI Congresso Brasileiro de Engenharia Mecânica – COBEM2001. Uberlândia, MG, Brasil, 2001.

Guenther, R.; Perondi, E.A.; DePieri, E.R.; Valdiero, A.C. ***Cascade Controlled Pneumatic Positioning System with LuGre Model Based Friction Compensation***. J. of the Braz. Soc. of Mech. Sci. & Eng. ABCM, v. XXVIII, no. 1, p. 48-57; janeiro-março 2006.

Hagan, M.T.; Demuth, H.B.; Beale, M. *Neural Network Design*. PWS Publishing Company, 1996.

Ham, F.M.; Kostanic, I. *Principles of Neurocomputing for Science & Engineering*. McGraw-Hill Companies, Inc., 2001.

Han, S.I.; Lee, J.M. *Precise Positioning of Nonsmooth Dynamic Systems Using Fuzzy Wavelet Echo State Networks and Dynamic Surface Sliding Mode Control*. IEEE Transactions on Industrial Electronics, v. 60, n. 11, p. 5124-5136, 2013.

Haykin, S. *Neural Networks - A Comprehensive Foundation*. Prentice Hall, 2nd Edition, 1999.

Hesselroth, T.; Sarkar, K.; Van Der Smagt, P.; Schulten, K. *Neural network control of a pneumatic robot arm*. IEEE Transactions on Systems Man and Cybernetics, v. 24, n. 1, p. 28–38, 1994.

Hodgson, S.; Tavakoli, M.; Pham, M.T.; Leleve, A. *Nonlinear Discontinuous Dynamics Averaging and PWM-Based Sliding Control of Solenoid-Valve Pneumatic Actuators*. IEEE/ASME Transactions on Mechatronics, v. 20, n. 2, p. 876-888, 2015.

Ilchmann, A.; *et al.* *Pneumatic cylinders: modelling and feedback force-control*. International Journal of Control, v. 79, p. 650-661, 2006.

Jain, A.K.; Mao, J. e Mohiuddin, K. *Artificial Neural Networks: A Tutorial*. IEEE Computer, v. 29, p. 31-44, 1996.

Kalman, R.E. *A new approach to linear filtering and prediction problems*. Journal of Basic Engineering, v. 82, n. 1, p. 35–45, 1960.

Korondi, P.; Gyeviski, J. *Robust Position Control for a Pneumatic Cylinder*. Proceedings of the 12th International Power Electronics and Motion Control Conference, p. 513– 518, 2006.

Kothapalli, G.; Hassan, M.Y. *Design of a Neural Network Based Intelligent PI Controller for a Pneumatic System*. IAENG International Journal of Computer Science, v. 35, p. 217-222, 2008.

Kunz, G.O. *Desenvolvimento de uma Arquitetura Programável de Controle em Tempo Real para um Servoposicionador Pneumático*. Porto Alegre, RS, 2006.

Lee, H.K.; *et al.* *A study on tracking position control of pneumatic actuators*. Mechatronics, v. 12, p. 813-831, 2002.

Li, J.; Kawashima, K.; Kagawa, T.; Fujita, T. *Trajectory control of pneumatic servo table with air bearing*. IEEE International Conference on Fluid Power and Mechatronics (FPM), p. 683-690, 2011.

Lischinsky, P.; Canudas de Wit, C.; Morel, G. *Friction Compensation for an Industrial Hydraulic Robot*. IEEE Control Systems, p.25-32, 1999.

Machado, C.L.D. *Compensação de Atrito em Atuadores Hidráulicos Utilizando Redes Neurais*. Dissertação de Mestrado em Engenharia Mecânica, Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis - SC, 2002.

Marquardt, D. *An Algorithm for Least-Squares Estimation of Nonlinear Parameters*. SIAM Journal on Applied Mathematics v. 11, n. 2, p. 431-441, 1963.

McCulloch, W.S.; Pitts, W.H. *A Logical Calculus of the Ideas Immanent in Nervous Activity*. Bull. Math. Biophy, no. 5, p. 115-133, 1943.

Meng, D.; Tao, G.; Liu, H.; Zhu, X. *Adaptive robust motion trajectory tracking control of pneumatic cylinders with LuGre model-based friction compensation*. Chinese Journal of Mechanical Engineering, v. 27, n. 4, p. 802-815, 2014.

Messina, A.; *et al.* *Experimenting and modelling the dynamics of pneumatic actuators controlled by the pulse width modulation (PWM) technique*. Mechatronics, v. 15, p. 859-881, 2005.

Na, J.; Chen, Q.; Ren X.; Guo, Y. *Adaptive Prescribed Performance Motion Control of Servo Mechanisms with Friction Compensation*. IEEE Transactions on Industrial Electronics, v. 61, n. 1, p. 486-494, 2014.

