

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

CONTROLE EM CASCATA DE UM ATUADOR HIDRÁULICO UTILIZANDO REDES
NEURAIS

por

Fábio Augusto Pires Borges

Tese para obtenção do Título de
Doutor em Engenharia

Porto Alegre, Junho de 2017.

CONTROLE EM CASCATA DE UM ATUADOR HIDRÁULICO UTILIZANDO REDES
NEURAIS

por

Fábio Augusto Pires Borges

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

Co-orientador: Prof. Dr. Mauro André Barbosa Cunha

Aprovada por:

Prof. Dr. Edson Roberto De Pieri,.....: UFSC

Prof. Dr. Antonio Carlos Valdiero.....:UNIJUI

Prof. Dr. Rafael Antonio Comparsi Laranja.:PROMEC/UFRGS

Prof. Dr. Mario Roland Sobczyk Sobrinho.....:UFRGS

Prof. Dr. Jakson Manfredini Vassoler

Coordenador do PROMEC

Porto Alegre, 22, Junho de 2017.

AGRADECIMENTOS

Agradeço a CAPES pelo suporte financeiro para a realização do presente trabalho. Agradeço a todos os profissionais exemplares como o Prof. Perondi, o meu amigo de longa data Prof. Mauro Cunha, o Prof. Mario Sobczyk, o laboratorista Henrique Werkhausen, os meus colegas doutorandos Rafael e Anselmo, a equipe do LAMECC e a tantos outros que foram essenciais para a realização do presente trabalho. Agradeço minha família, minha mãe, meus irmãos e principalmente minha esposa Márcia e meus filhos Pedro e Isabel, razões maiores de ter conseguido chegar ao fim.

RESUMO

No presente trabalho, é realizada a modelagem e identificação de um servoposicionador hidráulico de uma bancada de testes. As expressões analíticas tradicionalmente utilizadas em uma estratégia em cascata aplicada ao controle de trajetória de posição são obtidas. A estratégia em questão utiliza, conjuntamente, a linearização por realimentação como lei de controle do subsistema hidráulico e a lei de controle de Slotine e Li no subsistema mecânico. Com base na mesma estratégia, um controlador em cascata neural é proposto. Em tal controlador, a função analítica que representa o mapa inverso, presente na linearização por realimentação, e a função de compensação de atrito utilizada na lei de Slotine e Li são substituídas por funções constituídas por meio de redes neurais de perceptrons de múltiplas camadas. Essas redes neurais têm como entradas os estados do sistema e também a temperatura do fluido hidráulico. O novo controlador é apresentado em uma versão onde as redes neurais são aplicadas sem modificações *on-line* e em outra, onde são apresentadas leis de controle adaptativo para as mesmas. A prova de estabilidade do sistema em malha fechada é apresentada em ambos os casos. Resultados experimentais do controle de seguimento de trajetórias de posição em diferentes temperaturas do fluido hidráulico são apresentados. Esses resultados demonstram a maior efetividade do controlador proposto em relação aos controladores clássicos PID e PID+*feedforward* e ao controlador em cascata com funções analíticas fixas. Os experimentos são realizados em duas situações: quando não ocorrem variações paramétricas importantes no sistema, onde é utilizado o controlador em cascata neural fixo e quando ocorrem essas variações, onde se utiliza o controlador em cascata neural adaptativo.

Palavras - chave: Redes Neurais; Servoposicionador Hidráulico; Controlador em Cascata; Compensação de Atrito; Mapa inverso.

ABSTRACT

In this work, the modeling and identification of a hydraulic actuator testing setup are performed and the analytical expressions that are used in a cascade control strategy applied in a position trajectory tracking control are designed. Such cascade strategy uses the feedback linearization control law in the hydraulic subsystem and the Slotine and Li control law in the mechanical one. Based on this cascade strategy, a neural cascade controller is proposed, for which the analytical function used as inversion set in the feedback linearization control law and the friction function compensation of the Slotine and Li control law are replaced by multi layer perceptrons neural networks where the inputs are the states of the system and the hydraulic fluid temperature. The novel controller is introduced in two different approaches: the first one where the neural networks do not have on-line modifications and the second one where adaptive control laws are proposed. For both of them the stability proof of the closed-loop system is presented. Experimental results about some position tracking controls performed in different fluid temperature are showed. The results show that the novel controller is more effective than the classical PID, PID+feedforward and the traditional analytical cascade controller. The experiments are performed in two different setups: considering the system without important parametric variations where is applied the non adaptive cascade neural controller and in the presence of parametric variations where is applied the adaptive cascade neural controller.

Keywords: Neural Networks; Hydraulic Actuator; Cascade Controller; Friction Compensation; Diffeomorphism.

ÍNDICE

1. INTRODUÇÃO	1
1.1. Objetivos e enfoque da Tese.....	1
1.2. O Servoposicionador Hidráulico	2
1.3. O Estado da Arte.....	4
1.4. Organização do Trabalho.....	29
2. MODELAGEM DO SISTEMA DINÂMICO.	30
2.1. Modelo analítico não-linear do servoposicionador hidráulico.	31
2.1.1. Efeito da dinâmica nas tubulações.....	32
2.1.2. Vazamentos internos da válvula.	33
2.1.3. Dinâmica associada à válvula	33
2.1.4. Zona morta.....	34
2.1.5. Centro Hidráulico da Válvula e Histerese.	34
2.1.6. Temperatura do fluido hidráulico.	35
2.1.7. Equacionamento do subsistema hidráulico.....	36
2.1.7.1. Equacionamento da vazão nos orifícios da válvula direcional.....	36
2.1.7.2. Equacionamento das pressões no cilindro assimétrico.....	43
2.1.8. Equacionamento do subsistema mecânico.....	46
2.1.9. Modelo completo não linear do servoposicionador hidráulico.....	48
2.2. Modelo Analítico Linear do servoposicionador Hidráulico.	49
2.2.1. Coeficientes de vazão e de vazão-pressão	50
2.2.2. Linearização do equacionamento da vazão nos orifícios da válvula direcional	51
2.2.3. Linearização das pressões no cilindro assimétrico.	53
2.2.4. Linearização do subsistema mecânico.....	53
2.2.5. Modelo completo linear do servoposicionador hidráulico.	54
2.3. Modelo Analítico da bancada experimental.	55
2.3.1. Descrição da bancada experimental do servoposicionador hidráulico.	56
2.3.2. Obtenção do coeficiente da válvula.	59
2.3.3. Determinação dos parâmetros do modelo de atrito.	60
2.3.4. Parâmetros diretamente mensuráveis e módulo de compressibilidade volumétrica efetivo.....	64
2.3.5. Perdas de carga	65
2.3.6. Ganho de pressão, zero hidráulico e histerese.	66
2.4. Validação do Modelo Analítico.....	68
2.5. Modelo neural do Servoposicionador Hidráulico.....	75
2.5.1. Identificação de sistemas utilizando RN.....	75

2.5.2. Modelagem neural da válvula.....	76
2.5.3. Modelagem neural do atrito.....	79
2.5.4. Modelo neural da bancada experimental.....	80
2.6. Comparação dos resultados de simulação do modelo analítico com os do modelo neural.....	87
2.7. Discussões do Capítulo 2.....	89
3. CONTROLE DO SISTEMA DINÂMICO.....	90
3.1. Controladores lineares.....	90
3.1.1. Obtenção do modelo Analítico linear.....	90
3.1.2. Controlador PID.....	94
3.1.3. Controlador por realimentação de estados PVA (Posição, Velocidade e Aceleração).....	96
3.1.4. Controlador PID + feedforward.....	98
3.2. Estratégias de controle não linear.....	99
3.2.1. Linearização por realimentação.....	99
3.2.2. Controle de modos deslizantes (sliding mode control).....	100
3.2.3. Controle baseado no Backstepping.....	101
3.2.4. Controle Adaptativo por Modelo de Referência.....	103
3.2.5. Controle utilizando Lógica Fuzzy.....	105
3.2.6. Controle utilizando Redes Neurais.....	107
3.3. Discussões do Capítulo 3.....	110
4. ESTRATÉGIA EM CASCATA UTILIZANDO REDES NEURAIS.....	112
4.1. A Estratégia em Cascata.....	113
4.1.1. Subsistema mecânico.....	114
4.1.2. Subsistema Hidráulico.....	115
4.2. Compensação do atrito utilizando Redes Neurais.....	117
4.3. Mapa inverso da lei de controle do subsistema Hidráulico representado por Redes Neurais.....	119
4.4. Metodologia de projeto das redes neurais.....	121
4.4.1. Rede neural representando o mapa inverso.....	121
4.4.2. Rede neural representando o atrito.....	123
4.4.3. Metodologia de projeto da entrada u utilizada no treinamento off-line.....	123
4.4.4. Definição das arquiteturas e treinamento das redes neurais.....	126
4.5. Estratégias de adaptação on-line para as redes neurais propostas.....	142
4.6. Prova de estabilidade.....	145
4.6.1. Prova de estabilidade do controlador em cascata neural fixo.....	146
4.6.2. Prova de estabilidade do controlador em cascata neural adaptativo.....	154