Nergaard, M.; Ravn, O.; Poulsen, N.K.; Hansen, L.K., *Neural Networks for Modelling and Control of Dynamic Systems*. Springer-Verlag, London, 2000.

Niiyama, R. *Model-based trajectory control of robots with pneumatic actuator dynamics*. IEEE International Conference on Intelligent Robots and Systems (IROS), p. 634-639, 2012.

Noble, Ben; Daniel, J.W. *Álgebra Linear Aplicada*. Prentice-Hall do Brasil. 2nd edição. Rio de Janeiro, 1986.

Perondi, E.A. *Controle Não-Linear em Cascata de um Servoposicionador Pneumático com Compensação do Atrito*. Tese (Doutorado em Engenharia Mecânica), Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis - SC, 2002.

Perondi, E.A.; Guenther, R. *Controle de um Servoposicionador Pneumático por Modos Deslizantes*. Congresso Nacional de Engenharia Mecânica - CONEM/2000. Natal, Brasil, 2000.

Perondi, E.A.; Guenther, R. *Controle em Malha Fechada de um Servoposicionador Pneumático*. Anais do XV Congresso Brasileiro de Engenharia Mecânica – COBEM99. Águas de Lindóia, SP, Brasil, 1999.

Rahman, R.A.; Sepehri, N. *Position Tracking of a Pneumatic Actuator Using Backstepping-Sliding Mode Control With Adaptive Friction Observer*. ASME Symposium on Fluid Power and Motion Control, ISBN: 978-0-7918-5608-6, 2013.

Rahmat, M.F.; Salim, S.N.S.; Sunar, N.H.; Faudzi, A.A.M.; Ismail, Z.H.; Huda, K. *Identification and non-linear control strategy for industrial pneumatic actuator*. International journal of physical sciences, v. 7, n. 17, p. 2565-2579, 2012.

Rajendran, S.; Nanda, P.S. *Electro-Pneumatic Servo System*. presented at the 14th National Conference on Machines and Mechanisms (NaCoMM09), NIT, Durgapur, India, 2009.

Ramirez, I. *Modeling and tracking control of a pneumatic servo positioning system*. International Congress of Engineering Mechatronics and Automation (CIIMA), p. 1-6, 2013.

Rapp, P.; Weickgenannt, M.; Tarin, C.; Sawodny, O. *Valve flow rate identification and robust force control for a pneumatic actuator used in a flight Simulator*. American Control Conference (ACC), p. 1806-1813, 2012.

Ren, H.P.; Huang, C. *Adaptive backstepping control of pneumatic servo system*. IEEE International Symposium on Industrial Electronics (ISIE), p. 1-6, 2013a.

Ren, H.P.; Huang, C. *Experimental tracking control for pneumatic system*. IEEE Industrial Electronics Society, IECON, p. 4126-4130, 2013b.

Richer, E.; Hurmuzlu, Y. *A High Performance Pneumatic Force Actuator System: Part II-Nonlinear Controller Design*. Journal of dynamic systems, measurement, and control, v. 122, p. 426-434, 2000.

Rijo M.G.Q. *Desenvolvimento da Base e Controle do Grau de Liberdade Rotacional de um Robô Cilíndrico com Acionamento Pneumático*. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Mecânica, UFRGS, 2013.

Rosenblatt, F. *Principles of Neurodynamics: Perceptrons and Theory of Brain Mechanisms*. DC: Spartan. 1962.

Rosenblatt, F. *The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain*. Psychological Review, v. 65, n. 6, p. 386–408, 1958.

Saleem, A.; *et al.* *Mixed-reality environment for frictional parameters identification in servo-pneumatic system*. Simulation Modelling Practice and Theory, v. 17, p. 1575-1586, 2009.

Salgado, I.; Chairez, I. *Nonlinear Discrete Time Neural Network Observer*. Neurocomputing, v. 101, p. 73-81, 2013.

Sang-Eun, S.; *et al.* *Development of a pneumatic robot for MRI-guided transperineal prostate biopsy and brachytherapy: New approaches*. in Robotics and Automation (ICRA), IEEE International Conference on, p. 2580-2585, 2010.

Schindele D.; Aschemann, H. *Adaptive friction compensation based on the LuGre model for a pneumatic rodless cylinder*. in Industrial Electronics, 2009. IECON '09. 35th Annual Conference of IEEE, p. 1432-1437, 2009.

Shaojuan, Y.; *et al.* *A New Iterative Learning Controller for Electro-Pneumatic Servo System*. in Intelligent Systems Design and Applications, 2008. ISDA '08. Eighth International Conference on, p. 101-105, 2008.

Shearer, J.L. *Study of Pneumatic Process in the Continuous Control of Motion With Compressed Air*. Transactions of the ASME, p. 233-249, 1956.

Shu, N.; Bone, G.M. *Experimental comparison of two pneumatic servo position control algorithms*. in Mechatronics and Automation, 2005 IEEE International Conference, v. 1, p. 37-42, 2005.

Slotine, J.J.E.; Li, W. *Applied Nonlinear Control*. Prentice-Hall Inc. New Jersey, 1991.

Smaoui, M.; *et al.* *A study on tracking position control of an electropneumatic system using backstepping design*. Control Engineering Practice, v. 14, p. 923-933, 2006.

Sobczyk, M.R.; Perondi, E.A.; Cunha, M.A.B. *A continuous extension of the LuGre friction model with application to the control of a pneumatic servo positioner*. IEEE 51st Annual Conference on Decision and Control (CDC), p. 3544-3550, 2012.

Sobczyk, M.R.S. *Controle em Cascata e a Estrutura Variável com Adaptação de Parâmetros e Compensação de Atrito de Um Servoposicionador Pneumático*. Tese de Doutorado, Programa de Pós-Graduação em Engenharia Mecânica, UFRGS, 2009.

Song, J.; Bao, X.; Ishida, Y. *An Application of MNN Trained by MEKA for the Position Control of Pneumatic Cylinder*. IEEE International Conference on Neural Networks, v. 2, p. 829–833, 1997a.

Song, J.; Ishida Y. *A robust sliding mode control for pneumatic servo systems*. International journal of engineering science, v. 35, p. 711-723, 1997b.

Song, Q.; Liu, F. *Neural Network Modeling and Disturbance Observer Based Control of a Pneumatic System*. Proceedings of the 2nd IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications, p. 1-5, 2006.

Surgenor, B.W.; Vaughan, N.D.; Uebling, M. *Continuous Sliding Mode Control of a Pneumatic Positioning System*. Proceedings of Eighth Bath International Fluid Power Workshop, p. 270-285, 1995.

Suzuki, R.M. *Controle Baseado em Linearização por Realimentação dos Estados Aplicado a Um Servoposicionador Pneumático*. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Mecânica, UFRGS, 2010.

Tappan, P.W.; Vaccaro; A.C.; Babcock, L. *A Pneumatic Ultrasonic Transmitter for a Low-Cost Remote Control*. Transactions on Broadcast and Television Receivers, IRE, v. BTR-6, n. 2, p. 31-34. 1960.

Trung, N.T.; Truong, D.Q.; Ahn, K.K. *Identification of a pneumatic actuator using non-linear black-box model*. 11th International Conference on Control, Automation and Systems (ICCAS), p. 1576–1581, 2011.

Tsai, Y.C.; Huang, A.C. *Multiple-surface sliding controller design for pneumatic servo systems*. Mechatronics, v. 18, p. 506-512, 2008.

Utkin, V.I. *Discontinuous Control Systems: State of Art in Theory and Applications*. IFAC World Congress on Automatic Control. Preprints, Munich, v. 1, p. 75-94, 1987.

Van Varseveld, R.B.; Bone, G.M. *Accurate position control of a pneumatic actuator using on/off solenoid valves*. Mechatronics, IEEE/ASME Transactions on, v. 2, p. 195-204, 1997.

Vieira, A.D. *Análise Teórico Experimental de Servoposicionadores Lineares Pneumáticos*. Dissertação de mestrado. CPGEM. Centro Tecnológico. UFSC. Florianópolis, 1998.

Virvalo, T. *Modelling and design of a pneumatic position servo system realized with commercial components*. Dissertação de Doutorado. Tampere University of Technology. Tampere, 1995.

Wang, J.; *et al.* *Accurate position control of servo pneumatic actuator systems: an application to food packaging*. Control Engineering Practice, v. 7, p. 699-706, 1999a.

Wang, J.; Pu, J.; Moore, P. *A practical control strategy for servo-pneumatic actuator systems*. Control Engineering Practice, v. 7, n. 12, p. 1483-1488, 1999b.

Weist J.; Arteaga, M.A.; Cruz, L.R.; Hebisch, H. *Model free control for differential pneumatic pistons: experimental comparison*. International Journal of Control, v. 84, n. 1, p. 138-164, 2011.

Widrow, B.; Hoff, M.E.Jr. *Adaptive Switching Circuits*. IRE Wescon Convention Record. 1960.

Zhu, G.G.; *et al.* *An iterative algorithm for model-based predictive control of an Electro-Pneumatic Valve Actuator*. in American Control Conference'09, p. 2684-2689, 2009.

APÊNDICE I – Parâmetros Físicos do Sistema Servopneumático, Sensores e Atuadores

I.1 Parâmetros Físicos

Os parâmetros do sistema físico, levantados e utilizados nas simulações e experimentos são apresentados na Tabela I.1.