4.7. Discussões do Capítulo 4.....	158
5. RESULTADOS EXPERIMENTAIS	159
5.1. Trajetórias de posição desejadas.....	159
5.2. Controladores Lineares.....	160
5.3. Controladores em Cascata fixo.....	166
5.4. Controlador em Cascata Neural Adaptativo.....	186
5.5. Discussões do Capítulo 5.....	200
6. CONCLUSÕES DA TESE.....	202
6.1. Sugestões de trabalhos futuros.	203
REFERÊNCIAS BIBLIOGRÁFICAS	205
APÊNDICE A. RESULTADOS EXPERIMENTAIS NÃO UTILIZADOS NO MODELO.....	217
A.1. Parâmetros da Dinâmica da válvula	217
A.2. Medição da zona morta.....	219
APÊNDICE B. FORÇA DE ATRITO	221
APÊNDICE C. EQUIPAMENTOS UTILIZADOS NOS EXPERIMENTOS E INCERTEZAS.	225
C.1. Descrição dos equipamentos hidráulicos	225
C.2. Descrição dos sensores	227
C.3. Filtros e incertezas dos sensores.	230
C.4. Estudo das incertezas na medição do erro de posição do controlador em cascata neural.	233
C.4.1 Métodos de análise de incertezas.....	234
C.4.1.1. Método GUM.....	234
C.4.1.2. Método Monte Carlo.....	235
C.4.2. Cálculo das incertezas do controlador em cascata neural utilizando a simulação Monte Carlo.....	236
APÊNDICE D. REDES NEURAS ARTIFICIAIS	242

D.1. Rede Neural de perceptrons de múltiplas camadas alimentada adiante.	244
D.2. Rede Neural de funções de base radial	258
D.3. Redes Neurais Recorrentes	260

LISTA DE FIGURAS

Figura 1.1. Servoposicionador Hidráulico.....	4
Figura 1.2. Gráfico de vazão [Johnson, 2011].....	5
Figura 2.1. Circuito hidráulico da bancada experimental.....	31
Figura 2.2. Viscosidade versus temperatura de alguns fluidos hidráulicos (Bosch Rexroth). 35	
Figura 2.3. Válvula de 4 vias.....	36
Figura 2.4. Trechos com perdas de carga.....	42
Figura 2.5. Modelo do coeficiente de atrito viscoso variável.....	47
Figura 2.6. Bancada Hidráulica Experimental.....	58
Figura 2.7. Diagrama descritivo dos componentes da bancada hidráulica experimental.....	59
Figura 2.8. Mapa estático de F_A'	62
Figura 2.9. Aproximação do coeficiente Z por uma reta que passa pela origem.....	64
Figura 2.10. Ganho de pressão extraído do catálogo.....	66
Figura 2.11. Ensaio experimental dos ganhos de pressão da válvula.....	67
Figura 2.12. Ensaio experimental dos ganhos de pressão da válvula por via.....	67
Figura 2.13. Respostas do modelo analítico e dos experimentos – pressões medidas nos sensores de pressão (sinal positivo na válvula).....	70
Figura 2.14. Respostas do modelo analítico e dos experimentos – pressões medidas nos sensores de pressão (sinal negativo na válvula).....	71
Figura 2.15. Respostas do modelo analítico e dos experimentos – força hidráulica modificada F_H' (sinal positivo na válvula).....	72
Figura 2.16. Respostas do modelo analítico e dos experimentos – força hidráulica modificada F_H' (sinal negativo na válvula).....	73
Figura 2.17. Respostas do modelo analítico e dos experimentos - posição do pistão y	74
Figura 2.18. Coeficiente da válvula com a variação do sinal de entrada [Valdiero, 2005].....	78
Figura 2.19. Treinamento da RN.....	80
Figura 2.20- Comparação entre conjunto de teste e saídas da Rede Neural positiva.....	84
Figura 2.21. Comparação entre o conjunto de teste e saídas da Rede Neural negativa.....	85
Figura 2.22. Comparação entre a Força de Atrito modificada obtida experimentalmente e a saída da RN.....	86

Figura 2.23. Comparação entre as pressões P_A das simulações dos modelos analítico e neural e da curva experimental.....	87
Figura 2.24. Comparação entre as pressões P_B das simulações dos modelos analítico e neural da curva experimental.....	88
Figura 2.25. Resposta em malha aberta da posição do pistão - simulações e resultado experimental	88
Figura 3.1. Trajetória desejada.	91
Figura 3.2. Lugar Geométrico das Raízes do modelo linear	93
Figura 3.3. Controle Adaptativo por Modelo de Referência [Ioannou e Sun, 1996]	104
Figura 3.4. Sistema de lógica <i>fuzzy</i> (adaptado de Mendel, 1995).	106
Figura 3.5. Controle adaptativo por modelo de referência utilizando redes neurais (adaptado de Naredra e Parthasarathy, 1990).....	107
Figura 3.6. Controlador neural adaptativo baseado na linearização por realimentação (adaptado de Hagan e Demuth, 1999).	109
Figura 4.1. Interpretação da estratégia em cascata	113
Figura 4.2. Treinamento <i>off-line</i> do controlador neural baseado na linearização por realimentação (adaptado de Fregene, 1999).	121
Figura 4.3. Treinamento <i>off-line</i> da rede neural utilizada no mapa inverso.	122
Figura 4.4. Treinamento <i>off-line</i> da rede neural utilizada na obtenção da força de atrito modificada.	123
Figura 4.5. Conjunto total do mapa inverso – treinamento e validação.	129
Figura 4.6. Conjunto negativo do mapa inverso – treinamento e validação.	130
Figura 4.7. Conjunto positivo do mapa inverso – treinamento e validação.	131
Figura 4.8. Conjunto atrito modificado – treinamento e validação.	132
Figura 4.9. Conjunto de teste do mapa inverso (T=20°C).....	136
Figura 4.10. Conjunto de teste do mapa inverso (T=30°C).....	137
Figura 4.11. Conjunto de teste do mapa inverso (T=40°C).....	137
Figura 4.12. Conjunto de teste do atrito modificado(T=20°C ; 30°C ; 40°C).....	138
Figura 4.13. Aplicação de entradas aleatórias na rede neural que representa o mapa inverso com entradas extrapolando a região de treinamento.	140
Figura 4.14. Aplicação de entradas aleatórias na rede neural que representa o mapa inverso: região de treinamento.	140

Figura 4.15. Aplicação de entradas aleatórias na rede neural que representa a força de atrito modificada com entradas extrapolando a região de treinamento.	141
Figura 4.16. Aplicação de entradas aleatórias na rede neural que representa a força de atrito modificada: região de treinamento.	141
Figura 5.1. Experimentos a 40 °C PID e PID + f. (trajetória polinomial): posição.	161
Figura 5.2. Experimentos a 40 °C PID e PID + f. (trajetória polinomial): sinal de controle.	161
Figura 5.3. Experimentos a 20 °C : PID e PID + f. (trajetória polinomial): erros de posição.	162
Figura 5.4. Experimentos a 30 °C PID e PID + f. (trajetória polinomial): erros de posição.	162
Figura 5.5. Experimentos a 40 °C PID e PID + f. (trajetória polinomial) : erros de posição.	162
Figura 5.6. Variação de Erro de posição (RMSE) com a temperatura do fluido hidráulico para o controlador PID aplicado à trajetória polinomial.	163
Figura 5.7. Experimentos a 40 °C PID e PID + f. (trajetória senoidal): posição	164
Figura 5.8. Experimentos a 40 °C PID e PID + f. (trajetória senoidal): sinal de controle. ...	164
Figura 5.9. Experimentos a 20 °C PID e PID + f. (trajetória senoidal): erros de posição.	164
Figura 5.10. Experimentos a 30 °C PID e PID + f. (trajetória senoidal): erros de posição.	164
Figura 5.11. Experimentos a 40 °C PID e PID + f. (trajetória senoidal) : erros de posição.	165
Figura 5.12. Variação de Erro de posição (RMSE) com a temperatura do fluido hidráulico para o controlador PID aplicado à trajetória senoidal.	165
Figura 5.13. Experimentos a 40 °C para o cascata analítico na trajetória polinomial.	167
Figura 5.14. Experimentos a 20 °C para o cascata analítico na trajetória polinomial: sinal de controle e erro de seguimento de posição.	168
Figura 5.15. Experimentos a 30 °C para o cascata analítico na trajetória polinomial: sinal de controle e erro de seguimento de posição.	168
Figura 5.16. Experimentos a 40 °C para o cascata analítico na trajetória polinomial: sinal de controle e erro de seguimento de posição.	168
Figura 5.17. Experimentos a 40 °C para o cascata analítico na trajetória senoidal.	169
Figura 5.18. Experimentos a 20 °C para o cascata analítico na trajetória senoidal: sinal de controle e erro de seguimento de posição.	170
Figura 5.19. Experimentos a 30 °C para o cascata analítico na trajetória polinomial: sinal de controle e erro de seguimento de posição.	170

Figura 5.20. Experimentos a 40 °C para o cascata analítico na trajetória polinomial: sinal de controle e erro de seguimento de posição.....	170
Figura 5.21. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória polinomial.....	173
Figura 5.22. Experimentos a 20 °C Para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória polinomial.....	173
Figura 5.23. Experimentos a 30 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória polinomial.....	174
Figura 5.24. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória polinomial.....	174
Figura 5.25. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória senoidal.....	175
Figura 5.26. Experimentos a 20 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória senoidal.....	175
Figura 5.27. Experimentos a 30 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória senoidal.....	176
Figura 5.28. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória senoidal.....	176
Figura 5.29. Experimentos a 20 °C : Comparações entre os controladores para a trajetória polinomial.....	178
Figura 5.30. Experimentos a 30 °C : Comparações entre os controladores para a trajetória polinomial.....	178
Figura 5.31. Experimentos a 40 °C : Comparações entre os controladores para a trajetória polinomial.....	179
Figura 5.32. Experimentos a 20 °C : Comparações entre os controladores para a trajetória senoidal.....	179
Figura 5.33. Experimentos a 30 °C : Comparações entre os controladores para a trajetória senoidal.....	180
Figura 5.34. Experimentos a 40 °C : Comparações entre os controladores para a trajetória senoidal.....	180
Figura 5.35. Experimentos a 20 °C: comparações entre as funções de mapa inverso para a trajetória polinomial.	182