Tabela I.1 – Valores numéricos dos parâmetros do sistema físico.

Parâmetro	Valor
p_s - pressão de suprimento	$7,0 \times 10^5$ Pa
p_{atm} - pressão atmosférica	$1,01 \times 10^5$ Pa
c_p - calor específico do ar a pressão constante	1005 J/kg.K
c_v - calor específico do ar a volume constante	718 J/kg.K
r - relação dos calores específicos do ar	1,4
R - constante universal dos gases	286,9J.kg/K
T - temperatura do ar de suprimento	293 K
M - massa deslocada do conjunto (êmbolo + carro do cilindro)	0,4 kg
L - comprimento útil do cilindro do atuador	1,0 m
A - área útil do êmbolo do cilindro atuador	$4,5 \times 10^{-4}$ m ²
V_{10} - volume morto na câmara 1	6×10^{-6} m ³
V_{20} - volume morto na câmara 2	2×10^{-6} m ³

I.2 Sensores

Para a medição das pressões nas câmaras foram utilizados dois sensores de pressão cujas características são apresentadas na Tabela I.2.

Tabela I.2 – Características técnicas dos sensores de pressão.

Modelo/fabricante	510 Huba Control
Pressão manométrica de entrada	0 a 1 MPa
Corrente elétrica de saída	mA DC
Resolução de entrada	0,3 %fs
Desvio máximo combinado (linearidade + histerese + repetibilidade)	0,5 %fs
Tensão de alimentação	12 a 33 VDC

Para a medição da posição do êmbolo foi utilizado uma régua potenciométrica cujas características são apresentadas na Tabela I.3.

Tabela I.3 – Características técnicas da régua potenciométrica.

Modelo/Fabricante	MLO – POT – 1000 – TLF FESTO
Curso útil nominal	1 m
Resolução de trajeto	0,01 mm
Linearidade de resposta	0,04 %fs
Tensão elétrica de alimentação máxima	42 VDC
Velocidade máxima admissível	10 m/s
Aceleração máxima admissível	200 m ² /s

I.3 Atuadores

Os dados da servoválvula direcional são apresentados na Tabela I.4.

Tabela I.4 – Características técnicas da servoválvula direcional.

Modelo/Fabricante	MPYE 5-1/8 FESTO
Tipo	5/3 vias
Pressão absoluta de trabalho	0 a 10bar
Vazão nominal teórica	700 l/min
Vazão nominal medida (Vieira, 1998)	410 l/min
Temperatura do fluido de trabalho	5 a 40 °C
Temperatura ambiente	0 a 50 °C
Tensão teórica de trabalho	0 a 10 V DC, posição central em 5 V
Tempo de resposta na faixa	2 a 8 V, 5 ms; 200 Hz
Potência absorvida Máximo	20 W

As características técnicas do atuador pneumático linear encontram-se na Tabela I.5.

Tabela I.5 – Características técnicas do atuador pneumático linear.

Modelo/Fabricante	DGPL-25 FESTO
Diâmetro do êmbolo	0,025 m
Construção	Cilindro pneumático de dupla ação
Pressão de serviço	2x10 ⁵ a 8x10 ⁵ Pa
Força de atuação	295 N
Temperatura Admissível	-10°C a 60 °C
Componente de carga admissível verticalmente em relação ao eixo do cilindro	330 N
Curso do amortecimento fim de curso	0,018 m
Velocidade máxima do carro a 6x10 ⁵ Pa e 20 °C	1 m/s para uma massa de 3 kg

I.4 Sistema de Aquisição de Dados e Controle – DSPACE

O controle e aquisição de dados são realizados por uma placa dedicada (ds1104), instalada em um computador pessoal (PC) dedicado. As características da placa de aquisição utilizada para o processamento de dados são apresentadas na Tabela I.6.

Tabela I.6 – Características da placa de aquisição e processamento de dados.

Modelo/fabricante	DS – 1104 dSPACE
Entradas para conversão A/D	8 (4 de 16 <i>bits</i> + 4 de 12 <i>bits</i>)
Saídas com conversão D/A	8 (todas de 16 <i>bits</i>)
Entradas/saídas digitais	20 <i>bits</i> configuráveis individualmente
Frequência de operação do processador	250 MHz
Memória interna	32 MB global + 8 MB <i>flash</i>

APÊNDICE II – Caracterização Teórica das Vazões Mássicas na Servoválvula

Para o cálculo de vazões mássicas de gases ideais considerando-se o processo isentrópico, e utilizando o princípio da conservação de energia por unidade de massa [Borgnakke e Sonntag, 2013]

$$C_p T_u + \frac{v_u^2}{2} = C_p T_d + \frac{v_d^2}{2} \quad (\text{II.1})$$

com v_u e v_d as velocidades do ar a montante e a jusante respectivamente, T_u e T_d as temperaturas do ar a montante e jusante, respectivamente. A partir da hipótese que é estabelecida a condição de estagnação a montante, ou seja, $v_u \approx 0$, obtemos:

$$C_p T_u = C_p T_d + \frac{v_d^2}{2} \quad (\text{II.2})$$

dividindo ambos os termos por $C_p T_u$

$$1 = \frac{T_d}{T_u} + \frac{v_d^2}{2C_p T_u} \quad (\text{II.3})$$

Por outro lado

$$R = C_p - C_v \quad (\text{II.4})$$

dividindo ambos os termos por C_p

$$\frac{R}{C_p} = 1 - \frac{C_v}{C_p} \quad (\text{II.5})$$

como

$$r = \frac{C_p}{C_v} \quad (\text{II.6})$$

Utilizando as Equações (II.5) e (II.6)

$$\frac{R}{C_p} = 1 - \frac{1}{r} \quad (\text{II.7})$$

ou

$$C_p = \frac{rR}{r-1} \quad (\text{II.8})$$

substituindo (II.8) em (II.3)

$$v_d = \sqrt{\frac{2rR}{r-1}(T_u - T_d)} \quad (\text{II.9})$$

ou

$$v_d = \sqrt{\frac{2rRT_u}{r-1}\left(1 - \frac{T_d}{T_u}\right)} \quad (\text{II.10})$$

A vazão mássica é definida como a variação de massa no volume de controle ao longo do tempo

$$q_m = \frac{dm}{dt} \quad (\text{II.11})$$

onde m é a massa contida em um volume de controle e dada por

$$m = \rho_d V \quad (\text{II.12})$$

e sua derivada em função do tempo por

$$\dot{m} = \dot{\rho}_d V + \rho_d \dot{V} \quad (\text{II.13})$$

Assumindo a hipótese de que em regime permanente $\dot{\rho}_d = 0$, temos

$$\dot{m} = \rho_d \dot{V} \quad (\text{II.14})$$

Assumindo o volume de controle na região estrangulamento de forma cilíndrica, com área de passagem dada por $A(u)$ e de comprimento x , o volume de controle na região de estrangulamento pode ser expresso por

$$V = A(u)x \quad (\text{II.15})$$

utilizando (II.15) em (II.14)

$$\dot{m} = \rho_d \frac{d(A(u)x)}{dt} \quad (\text{II.16})$$

ou

$$\dot{m} = A(u)\rho_d v_d \quad (\text{II.17})$$

Pela equação dos gases perfeitos

$$\rho_d = \frac{p_d}{RT_d} \quad (\text{II.18})$$

Substituindo (II.10) e (II.18) em (II.17)

$$\dot{m} = A(u) \frac{p_d}{RT_d} \sqrt{\frac{2rRT_u}{r-1} \left(1 - \frac{T_d}{T_u}\right)} \quad (\text{II.19})$$

ou

$$\dot{m} = A(u) \frac{p_d}{T_d} \sqrt{\frac{2rT_u}{(r-1)R} \left(1 - \frac{T_d}{T_u}\right)} \quad (\text{II.20})$$

Para um processo isentrópico

$$pV^r = cte \quad (\text{II.21})$$

Para um gás ideal

$$pV = mRT \quad (\text{II.22})$$

De (II.21) e (II.22)

$$p \left(\frac{mRT}{p}\right)^r = cte \quad (\text{II.23})$$

ou

$$\frac{T}{p^{\frac{r-1}{r}}} = \frac{cte^{\frac{1}{r}}}{mR} \quad (\text{II.24})$$

Considerando a conservação da massa, i.e.

$$m = cte_1 \quad (\text{II.25})$$

$$\frac{T}{p^{\frac{r-1}{r}}} = cte_2 \quad (\text{II.26})$$

com

$$cte_2 = \frac{cte^{\frac{1}{r}}}{cte_1 R} \quad (\text{II.27})$$

As equações de temperatura à montante e à jusante ficam na forma

$$\frac{T_u}{p_u^{\frac{r-1}{r}}} = cte_2 \quad (\text{II.28})$$

$$\frac{T_d}{p_d^{\frac{r-1}{r}}} = cte_2 \quad (\text{II.29})$$

dividindo-se (II.29) por (II.28)

$$\frac{T_d}{T_u} = \left(\frac{p_d}{p_u}\right)^{\frac{r-1}{r}} \quad (\text{II.30})$$

ou

$$\frac{T_d}{T_u} = \frac{p_d}{p_u} \left(\frac{p_u}{p_d}\right)^{\frac{1}{r}} \quad (\text{II.31})$$

podemos agora calcular o termo $\frac{p_d}{T_d}$

$$\frac{p_d}{T_d} = \frac{p_u}{T_u} \left(\frac{p_d}{p_u}\right)^{\frac{1}{r}} \quad (\text{II.32})$$