Figura 5.36. Experimentos a 30 °C: comparações entre as funções de mapa inverso para a trajetória polinomial.	182
Figura 5.37. Experimentos a 40 °C: comparações entre as funções de mapa inverso para a trajetória polinomial.	183
Figura 5.38. Experimentos a 20 °C: comparações entre as funções de mapa inverso para a trajetória senoidal.	184
Figura 5.39. Experimentos a 30 °C: comparações entre as funções de mapa inverso para a trajetória senoidal.	184
Figura 5.40. Experimentos a 40 °C: comparações entre as funções de mapa inverso para a trajetória senoidal.	185
Figura 5.41. Configuração da bancada hidráulica para os ensaios experimentais utilizando os controladores adaptativos propostos.	187
Figura 5.42. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória polinomial.	188
Figura 5.43. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória polinomial (7 min de experimento). Erro de posição.	189
Figura 5.44. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória polinomial (7 min de experimento). Temperatura do fluido hidráulico no experimento.	190
Figura 5.45. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória polinomial (7 min de experimento). Adaptação de \hat{W}_{3r} (atrito modificado).....	191
Figura 5.46. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória polinomial (7 min de experimento). Adaptação de $\hat{\alpha}$ (mapa inverso).	191
Figura 5.47. Experimentos a 40 °C : Cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória senoidal.	192
Figura 5.48. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória senoidal (7 min de experimento). Erro de posição.	193

Figura 5.49. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória senoidal (7 min de experimento). Temperatura do fluido hidráulico no experimento.	194
Figura 5.50. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória senoidal (7 min de experimento). Adaptação de \hat{W}_{3r} (atrito modificado).	194
Figura 5.51. Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória senoidal (7 min de experimento). Adaptação de $\hat{\alpha}$ (mapa inverso).	195
Figura 5.52. Experimentos a 20 °C : Comparações entre os controladores em Cascata na trajetória polinomial.	197
Figura 5.53. Experimentos a 30 °C : Comparações entre os controladores em Cascata na trajetória polinomial.	196
Figura 5.54. Experimentos a 40 °C : Comparações entre os controladores em Cascata na trajetória polinomial.	197
Figura 5.55. Experimentos a 20 °C : Comparações entre os controladores em Cascata na trajetória senoidal.	198
Figura 5.56. Experimentos a 30 °C : Comparações entre os controladores em Cascata na trajetória senoidal.	199
Figura 5.57. Experimentos a 40 °C : Comparações entre os controladores em Cascata na trajetória senoidal.	199
Figura A.1. Resposta em frequência da válvula - catálogo do fabricante.	217
Figura A.2. Resposta em frequência – levantamento experimental.	218
Figura A.3. Variação das pressões medidas na bancada experimental.	219
Figura B.1. Modelo de atrito de Coulomb [Machado, 2003]	221
Figura B.2. Força de atrito estático.....	222
Figura B.3. Atrito viscoso [Machado, 2003].	222
Figura B.4. Modelo completo de atrito [Machado, 2003].	223
Figura B.5. Efeito Adere Desliza [Machado, 2003].	224
Figura C.1. Servoválvula	226
Figura C.2. Cilindro Hidráulico.....	226
Figura C.3. Unidade de Potência e Condicionamento Hidráulicos.	227

Figura C.4. Régua Potenciométrica.....	228
Figura C.5. Sensor da Pressão A.	228
Figura C.6. Sensor da Pressão B.....	229
Figura C.7. Transmissor de Temperatura.	230
Figura C.8. Medida de Posição.....	231
Figura C.9. Medida da Pressão A.	232
Figura C.10. Medida da Pressão B.	232
Figura C.11. Simulação Monte Carlo.....	237
Figura C.12. Erro de posição da simulação do modelo.....	239
Figura C.13. Distribuição normal dos desvios de erro agrupados na simulação.....	239
Figura C.14. Erro de posição no experimento.	240
Figura C.15. Distribuição normal dos desvios de erro agrupados no experimento.....	240
Figura D.1. Neurônio Biológico [Borges, 1999].....	242
Figura D.2. Neurônio Artificial Perceptron.....	243
Figura D.3. RN MLP	245
Figura D.4. Função logística sigmoideal.....	246
Figura D.5. Diagrama esquemático da relação entrada e saída de um sistema R e uma RN	248
Figura D.6. Treinamento bem sucedido e sobre treinamento.....	250
Figura D.7. Mínimos locais e mínimos globais.....	255
Figura D.8. Regiões de planície.....	255
Figura D.9. Esquema de uma Rede RBF.....	258
Figura D.10. Rede neural recorrente	261

LISTA DE TABELAS

Tabela 1.1. Contribuições de maior relevância de 2015 a 2017.....	27
Tabela 1.2. Contribuições de maior relevância de 2011 a 2014.....	28
Tabela 2.1. Resumo das equações do modelo não linear do servoposicionador hidráulico....	48
Tabela 2.2. Parâmetros do modelo de atrito viscoso variável aplicados à Equação (2.76).....	63
Tabela 2.3. Parâmetros do modelo da bancada experimental.....	69
Tabela 2.4. Equações do modelo analítico da bancada experimental.	69
Tabela 2.5. Equações do modelo neural da bancada experimental.	81
Tabela 2.6. Parâmetros de normalização para as RN da válvula.....	83
Tabela 2.7. Parâmetros referentes ao treinamento: RN positiva	83
Tabela 2.8. Parâmetros referentes ao treinamento: RN negativa	84
Tabela 2.9. Parâmetros de normalização para a RN do atrito modificado	86
Tabela 2.10. Resumo do treinamento RN atrito modificado.....	86
Tabela 3.1. Valores dos parâmetros utilizados no modelo linear.....	92
Tabela 3.2. Ganhos do controlador PID sintonizados ($T = 30^{\circ}\text{C}$).....	95
Tabela 3.3. Valores dos ganhos calculados do controlador PID+ <i>feedforward</i> ($T = 30^{\circ}\text{C}$)....	99
Tabela 4.1. Conjuntos de treinamento das redes neurais.....	126
Tabela 4.2. Conjuntos de validação das redes neurais.	128
Tabela 4.3. Conjuntos de teste das redes neurais.	128
Tabela 4.4. Treinamento e validação para as arquiteturas escolhidas ($T=30^{\circ}\text{C}$).	133
Tabela 4.5. Treinamento para as arquiteturas escolhidas considerando a temperatura do fluido hidráulico.....	134
Tabela 4.6. Parâmetros de normalização para as entradas e saída das redes neurais que representam o mapa inverso.	134
Tabela 4.7. Parâmetros de normalização para as entradas e saída das redes neurais que representam o atrito modificado.	136
Tabela 4.8. Erros (RMSE) em relação ao conjunto de teste: mapa inverso.	138
Tabela 4.9. Erros (RMSE) em relação ao conjunto de teste: atrito modificado (20°C ; 30°C ; 40°C).....	138
Tabela 4.10. Limites utilizados nas distribuições de probabilidade que extrapolam a região de treinamento das redes neurais.....	139

Tabela 4.11. Limites utilizados nas distribuições de probabilidade que delimitam aproximadamente a região de treinamento das redes neurais.....	139
Tabela 4.12. Equações do modelo do atuador hidráulico.....	145
Tabela 5.1. Ganhos dos controladores em cascata.	166
Tabela 5.2. Comparação de erro entre os controladores lineares e o controlador em cascata analítico para a trajetória polinomial.	171
Tabela 5.3. Comparação de erro entre os controladores lineares e o controlador em cascata analítico para a trajetória senoidal.	171
Tabela 5.4. Comparação de erro entre os controladores em cascata para a trajetória polinomial.....	177
Tabela 5.5. Comparação de erro entre os controladores em cascata para a trajetória senoidal.	177
Tabela 5.6. Comparação de erro entre as funções de mapa inverso para a trajetória polinomial.....	183
Tabela 5.7. Comparação de erro entre as funções de mapa inverso para a trajetória senoidal.	185
Tabela 5.8. Comparação de erro entre os controladores em cascata para a trajetória polinomial.....	198
Tabela 5.9. Comparação de erro entre os controladores em cascata para a trajetória senoidal.	200
Tabela C.1. Características da servoválvula.....	225
Tabela C.2. Características do cilindro hidráulico	226
Tabela C.3. Características da unidade de potência e condicionamento hidráulicos.	227
Tabela C.4. Características da Régua Potenciométrica	227
Tabela C.5. Características do Sensor da Pressão A.	228
Tabela C.6. Características do Sensor da Pressão B.....	228
Tabela C.7. Características Conversor A/D.....	229
Tabela C.8. Características Conversor D/A.....	229
Tabela C.9. Características Transmissor de Temperatura.	230
Tabela C.10. Frequência de corte filtros (Butterworth primeira ordem).....	230
Tabela C.11. Estatísticas da Medida de Posição	231
Tabela C.12. Estatísticas da medida da Pressão A.	231

Tabela C.13. Estatísticas da medida da Pressão B.	232
Tabela C.14. Distribuições de probabilidade retangulares dos mesurandos.	237
Tabela C.15. Distribuições normais de probabilidade dos mesurandos.	237
Tabela C.16. Parâmetros estatísticos do erro de posição.....	241
Tabela D.1. Notação para descrição do algoritmo <i>Backpropagation</i>	251

LISTA DE SIGLAS E ABREVIATURAS

A/D	Conversor Analógico/Digital
AESRC	<i>Auxiliary Error Signal Robust-based adaptive Controller</i> (Controlador adaptativo robusto baseado em um sinal de erro auxiliar)
ARC	<i>Adaptive Robust Controller</i> (Controle Adaptativo Robusto)
ARMA	<i>Autoregressive Moving Average</i> (Modelo Auto Regressivo de Média Móvel)
CAMR	Controle Adaptativo por Modelo de Referência
D/A	Conversor Digital/Analógico
DC	Corrente contínua
DIARC	<i>Integrated Direct Indirect Adaptive Robust Control</i> (Controle robusto adaptativo integrado direto / indireto)
ESN	<i>Echo-State Network</i> (Rede neural tipo echo-state)
IARC	<i>Indirect Adaptive Robust Control</i> (Controle robusto adaptativo indireto)
ITSE	<i>Integral Time Squared Error</i> (Integral do erro quadrático no tempo)
LAMECC	Laboratório de Mecatrônica e Controle
LGR	Lugar Geométrico das Raízes
LVDT	<i>Linear Variable Differential Transformer</i> (Transformador diferencial variável linear)
MIMO	<i>Multiple Inputs Multiple Outputs</i> (Sistemas de Múltiplas Entradas e Múltiplas Saídas)
MLP	<i>Multi Layer Perceptrons</i> (Redes de Perceptrons de Múltiplas Camadas)
NARMAX	<i>Nonlinear Autoregressive Moving Average X</i> (Modelo Não Linear Auto Regressivo de Média Móvel tipo X)
PI	Controlador Proporcional Integral
PID	Controlador Proporcional Integral Derivativo

PID+ <i>feedforward</i>	Controlador PID acrescido de uma parcela <i>feedforward</i>
PVA	Controlador por realimentação de estados de Posição, Velocidade e Aceleração
RBF	Redes Neurais de Base Radial
RISE	<i>Robust Integral of the Sign of the Error</i> (Termo integral robusto baseado no sinal de erro)
RMSE	<i>Root Mean Square Error</i> (Raíz do erro quadrático médio)
RN	Redes Neurais
SMC	<i>Sliding Mode Control</i> (Controle por modos deslizantes)
SISO	<i>Single Input Single Output</i> (Sistemas de uma Entrada e uma Saída)
UPCH	Unidade de Potência e Condicionamento Hidráulico

LISTA DE SÍMBOLOS

A_{01}	Área do orifício 1 da válvula	(m^2)
A_{02}	Área do orifício 2 da válvula	(m^2)
A_{03}	Área do orifício 3 da válvula	(m^2)
A_{04}	Área do orifício 4 da válvula	(m^2)
A_1	Área da secção transversal do êmbolo do pistão,	(m^2)
A_2	Área da secção transversal do êmbolo do pistão menos a área da secção transversal da haste do pistão	(m^2)
α	Inversa do percentual de erro de estimação da rede neural ao longo do tempo somado a um	
$\tilde{\alpha}$	Erro da estimação de α	
$\hat{\alpha}$	Estimação de α	
b	Vetor de bias da RN	
B	Coefficiente de atrito viscoso	(Ns/m)
b	Mapa direto das entradas na estratégia de linearização por realimentação	
b^{-1}	Mapa inverso das entradas na estratégia de linearização por realimentação	
B_{eq}	Coefficiente total de amortecimento equivalente (linearização)	(Ns/m)
β	Módulo de compressibilidade volumétrica efetivo	(Pa)
C	Coefficiente linear de amortecimento referente às perdas nas conexões de pressão	(Ns/m)
C_d	Coefficiente de descarga	
C_{l1}	Coefficiente de perda de carga no trecho 1	$(m^3/s/Pa)$
C_{l2}	Coefficiente de perda de carga no trecho 2	$(m^3/s/Pa)$
C_{l3}	Coefficiente de perda de carga no trecho 3	$(m^3/s/Pa)$
C_{l4}	Coefficiente de perda de carga no trecho 4	$(m^3/s/Pa)$

C_l	Coeficiente de perda de carga na tubulação	(m ³ /s/Pa)
δ	Percentual de erro de estimação da rede neural ao longo do tempo somado a um	
$\tilde{\delta}$	Percentual de erro de estimação da rede neural ao longo do tempo	
ΔP	Pressão diferencial entre as câmaras 1 e 2 do cilindro	(Pa)
ΔP_1	Perda de carga no trecho 1	(Pa)
ΔP_2	Perda de carga no trecho 2	(Pa)
ΔP_3	Perda de carga no trecho 3	(Pa)
ΔP_4	Perda de carga no trecho 4	(Pa)
ΔP_l	Perda de carga na tubulação	(Pa)
ΔP_{vri}	Pressão diferencial para qual a vazão nominal da válvula foi medida	(Pa)
$\Delta \mathbf{W}$	Matriz ou vetor da direção de minimização	
e	Erro da saída da RN	
ε	Erro de estimação da RN	
ε_a	Erro máximo admitido (objetivo do treinamento)	
E_p	Erro em relação ao padrão de treinamento p da rede neural	
E_t	Erro em relação ao conjunto total de padrões da rede neural	
η	Taxa de aprendizagem da rede neural	
\tilde{F}	Erro de força	(N)
f	Função de multiplicação dos estados na estratégia de linearização por realimentação	
F_A	Força de atrito do pistão	(N)
F_A'	Força de atrito modificada	(N)
F_{eq}	Força equivalente (linearização)	(N)
F_f	Ganho feedforward	
F_H	Força Hidráulica	(N)
\dot{F}_H	Derivada da Força Hidráulica	(N/s)

F_H'	Força Hidráulica Modificada	(N)
\tilde{F}_H	Erro de força hidráulica	(N)
F_{Hd}	Força hidráulica desejada	(N)
F_L	Força atuante na carga	(N)
F_S	Força nas velocidades limite no modelo do atrito viscoso variável	(N)
\dot{F}_{Hd}	Derivada da força hidráulica desejada	(N/s)
F_p	Força equivalente as perdas de carga nas conexões em T	(N)
f_v	Coefficiente de atrito viscoso variável	(Ns/m)
Γ	Matriz de ganhos de adaptação para o atrito modificado	
$\nabla \mathbf{E}_p$	Gradiente em relação a E_p	
$\nabla \mathbf{E}_t$	Gradiente em relação a E_t	
G_p	Ganho positivo da função de suavização do atrito	
G_n	Ganho negativo da função de suavização do atrito	
H_m	Coefficiente de amortecimento no subsistema mecânico resultante das perdas de carga	(Ns/m)
K_c	Coefficiente de vazão-pressão	(m ³ /s/Pa)
K_{c1}	Coefficiente de vazão-pressão na via 1	(m ³ /s/Pa)
K_{c2}	Coefficiente de vazão-pressão na via 2	(m ³ /s/Pa)
K_{cp}	Coefficiente de vazão-pressão simplificado	(m ³ /s/Pa)
K_D	Ganho derivativo (PID).	
K_d	Ganho do subsistema mecânico (estratégia em cascata)	
K_{fn}	Ganho feedforward negativo	
K_{fp}	Ganho feedforward positivo	
K_I	Ganho integral (PID)	

K_P	Ganho proporcional (PID),	
K_p	Ganho do subsistema hidráulico (estratégia em cascata)	
K_{pa}	Ganho de pressão	(Pa/m)
K_{pa1}	Ganho de pressão normalizado na via 1	(Pa/V)
K_{pa2}	Ganho de pressão normalizado na via 2	(Pa/V)
K_q	Coefficiente de vazão	(m ³ /s/m)
K_{q1}	Coefficiente normalizado de vazão na via 1	(m ³ /s/V)
K_{q2}	Coefficiente normalizado de vazão na via 2	(m ³ /s/V)
K_v	Coefficiente da válvula,	(m ³ /s/Pa ^{1/2})
K_{su}	Coefficiente da válvula [Valdiero, 2005]	(m ³ /s/V/Pa ^{1/2})
$K_{v,via}$	Coefficiente da válvula por via,	(m ³ /s/Pa ^{1/2})
K_{VA}	Coefficiente da válvula considerando u_{max} para a via 1	(m ³ /s/V/Pa ^{1/2})
K_{VB}	Coefficiente da válvula considerando u_{max} para a via 2	(m ³ /s/V/Pa ^{1/2})
l	Ganho de adaptação do mapa inverso	
λ	Ganho do subsistema mecânico (estratégia em cascata)	
M	Massa da carga + massa do pistão + massa do óleo nas mangueiras	(kg)
M_0	Massa estimada da carga + massa do pistão + massa do óleo nas mangueiras	(kg)
α_m	Momentum	
N_Y	RN que representa a razão vazões de controle/entrada	(m ³ /s/V)
N_Δ	RN que representa o atrito modificado no modelo	(N)
Ω	RN que representa o mapa inverso	(Vs/N)
ϖ_v	Frequência natural da válvula	(rad/s)
\dot{P}_1	Derivada da pressão na câmara 1	(Pa/s)