Aplicando (II.30) e (II.32) em (II.20)

$$\dot{m} = A(u) \frac{p_u}{T_u} \left(\frac{p_d}{p_u} \right)^{\frac{1}{r}} \sqrt{\frac{2rT_u}{(r-1)R} \left(1 - \left(\frac{p_d}{p_u} \right)^{\frac{r-1}{r}} \right)} \quad (\text{II.33})$$

Finalmente a vazão mássica pode ser escrita como

$$\dot{m} = A(u) p_u \sqrt{\frac{2r}{(r-1)RT_u} \left(\left(\frac{p_d}{p_u} \right)^{\frac{2}{r}} - \left(\frac{p_d}{p_u} \right)^{\frac{r+1}{r}} \right)} \quad (\text{II.34})$$

Para calcular a vazão mássica no regime saturado deve-se dividir a Equação (II.2) por $C_p T_d$

$$\frac{T_u}{T_d} = 1 + \frac{v_d^2}{2C_p T_d} \quad (\text{II.35})$$

Substituindo (II.8) em (II.35)

$$\frac{T_u}{T_d} = 1 + \frac{(r-1)v_d^2}{2rRT_d} \quad (\text{II.36})$$

como

$$c_d^2 = rRT_d \quad (\text{II.37})$$

Onde c_d é a velocidade do som à jusante, portanto

$$\frac{T_u}{T_d} = 1 + \frac{(r-1)}{2} \left(\frac{v_d}{c_d} \right)^2 \quad (\text{II.38})$$

O número de *mach* é definido por

$$M \triangleq \frac{v_d}{c_d} \quad (\text{II.39})$$

Obtendo-se

$$\frac{T_u}{T_d} = 1 + \frac{(r-1)}{2} M^2 \quad (\text{II.40})$$

Para *mach* 1, isto é, $M = 1$

$$\frac{T_u}{T_d} = 1 + \frac{(r-1)}{2} \quad (\text{II.41})$$

ou

$$\frac{T_u}{T_d} = \frac{r+1}{2} \quad (\text{II.42})$$

de (II.30)

$$\frac{p_d}{p_u} = \left(\frac{T_d}{T_u} \right)^{\frac{r}{r-1}} \quad (\text{II.43})$$

Substituindo (II.42) em (II.43)

$$\frac{p_d}{p_u} = \left(\frac{2}{r+1} \right)^{\frac{r}{r-1}} \quad (\text{II.44})$$

Substituindo (II.32) e (II.42) em (II.19)

$$\dot{m} = A(u) \frac{p_u}{T_u} \left(\frac{p_d}{p_u} \right)^{\frac{1}{r}} \sqrt{\frac{2rRT_u}{(r-1)R^2} \left(1 - \frac{2}{r+1} \right)} \quad (\text{II.45})$$

ou

$$\dot{m} = A(u) p_u \sqrt{\frac{2rT_u}{(r-1)RT_u^2} \left(\frac{2}{r+1} \right)^{\frac{2}{r-1}} \left(\frac{r-1}{r+1} \right)} \quad (\text{II.46})$$

simplificando

$$\dot{m} = A(u) p_u \sqrt{\frac{r}{RT_u} \left(\frac{2}{r+1} \right)^{\frac{2}{r-1}} \left(\frac{2}{r+1} \right)} \quad (\text{II.47})$$

Resultando assim na Equação para a vazão mássica em regime saturado (sônico) com valor máximo e fixo dado por:

$$\dot{m} = A(u)p_u \sqrt{\frac{r}{RT_u} \left(\frac{2}{r+1}\right)^{\frac{r+1}{r-1}}} \quad (\text{II.48})$$

APÊNDICE III – Identificação Neural da derivada da Força de Atrito e da Dinâmica Inversa da Servoválvula (Difeomorfismo)

III.1 Identificação da derivada da Força de Atrito

Para a estimativa neural da derivada da força de atrito utilizou-se a mesma arquitetura neural apresentada na Figura 2.9, que foi utilizada para a estimação da força de atrito. A Figura III.1 ilustrada a arquitetura da rede neural adotada com dois neurônios de entrada (associados à diferença das derivadas das pressões nas câmaras e aceleração do êmbolo), quatro neurônios na *camada oculta* e um neurônio na *camada de saída* (associado à derivada da força de atrito estimado). A arquitetura dos neurônios é a mesma que foi apresentada na Figura 2.10.




Figura III.1 – Arquitetura da Rede Neural Artificial (RNA) usada para a realização da estimação da derivada da força de atrito

Após o treinamento utilizando a técnica clássica da retropropagação do erro (*backpropagation*), a rede apresentou uma taxa de erro de aproximadamente de 0.024 dos padrões apresentados à rede (este valor equivale a um erro médio de 1,2 % do valor desejado, pois a saída da rede pode variar apenas entre -1 e 1). O erro e de uma rede neural pode ser calculado conforme Equação (2.15).