P_1	Pressão na Câmara 1 do cilindro	(Pa)
P_2	Pressão na Câmara 2 do cilindro	(Pa)
\dot{P}_2	Derivada da pressão na câmara 2	(Pa/s)
P_A	Pressão medida pelo sensor A.	(Pa)
\dot{P}_A	Derivada da pressão medida pelo sensor A.	(Pa/s)
P_{ac}	Pressão no acumulador	(Pa)
P_B	Pressão medida pelo sensor B.	(Pa)
\dot{P}_B	Derivada da pressão medida pelo sensor B.	(Pa/s)
ϕ	Vetor que representa a parcela não linear da rede neural	
P_{in}	Pressão de entrada na tubulação	(Pa)
P_{out}	Pressão de saída na tubulação	(Pa)
P_r	Pressão de referência	(Pa)
Ψ	Função logística sigmoidal	
P_S	Pressão de suprimento	(Pa)
P_{va}	Pressão imediatamente a jusante da saída 1 da válvula (via 1)	(Pa)
P_{vb}	Pressão imediatamente a montante da saída 2 da válvula (via 2)	(Pa)
Q	Vazão volumétrica	(m ³ /s)
Q_1	Vazão volumétrica na via 1	(m ³ /s)
Q_{1a}	Vazão volumétrica no orifício 1 da servoválvula	(m ³ /s)
Q_2	Vazão volumétrica na via 2	(m ³ /s)
Q_{2a}	Vazão volumétrica no orifício 2 da servoválvula	(m ³ /s)
Q_{3a}	Vazão volumétrica no orifício 3 da servoválvula	(m ³ /s)
Q_{4a}	Vazão volumétrica no orifício 4 da servoválvula	(m ³ /s)

Q_{in}	Vazão de entrada no acumulador	(m ³ /s)
Q_L	Vazão volumétrica para o cilindro simétrico operando com válvula simétrica	(m ³ /s)
Q_{out}	Vazão de saída no acumulador	(m ³ /s)
Q_v	Vazão volumétrica para obtenção do coeficiente da válvula	(m ³ /s)
Q_{vn}	Vazão nominal da válvula	(m ³ /s)
ρ	Massa específica do fluido	(kg/m ³)
ζ_v	Coeficiente de amortecimento da válvula	
T	Temperatura do fluido hidráulico	(°C)
Θ	RN que representa a compensação do atrito	(N)
u	Sinal de entrada da válvula	(V)
\mathbf{u}	Vetor de entrada RN	
u_{max}	Sinal máximo de entrada da válvula	(V)
v	Lei de controle aplicada a função linearizada na estratégia de linearização por realimentação	
V_1	Volume total da câmara 1	(m ³)
V_{10}	Volume inicial da câmara 1 do cilindro mais tubulações	(m ³)
V_2	Volume total da câmara 2	(m ³)
V_{20}	Volume inicial da câmara 2 do cilindro mais tubulações	(m ³)
V_c	Volume de controle do acumulador	(m ³)
v_{lim}	Velocidade limte para suavização do atrito	(m/s)
\mathbf{w}	Peso da RN	
w_p	Largura do pórtico da válvula (igual ao perímetro da camisa ou uma fração desse)	(m)
\mathbf{W}	Matriz ou vetor de pesos RN	
$\hat{\mathbf{W}}$	Matriz ou vetor de pesos estimado da rede neural	
$\tilde{\mathbf{W}}$	Erro da estimação da matriz ou vetor de pesos da rede neural	

x_v	Deslocamento do carretel da válvula	(m)
x_{vmax}	Deslocamento máximo do carretel da válvula	(m)
\mathbf{y}	Vetor de saída da RN	
y	Deslocamento do êmbolo do pistão	(m)
\ddot{y}	Aceleração do êmbolo do pistão	(m/s ²)
\ddot{y}_r	Aceleração de referência	(m/s ²)
\dot{y}_r	Velocidade de referência	(m/s)
\tilde{y}	Erro de posição.	(m)
y_d	Deslocamento desejado do êmbolo do pistão	(m)
\ddot{y}_d	Aceleração desejada do êmbolo do pistão	(m/s ²)
\dot{y}_d	Velocidade desejada do êmbolo do pistão	(m/s)
\dot{y}_0	Velocidade limite da região C para D no modelo do atrito viscoso variável	(m/s)
\dot{y}_{lim}	Velocidade limite da região B-D para A no modelo do atrito viscoso variável	(m/s)
z	Medida de erro de velocidade no seguimento de trajetória	(m/s)
Z	Soma do termo linear referente à parcela viscosa do atrito com o termo linear que representa a perda de carga nas conexões de pressão	(Ns/m)

1. INTRODUÇÃO

Os atuadores hidráulicos destacam-se por sua boa relação força/tamanho. A grande resistência mecânica dos atuadores, aliada à capacidade de produzir forças elevadas em comparação com a sua dimensão e à rapidez de resposta estão entre os principais atrativos desses sistemas. Os atuadores hidráulicos têm sido cada vez mais utilizados em aplicações que requerem precisão no controle, tais como: aeronaves [Karpenko e Sepehri, 2009], máquinas de produção [Pluta, 2008], testes de fadiga [Ruan et al., 2006], escavadeiras [Chiang e Huang, 2004], laminadoras de metal [Lo e Yang, 2004], sistemas automotivos [Pedro e Dahunsi, 2011], manipuladores robóticos [Yu et al., 2012], dentre outras. Existem, porém, características dos atuadores hidráulicos que dificultam seu controle em malha fechada em aplicações de alto desempenho [Vossoughi e Donath, 1995; Guenther e De Pieri, 1997; Virvalo, 2002]. O modelo matemático do sistema mostra que o mesmo apresenta diversas não linearidades importantes, tais como a relação entre a variável de controle e a vazão do óleo, a força de atrito entre as paredes do cilindro hidráulico e o pistão, os vazamentos internos do sistema e a zona morta e a saturação presentes nas válvulas de controle. Para permitir uma utilização mais eficiente, muitas técnicas de controle não linear têm sido largamente empregadas em atuadores hidráulicos. Devido a esse fato, muitos algoritmos de controle têm sido desenvolvidos buscando aumentar o desempenho em malha fechada dos atuadores hidráulicos e, com isso, ampliar o número de aplicações desses sistemas. O estudo do problema de controle do atuador hidráulico e a proposição e implementação de algoritmos de controle para melhorar o desempenho desses sistemas em malha fechada são o tema a ser tratado na presente tese.

1.1. Objetivos e enfoque da Tese.

Esta tese de doutorado tem como objetivo:

Propor contribuições teóricas em relação ao desenvolvimento de algoritmos aplicados ao controle de trajetória de posição em malha fechada de atuadores hidráulicos e comprovar, de forma experimental, a efetividade das soluções teóricas propostas.

Do ponto de vista teórico, propõe-se estratégias baseadas no conceito de sistemas inteligentes, mais particularmente, nas redes neurais artificiais, as quais já vêm sendo utilizadas em sistemas hidráulicos (consultar Watton, 2012, por exemplo). Porém, na bibliografia estudada, como é visto mais adiante, a representação da função que relaciona a vazão volumétrica com a variável de controle (e vice versa) só é encontrada na forma da equação do escoamento turbulento em orifícios [Watton, 2012] ou na forma de funções de mapeamento experimentais [Prabel e Aschemann, 2014]. A aplicação de redes neurais no caso do mapa inverso dessa função (sem englobar outras tantas características do sistema) é encontrada somente em Gervini, 2014, para atuadores pneumáticos. Na presente tese, desenvolve-se uma metodologia para que essa função possa ser representada por redes neurais. O controlador em cascata proposto por Guenther e de Pieri, 1997, e aperfeiçoado por trabalhos subsequentes [Cunha et al., 1998; Cunha et al., 2000; Cunha e Guenther, 2005; Cunha e Guenther, 2006; Coelho e Cunha, 2011] será, assim, modificado com a introdução dessa nova função. Em conjunto com essa proposta, aproveita-se também o potencial das redes neurais para a implantação de uma estratégia de compensação de atrito, baseando-se em trabalhos anteriores como Machado, 2003, e Gervini, 2014. Agrega-se, ainda, a essas funções a informação da temperatura do fluido hidráulico do sistema, utilizando a mesma como entrada nas redes neurais projetadas, visando, com isso, a tornar essas redes neurais propostas mais robustas em relação às variações de temperatura do fluido hidráulico. Com o objetivo de adaptar as redes neurais às variações paramétricas do sistema, a presente tese propõe uma metodologia simplificada de adaptação, baseada em trabalhos como Sadegh, 1993, Hayakawa, et al., 2008, onde uma base fixa não linear é utilizada e parâmetros lineares nas saídas das redes neurais são adaptados.

Do ponto de vista experimental, implementam-se, em uma bancada experimental composta por um cilindro diferencial comandado por meio de uma válvula simétrica, os algoritmos propostos e realizam-se comparações em relação ao desempenho dos mesmos com controladores clássicos e com o controlador em cascata fixo [Pereira, 2006].

1.2. O Servoposicionador Hidráulico

O servoposicionador em estudo é apresentado na Figura 1.1. Uma descrição sucinta de sua operação pode ser feita da seguinte maneira:

- Um sinal elétrico aplicado à servoválvula proporciona uma movimentação x_v do carretel proporcional ao seu valor. Um sinal elétrico positivo, por exemplo, desloca o carretel da válvula para a direita.

- O deslocamento do carretel libera parcialmente o orifício da servoválvula e provoca uma diferença de pressão entre P_S e a pressão P_1 , na câmara um do cilindro, originando uma vazão volumétrica Q_1 . Simultaneamente, o outro orifício da válvula também é liberado, provocando uma diferença de pressão entre P_2 , na câmara dois do cilindro, e a pressão P_r , originando uma vazão volumétrica Q_2 .

- A diferença entre as Pressões P_1 e P_2 provoca o surgimento de uma força proporcional a $A_1P_1 - A_2P_2$. Caso essa força seja capaz de vencer as demais forças contrárias (atrito, perturbações de força, etc), o pistão entrará em movimento (supondo o mesmo inicialmente em repouso).

- Quando um sinal elétrico maior é aplicado, o orifício de passagem na válvula torna-se maior, provocando o aumento das vazões volumétricas Q_1 e Q_2 e uma diferença de pressão maior entre P_1 e P_2 . A Força no pistão, por consequência, aumenta.

Juntamente com a capacidade volumétrica do sistema de suprimento, a pressão P_S determina a potência hidráulica disponível no sistema. As pressões P_1 e P_2 nas câmaras são determinadas pela pressão de carga do sistema e a mesma depende do balanço de forças no pistão, representado pela força F .

- A pressão de suprimento é fornecida por uma bomba hidráulica movida por meio de um motor elétrico. Essa pressão é regulada por uma válvula de alívio, a qual não está ilustrada na Figura 1.1.

- A pressão de retorno P_r é a pressão no tanque, normalmente considerada como referência (considerada, usualmente, a pressão atmosférica).

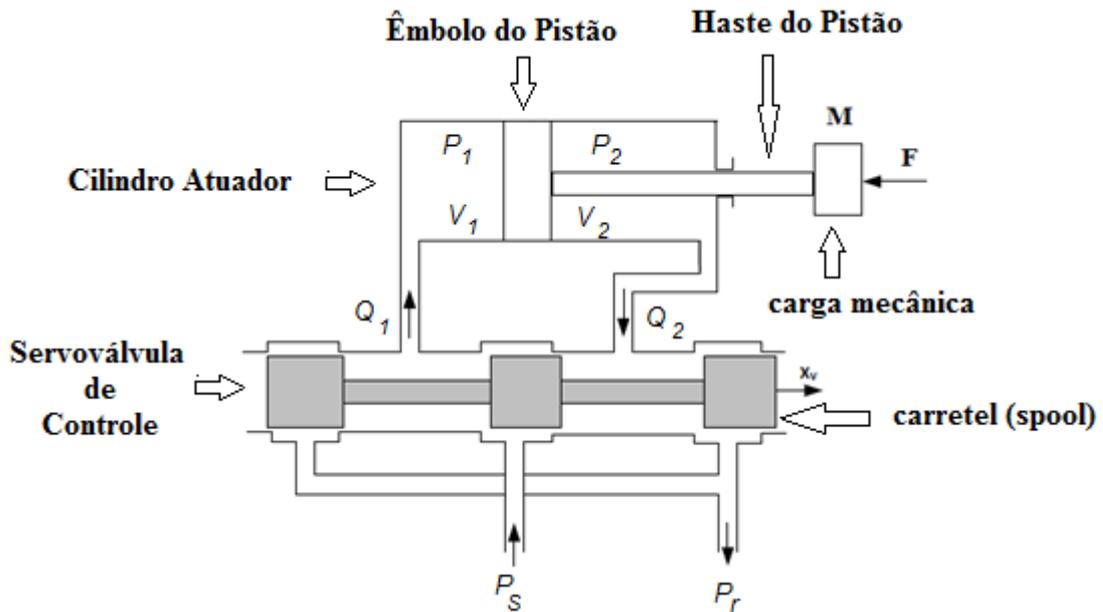


Figura 1.1 - Servoposicionador Hidráulico

A utilização de um cilindro de haste simples determina que as vazões Q_1 e Q_2 sejam diferentes durante a operação, pois as áreas transversais do lado do êmbolo sem haste e do lado em que se encontra a haste do pistão são diferentes. Em aplicações envolvendo cilindros desse tipo normalmente utilizam-se servoválvulas assimétricas [Pereira, 2006]. No caso do presente trabalho, a servoválvula utilizada é simétrica.

1.3. O Estado da Arte

Nesta seção apresenta-se um panorama de trabalhos que têm sido realizados na área de controle de alta precisão de atuadores hidráulicos. A ênfase será dada para as publicações recentes, que tenham contribuído para o avanço da pesquisa nessa área, procurando também indicar as referências clássicas em cada tópico.

A *Servoválvula* e a *Válvula Proporcional* são os elementos importantes na elaboração de um controle de alta precisão para um atuador hidráulico. Visando evitar interpretações equivocadas, é importante definir claramente o que são e quais as suas diferenças. Em Merrit, 1967, não há a citação do termo *válvula proporcional*. Segundo Jones, 1997, as válvulas proporcionais apareceram comercialmente na década de 1970, como uma opção de menor custo em relação às servoválvulas. Naquela época, também surgiram avanços fundamentais em relação às válvulas, como, por exemplo, a eletrônica embarcada, que, somados aos

avanços da década anterior, como a realimentação de posição do carretel e o aprimoramento dos motores de torque, os quais tornaram as válvulas menores e mais rápidas, deram impulso importante à aplicação de técnicas avançadas de controle em servoposicionadores hidráulicos. Trabalhos como Linsingen, 2001, e De Negri, 2001, destacam que os termos *servoválvula* e *válvula proporcional*, mesmo sendo possível uma classificação construtiva, encontram-se mais na esfera comercial, sendo mais importante a análise das características de cada válvula do que a sua classificação propriamente dita. Segundo Johnson, 2011, a norma ISO-5598 define ambos os dispositivos como válvulas eletricamente moduladas de controle contínuo, estabelecendo a diferença entre eles como sendo a de que a válvula proporcional apresenta zona morta igual ou superior a 3% do curso do carretel. Segundo o autor, a zona morta é equivalente a zona de sobreposição (*overlap*). Essa sobreposição, ainda que pequena, provoca uma alteração de vazão, descrita na Figura 1.2, que, segundo o autor, nem sempre é apresentada no catálogo dos fabricantes. Nessa questão é importante destacar que o termo *servo* (segundo dicionários léxicos) refere-se à presença de controle de posição e as suas derivadas. Assim, “servoválvula” implica também a presença de controle realimentado interno de posição do carretel.

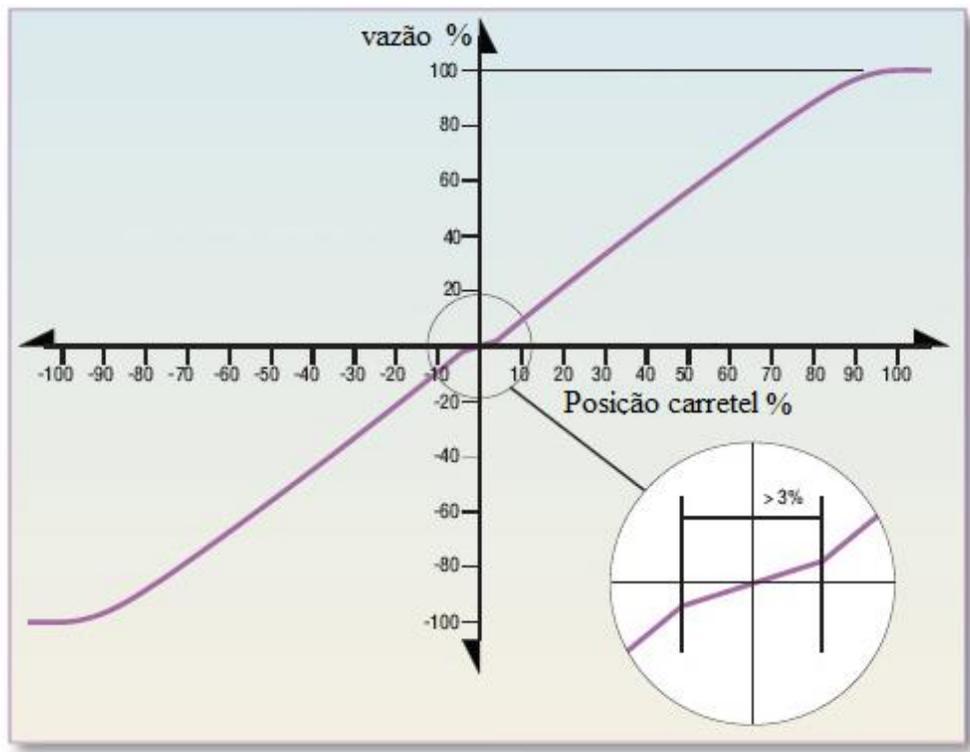


Figura 1.2 - Gráfico de vazão [Johnson, 2011]

Segundo Han, 2009, o controlador PID (Proporcional-Integral-Derivativo) domina a maioria das aplicações industriais. Alguns dos recentes trabalhos pesquisados, como Ghazali et al., 2011b, Seo et al., 2007, Pedro e Dahunsi, 2011, e Mintsá et al., 2012, usam o método de Ziegler-Nichols [Dorf e Bishop 2008], que não necessita do conhecimento preciso da planta para a sintonia dos ganhos do PID. Se sabe, porém, de alguns trabalhos [Yao e Ma, 2014; Ghazali et al., 2011a; Ghazali et al., 2011b; Guo et al., 2015] que o controlador PID apresenta limitações quanto ao cumprimento de exigências de controle mais rigorosas em relação ao erro de posição e no controle de seguimento de trajetórias em servoposicionadores hidráulicos. Essas limitações devem-se às características não lineares da planta a ser controlada e também à presença de polos complexos pouco amortecidos na planta em malha aberta no sistema linearizado (consultar, por exemplo, Paim, 1997).