As entradas da rede neural são à diferença das derivadas das pressões nas câmaras e aceleração do êmbolo, enquanto a saída é a derivada da força de atrito, conforme ilustrado

anteriormente na Figura III.1. Os padrões de treinamento foram obtidos através de uma série de ensaios experimentais. Esses ensaios constituíram-se da aplicação de um controlador proporcional para o seguimento de trajetória de posição utilizando como referência sinais do tipo degrau e também sinais do tipo senoidal.

Os valores dos parâmetros do controlador e referências utilizados nos experimentos selecionados para a identificação da derivada do atrito foram apresentados na Tabela 2.2.

Na Figura III.2 é apresentada a curva da derivada da força de atrito estimada pela rede neural após o treinamento sobreposta com a derivada da força de atrito calculada através da derivada numérica da Equação (2.14) para o caso de uma referência senoidal de amplitude de 0,45 m e frequência de 2 rad/s, com o controlador proporcional com ganho $K_p = 8$. Cabe salientar que a rede neural para a estimativa do atrito não foi treinada para um experimento com este ganho para o controlador proporcional, mesmo assim a rede conseguiu uma boa estimativa para este novo conjunto de entradas, que não foram treinadas. Isto indica que a rede neural possui uma satisfatória generalização para a estimativa do atrito.




Figura III.2 – Derivada da força de atrito experimental (preto) e estimada pela rede neural (azul) para $K_p = 8$ e referência senoidal com frequência de 2 rad/s e amplitude de 0,45 m

III.2 Identificação da dinâmica inversa da servoválvula

Nesta seção é apresentada a estratégia de identificação da inversa da dinâmica da servoválvula através de redes neurais. Utilizando a equação (2.13), temos,

$$u_n(p_1, p_2, y, u) = \dot{p}_\Delta - h_n(p_1, p_2, y, \dot{y}) \quad (\text{III.1})$$

Como $u_n = u_n(p_1, p_2, y, u)$ podemos inferir que $u = u(p_1, p_2, y, u_n)$. Baseando-se nessa equação, a topologia da rede neural proposta para a realização da identificação da estimativa neural da tensão de controle da servoválvula é apresentada na Figura III.3.




Figura III.3 – Arquitetura da RNA para estimativa da tensão de controle

A rede neural possui quatro entradas (sinal de controle calculado u_n , posição do êmbolo y e pressões nas câmaras p_1 e p_2) e uma saída (estimativa da tensão de controle u a ser aplicada a servoválvula). Para o cálculo experimental de u_n foi utilizada a Equação (III.1). Foram escolhidos quatro neurônios na camada intermediária, tendo a rede neural, com esse número, apresentado aprendizado dos padrões considerado satisfatório e uma boa generalização. Após o treinamento a rede apresentou uma taxa de erro de aproximadamente 1,7% (0.034) de erro em relação ao valor desejado. O erro e de uma rede neural foi calculado de acordo com a Equação (2.15).

Após a fase de treinamento, foram realizados alguns testes visando avaliar o desempenho da rede neural treinada na predição das vazões mássicas em experimentos que não foram utilizados no treinamento (com ganho proporcional igual 8 e com referência senoidal, de acordo com a Tabela 2.2. Resultados destes testes estão apresentados na Figura III.4. É possível perceber que por meio do uso da rede neural foi possível estimar adequadamente a tensão de controle a ser aplicada a servoválvula.




Figura III.4 – Tensão de controle experimental (preto) e estimada pela rede neural (azul)

III.2 Comandos em MatLab para o cálculo da saída de algumas RN

Comandos em *MatLab* para o cálculo da tensão na servoválvula:

```
un=3.1584e+006;y=0;p1=6.0466e+005;p2=3.0e+005; % exemplo de entradas
% obs.: entradas no SI
Wxy_inversa = [0.5175    0.0346    2.2083    0.9217;...
               1.1495   -0.8030   -0.5552    1.5965;...
               0.8021    0.6618    0.7035   -0.4279;...
               0.5822    0.4866    1.3695   -3.5289];
Wyz_inversa = [-1.1988; 0.8859; 0.9893; 1.9244];
Ofy_inversa = [1.6428 0.9278 1.8335 0.2852];
Ofz_inversa = [-0.9381];
min_un = -3.8060e+006;
min_y = -0.3934;
min_p1 = 3.8377e+005;
min_p2 = 3.9600e+005;
min_u = 4.082;
max_un = 3.1584e+006;
max_y = 3.1584e+006;
max_p1 = 6.0466e+005;
max_p2 = 6.0876e+005;
max_u = 6.005;
un_sat=((un-min_un)/( max_un - min_un)-0.5)*2;
y_sat=((y-min_y)/( max_y - min_y)-0.5)*2;
p1_sat=((p1-min_p1)/( max_p1 - min_p2)-0.5)*2;
p2_sat=((p2-min_p2)/( max_p2 - min_p2)-0.5)*2;
ve = [un_sat y_sat p1_sat p2_sat];
u_sat=tanh((tanh((ve*Wxy_inversa)+Ofy_inversa)*Wyz_inversa)+...
Ofz_inversa);
u=(u_sat /2+0.5)*( max_u - min_u) + min_u; % tensao u
```

Comandos em *Matlab* para o cálculo da força de atrito desejada:

```

vel=1;                % velocidade em [m/s]
p_delta=0            % diferença de pressão p1-p2 em Pa
Wxy_atrito = [ 0.0705 0.2261 0.1143 -0.0105; 0.3895 0.1530 0.3502 0.5526];
Wyz_atrito = [1.5223; 0.2878; 0.9805; 0.6473];
Ofy_atrito = [0.3045 0.2896 -0.2929 -0.4528];
Ofz_atrito = [0.0198];
min_atr=-72.6665;
max_atr=71.0760;
min_vel = -0.9826;
max_vel = 0.9953;
min_pdelta = -172112;
max_pdelta = 1.6999e+005;

vel_sat=((vel-min_vel)/( max_vel - min_vel)-0.5)*2;
p_delta_sat=(( p_delta -min_pdelta)/( max_pdelta - min_pdelta)-0.5)*2;
ve = [vel_sat  p_delta_sat]; % vetor das entradas da rede neural
fa_sat=tanh((tanh((ve*Wxy_atrito)+Ofy_atrito)*Wyz_atrito)+Ofz_atrito)
fa=(fa_sat /2+0.5)*( max_atr - min_atr) + min_atr; % força de atrito

```

APÊNDICE IV – Resultados com controlador Cascata Neural com compensação de Atrito com utilizando setup do Robô Pneumático

Com base nos resultados apresentados e discutidos na Seção 4.8, pode-se concluir que uma forma de melhorar o desempenho do seguimento de trajetórias é adicionando massa à carga movimentada. Nesta seção são apresentados resultados experimentais da aplicação de um atuador pneumático e sensores de pressões e posição utilizados na montagem do robô pneumático [Rijo, 2013]. Com este novo setup experimental conseguiu-se reduzir ainda mais os erros no seguimento de trajetória. As Figuras 4.43 a 4.45, apresentam os resultados experimentais obtidos em bancada para este novo setup. Cabe salientar que foi feita uma nova identificação neural de atritos, da inversa da válvula e da derivada da função de atrito. Os ganhos utilizados estão apresentados na Tabela IV.1

Tabela IV.1 – Ganhos utilizados no controlador Cascata Neural – *Setup* Robô Pneumático

K_p	K_d	λ
400	20	80

A Figura IV.1 apresenta o desempenho do controlador Cascata Neural no seguimento de trajetórias senoidais para este novo *setup*. Pode-se perceber com base no gráfico do erro em posição que o mesmo fica abaixo de 5 mm. A amplitude total da trajetória foi modificada para 12,5 cm devido ao curso limitado do novo atuador, e como se manteve a mesma frequência de referência, isto fez com que se obtiveram menores velocidades de referência. Ao se controlar estruturas pneumáticas o desempenho no seguimento de trajetórias é dificultado quando se tem pouca massa para baixas velocidades, pois nestes casos o fenômeno do atrito se apresenta com maior importância. Mesmo sendo este o caso analisado o controlador Cascata Neural apresentou desempenho satisfatório no seguimento de trajetórias com baixas velocidades e sem carga (massa de 0,37 kg). Com base na Seção 4.8 infere-se que ao se adicionar carga para este novo setup irão se conseguir resultados ainda melhores no seguimento de trajetória.

A velocidade e o sinal de controle são apresentados na Figura IV.2. O gráfico da velocidade apresenta uma pequena vibração, esta devido a dificuldades de se controlar em baixas velocidades e sem carga. O gráfico do sinal de controle apresenta uma pequena oscilação devido aos mesmos motivos. Finalmente a Figura IV.3 apresenta a comparação das forças calculadas pelo controlador Cascata Neural.




Figura IV.1 – Posição do êmbolo e seu respectivo erro experimental para o controlador cascata neural com trajetória de referência senoidal.




Figura IV.2 – Velocidade do êmbolo e sinal de controle experimental para o controlador cascata neural com trajetória de referência senoidal.




Figura IV.3 – Forças e respectivo erro para o controlador cascata neural com trajetória de referência senoidal.