Resume-se à seguir alguns trabalhos que utilizam controladores PID aplicados a atuadores hidráulicos:

- a) **Ghosh et al., 2015:** nesse trabalho é proposto um esquema com dois controladores PID auto-ajustáveis, através do uso de lógica *fuzzy*. Os controladores são aplicados em um esquema de controle de uma plataforma de nível. Nesse sistema, dois servoatuadores são responsáveis por manter a plataforma em um nível aproximadamente constante mediante perturbações de giro em torno de seu eixo central. Um algoritmo *fuzzy* recebe sinais de posição de dois sensores LVDT (*Linear Variable Differential Transformer*) e de velocidade por derivação numérica e calcula *on-line* o ganho dos controladores PID. Resultados experimentais para entradas constituídas de funções senoidais e em degrau são apresentados, comparando esquemas de controle com e sem adaptação dos ganhos. Os autores mostram que o esquema adaptativo apresenta resultados superiores em termos de rejeição de perturbações na posição da plataforma.
- b) **Ishak et al., 2011:** nesse trabalho os autores utilizam uma válvula proporcional que aciona um cilindro de haste simples, cujo deslocamento do pistão é medido por um transdutor linear de posição. O sistema é controlado por um PID, cujos ganhos são adaptados por meio de um algoritmo *fuzzy*, operando em tempo real.

Resultados experimentais para uma entrada em degrau e para entradas harmônicas são mostrados. Os controladores com e sem adaptação são comparados, apresentando melhor desempenho o controle com adaptação dos ganhos.

Apesar da melhoria dos resultados, os esquemas encontrados nos trabalhos supracitados não caracterizam controles de alta precisão, pois apenas ajustam os ganhos do controlador PID, sem, no entanto, propor uma melhora significativa nos resultados de controle, tal como Kaddissi et al., 2011, Ursu et al., 2013, Seo et al., 2007 e Mintsá et al., 2012, por exemplo. É conhecido na literatura [Guenther e De Pieri, 1997; Cunha, 1997; Mintsá et al., 2012] que ajustes nos ganhos do PID não alteram significativamente a performance do sistema.

Um outro controlador clássico aplicado em atuadores hidráulicos é o controlador por realimentação de estados. Um trabalho onde é utilizado tal controlador é Honkakorpi et al., 2013. Nesse trabalho, os autores utilizam um manipulador robótico de dois graus de liberdade acionado por válvulas do tipo servo solenóide (servoválvulas acionadas por solenóide e com retorno por mola). Uma massa de 475 kg é transportada pelo atuador desse manipulador. As válvulas utilizadas têm aproximadamente 100 Hz de banda de passagem. Segundo os resultados experimentais, uma melhora significativa é obtida em relação ao erro de seguimento de uma trajetória de posição em comparação ao mesmo resultado obtido fazendo uso de um controlador proporcional. A realimentação de estados utilizada é de posição, velocidade e aceleração (PVA), o que, segundo Cunha, 2001, é um esquema menos sensível a perturbações do que uma realimentação de posição, velocidade e pressão. Segundo Virvalo, 2002, o controlador PVA é capaz de conferir amortecimento ao sistema em malha fechada de um atuador hidráulico, pois, por meio da realimentação de estados, polos mais amortecidos podem ser escolhidos para sistema em malha fechada. Honkakorpi et al., 2013, propõem um encoder de baixo custo (de acordo com os autores) e de baixo ruído, para obter amostras de velocidade e posição angular (por integração numérica), permitindo, assim, que a aceleração seja estimada com maior precisão utilizando derivação numérica e mostra que o desempenho do sistema é semelhante ao obtido com um encoder sofisticado. Uma limitação, normalmente encontrada nesse tipo de controlador, é a dificuldade de uma estimação de aceleração pouco ruidosa para a realimentação de aceleração [Virvalo, 2002]. Os resultados mostram uma melhora significativa em relação ao controlador proporcional, quando no controle de seguimento de uma trajetória cartesiana de posição.

A limitação dos controladores clássicos levou os pesquisadores a buscarem soluções baseadas em controladores que fossem capazes de lidar com as não linearidades do sistema. As estratégias não lineares de controle são, em sua maioria, baseadas no conhecimento do modelo. Uma referência ainda muito utilizada no estudo de modelos em sistemas hidráulicos é o clássico livro de Merrit, 1967, que detalha os procedimentos de modelagem desses sistemas de posicionamento. Uma referência mais recente é o livro de Watton, 2012, que, além de discorrer sobre os conceitos básicos, já amplamente discutidos em Merrit, 1967, acrescenta algumas inovações construtivas incorporadas ao longo dos anos e, também, as técnicas mais avançadas de modelagem, como sistemas inteligentes (Redes Neurais e Lógica *Fuzzy*).

Com base nessas referências [Merrit, 1967; Watton, 2012] é possível afirmar que, genericamente, um sistema hidráulico de atuação é constituído de servoválvulas ou válvulas proporcionais simétricas que acionam cilindros de haste dupla ou motores hidráulicos. Alternativamente, pode ser constituído pelas mesmas válvulas, só que assimétricas, acionando cilindros de haste simples. Ambos os tipos de sistemas (simétrico e assimétrico) podem ser representados por um sistema de quarta ordem, conforme visto em Guo et al., 2015. Esse sistema pode ser reduzido para um sistema de terceira ordem através da utilização da diferença de pressão na carga ou da força hidráulica na carga como variável de estado, sendo que um sistema modelado dessa forma é encontrado nos trabalhos de Yao et al., 2014, Yao, et al., 2014b, Yao, et al., 2015, Rozali et al., 2012 e Prabel e Aschemann, 2014. Nesses trabalhos, a dinâmica da válvula é desprezada. Alguns autores, porém, consideram essa dinâmica como sendo de primeira ordem, como em Kaddissi et al., 2011, Ursu et al., 2013, Seo et al., 2007 e Mintsá et al., 2012. Encontram-se também na literatura trabalhos em que a dinâmica é considerada de segunda ordem, como em Kim et al., 2012 e Valdiero, 2005. Ambas as considerações aumentam a ordem do sistema.

Em relação às técnicas de controle não lineares, uma metodologia utilizada é a estratégia de controle baseada na Linearização por Realimentação, que consiste no cancelamento das não linearidades do sistema e a imposição de uma dinâmica linear para o mesmo [Slotine e Li, 1991; Isidori e Benedetto, 1996; Khalil, 2002]. Trabalhos como Alleyne e Hedrick, 1995 e Vossoughi e Donath, 1995, mostraram a efetividade da técnica quando aplicada a atuadores hidráulicos e também a necessidade da utilização de outras técnicas

conjuntas para conferir robustez ao sistema mediante o cancelamento não exato das não linearidades.

Resume-se à seguir alguns trabalhos que utilizam a estratégia da Linearização por Realimentação aplicada a atuadores hidráulicos:

- a) **Seo et al., 2007:** aborda-se nesse trabalho o controle em malha fechada de um motor hidráulico acionado por uma servoválvula, sendo esse motor hidráulico ligado a outro motor hidráulico que funciona oferecendo torque de carga, acionado em malha aberta. O sistema modelado é de quarta ordem, onde é considerada uma dinâmica de primeira ordem para a servoválvula que se encontra em malha fechada. A posição angular do motor e as pressões nas câmaras têm seus valores medidos através de sensores e a válvula fornece a medida de posição do seu carretel. Como controlador, é utilizado o esquema da Linearização por Realimentação, onde as não linearidades são canceladas e uma dinâmica linear é imposta utilizando uma realimentação de estados. A proposta do artigo é a de servir como um guia para o projeto de um controle utilizando linearização por realimentação aplicado a um servossistema eletrohidráulico. De fato, verifica-se nesse artigo a utilização de um modelo de atuador hidráulico onde se define como variáveis de estado a posição angular, a velocidade angular, a diferença de pressão nas câmaras do motor hidráulico e a posição do carretel da válvula e se demonstra passo a passo a aplicação da estratégia do controle de linearização por realimentação. Os autores mostram que o grau relativo do sistema [Khalil, 2002] é igual à ordem do sistema físico, o que possibilita a aplicação da linearização por realimentação de estados. Os mesmos aplicam ao sistema hidráulico o conceito de linearização de entrada-saída, descrita em Khalil, 2002. Dependendo da variável de estado a ser controlada, diferentes realimentações de estado são propostas na lei de controle linear. Por exemplo, caso o objetivo seja realizar o controle da posição angular do motor, utilizam-se trajetórias desejadas dessa variável de estado desde a primeira até a terceira ordem. Caso o objetivo seja controlar apenas a diferença de pressão nas câmaras, utilizam-se duas trajetórias desejadas, uma delas envolvendo a diferença de pressão desejada e outra envolvendo a derivada da diferença de pressão desejada. Para o cálculo do erro em tempo real, as derivadas da variável de

estado desejada são calculadas utilizando equacionamentos envolvendo as demais variáveis de estado do sistema, de acordo com a formulação descrita em Khalil, 2002, e no próprio artigo. Resultados experimentais são apresentados, comparando o controlador em questão com um controlador PID para o controle de trajetórias de posição angular, velocidade angular e diferença de pressão nas câmaras. Percebe-se uma melhora nos resultados de erro em relação à resposta do controlador PID, mas detalhes quantitativos do erro experimental não são fornecidos.

- b) **Mintsa et al., 2012:** os autores utilizam uma servoválvula para acionar um motor hidráulico do qual deseja-se controlar a posição angular seguindo uma trajetória senoidal desejada. Uma Linearização por Realimentação é utilizada. Para aumentar a robustez em relação as variações na pressão de suprimento no sistema, propõe-se a estimação de um parâmetro que represente essa pressão de suprimento na estratégia de controle e de um outro parâmetro, representando o módulo de compressibilidade volumétrica efetivo (*Bulk Modulus*). Uma lei de chaveamento desses parâmetros baseada no método direto de Lyapunov é proposta. Os resultados de simulação mostram melhoras em relação ao erro de seguimento de trajetória de posição angular com a utilização dos parâmetros de estimação propostos na lei de controle. Comparações também são realizadas mostrando uma melhora desse mesmo erro com relação à utilização de um controlador PID.
- c) **Fales e Kelkar, 2009:** um controlador utilizando Linearização por Realimentação em conjunto com um controlador H_∞ é utilizado na lei de controle de posição de dois graus de liberdade de uma retro-escavadeira. Os resultados de simulação apresentam uma análise de robustez do sistema.

Nos trabalhos supracitados, apenas Mintsa et al., 2012, procuram apresentar uma prova de estabilidade do controlador proposto mediante a ocorrência de incertezas paramétricas.

Um esquema de controle não linear que se mostra mais adequado à apresentação de uma prova formal de estabilidade é a técnica chamada de *Backstepping* [Khalil, 2002], que

consiste em um método sistemático de controle levando em conta as não linearidades do sistema e procurando uma lei de controle com base no método direto de Lyapunov. Trabalhos como Fialho e Balas, 1998, Alleyne e Liu, 2000, Sirouspour e Salcudean, 2000, e Yao et al., 2000, são exemplos de aplicação dessa técnica em atuadores hidráulicos.

Resume-se à seguir alguns trabalhos que utilizam a técnica do *Backstepping* aplicada a atuadores hidráulicos:

- a) **Kaddissi et al., 2011:** nesse trabalho os autores utilizam a estratégia de controle *Backstepping* em um controlador adaptativo. O sistema em questão é constituído de um motor hidráulico acionado por uma servoválvula. O sistema é de quarta ordem e a dinâmica da servoválvula é considerada no modelo como de primeira ordem. As equações de estado que representam a planta são divididas em quatro partes: subsistema posição/velocidade, subsistema hidráulico, subsistema mecânico e subsistema da válvula. Para a elaboração da lei de controle, aplica-se a metodologia do *Backstepping* a cada subsistema, determinando funções de Lyapunov e uma lei de controle de estabilização, de acordo com essa metodologia. Ao final, a estabilidade assintótica global é provada, mesmo na presença de um conjunto de parâmetros incertos, os quais são ajustados por uma lei de adaptação que garante a estabilidade do sistema. É demonstrado pelos autores que os parâmetros adaptados convergem em cerca de 1 s. Um dos problemas observados é a alta carga computacional, exigindo um período de amostragem inferior a 0,1 ms, o que faz com que se tenha de utilizar um *hardware* mais sofisticado. Resultados experimentais são apresentados para comprovar o desempenho do controlador. Uma lei de controle elaborada utilizando somente o *Backstepping*, sem o controlador adaptativo, apresenta resultados de desempenho de erro de seguimento de trajetória inferiores quando na ocorrência de uma alteração na carga (uma carga dez vezes maior é utilizada no experimento). As curvas experimentais apresentadas não permitem avaliar a ordem de grandeza da amplitude dos erros.
- b) **Yao et al., 2014a:** em tal trabalho os autores utilizam um observador de estados estendido capaz de estimar os estados do sistema e as suas incertezas paramétricas. Para tanto, o observador utiliza somente informações das entradas e saídas da planta.

Todos os estados do sistema não necessitam, portanto, estar disponíveis e, conseqüentemente, somente um sensor de deslocamento, tal como em um controlador PI, precisa ser utilizado. O sistema em estudo é constituído de uma servoválvula que aciona um motor hidráulico, sendo modelado matematicamente como de terceira ordem, não incluindo a dinâmica da servoválvula, que, no caso, possui largura de banda elevada (150 Hz). Para elaboração da lei de controle, é utilizado a metodologia do *Backstepping*. Os estados estimados e as incertezas paramétricas são fornecidos pelo estimador à lei de controle. Através da metodologia *Backstepping* é possível obter-se a prova de estabilidade assintótica do controlador. Resultados experimentais são apresentados comparando estatisticamente o desempenho entre o controlador apresentado e um controlador PI para o seguimento de trajetórias senoidais de posição angular desejada. O erro de seguimento de trajetória tem um valor máximo de aproximadamente 0,038 rad contra 0,050 rad do controlador PI. O desempenho do controlador proposto torna-se mais efetivo em relação ao do controlador PI quando são inseridas perturbações no sistema, pois é mostrado que o controlador em questão consegue manter os erros baixos mesmo com a presença de perturbações.

- c) **Yao et al, 2014b**: a mesma configuração experimental do artigo anterior é utilizada. utilizada. Um algoritmo adaptativo robusto (ARC) [Yao et al., 2000] é utilizado em conjunto com a formulação do *Backstepping* para garantir a adaptação de parâmetros e a estabilidade assintótica. A inovação proposta é a inclusão da representação dos vazamentos internos do sistema no modelo. Esses vazamentos são modelados por meio de uma equação polinomial, que é obtida variando-se a pressão de carga e medindo-se os vazamentos. Os autores não detalham o procedimento de medição dos vazamentos, o que geralmente não é trivial. Outra inovação é a inclusão de um termo integral na lei de controle, chamado termo integral robusto baseado no sinal de erro (RISE – *robust integral of the sign of the error*), que tem por objetivo compensar incertezas não estruturadas, tais como o atrito e as perturbações externas. Resultados experimentais são apresentados para o seguimento de trajetórias senoidais de posição angular desejadas. Para trajetórias lentas, percebe-se que o controlador proposto apresenta desempenho um pouco superior ao PID e ao controlador proposto por Yao et al., 2000, chamado de ARC, incluído pelos autores nas comparações de desempenho.

Para trajetórias rápidas percebe-se a vantagem das inovações. O benefício do controlador pode ser, portanto, considerado baixo, levando em consideração a sua grande complexidade matemática.

- d) **Yao et al., 2015:** nesse artigo um sistema constituído de uma servoválvula de 150 Hz de largura de banda acionando um cilindro de haste dupla é utilizado. A dinâmica da válvula é desprezada. Um controlador adaptativo robusto (ARC) é novamente aplicado em conjunto com a técnica do *Backstepping*, assim como em Yao et al, 2014b. Uma compensação de atrito e um modelo analítico que representa os vazamentos internos da válvula são considerados. Segundo a estratégia adotada, para a inclusão da compensação de atrito na lei de controle é necessário que a mesma seja continuamente diferenciável. O modelo Luge [Canudas de Wit, 1995] é utilizado, com uma modificação na função que representa o estado interno do sistema, o qual foi suavizada através de funções tangente hiperbólicas. Esse modelo Luge modificado é então incluído na lei de controle, juntamente com a função analítica que representa os vazamentos internos da válvula. Os parâmetros da função que representa o estado interno do modelo Luge e os parâmetros da função analítica são considerados como incertezas e são incluídos na estimação de parâmetros feita pelo algoritmo ARC. Um estudo matemático foi necessário para a obtenção da prova final de estabilidade. Os resultados experimentais de seguimento de trajetórias senoidais de posição desejadas mostram um melhor desempenho do controlador com compensação de atrito em relação à mesma estratégia sem compensação de atrito.
- e) **Guo e Zhang et al., 2016:** nesse artigo utiliza-se um observador de estados estendido em conjunto com a estratégia *backstepping*, de maneira semelhante como proposto em Yao et al., 2014a, no controle de trajetória de posição de um manipulador hidráulico de dois graus de liberdade. Como inovação, os autores consideram a dinâmica da válvula e provam que, por meio de uma adequada sintonia do parâmetro que representa a largura de banda do observador, é possível a rejeição de elevados valores de perturbações de força desconhecidas (e não somente conhecidas, como em Yao et al., 2014a) sem a saturação do sinal de controle da válvula. Resultados experimentais ilustram o desempenho do controlador mediante várias perturbações de força e

comprovam a efetividade do mesmo e a melhoria dos resultados em relação a um controlador PI.

- f) **Yang et al., 2016:** utiliza-se o controlador ARC, acrescido do termo RISE, aplicando a estratégia *Backstepping* para a formulação da lei de controle, como proposto em Yao et al., 2014b. Os autores introduzem uma modificação no controlador por meio da inclusão de um sinal de erro auxiliar na lei de controle, que tem por objetivo proporcionar estabilidade assintótica ao sistema em malha fechada mediante perturbações elevadas de força, as quais não se conhecem os limites. O sinal de erro auxiliar é utilizado para a adaptação do termo RISE (anteriormente descrito), de modo a proporcionar a rejeição de perturbações elevadas de força. Os autores chamam o novo controlador de AESRC (*auxiliary error signal robust-based adaptive controller*). O controlador é aplicado a um atuador hidráulico composto por um cilindro de haste dupla, acionado por uma servoválvula. Assim como em Yao et al., 2014b, os autores não consideram a dinâmica da válvula, utilizando uma modelagem de terceira ordem. A estabilidade assintótica em malha fechada é provada. Resultados experimentais indicam uma discreta melhora do controlador proposto em relação ao esquema utilizado em Yao et al., 2014b.
- g) **Guo e PingSun et al., 2016:** um manipulador robótico hidráulico de dois graus de liberdade, constituído de dois cilindros de haste simples acionados por duas servoválvulas, tem o seguimento de trajetórias desejadas no espaço de juntas controlado por meio de um controlador baseado na estratégia *backstepping*. Os torques, calculados por meio do método de Lagrange, são interpretados como forças de carga variáveis no modelo de cada atuador hidráulico. Os sinais de controle são fornecidos por meio de uma parametrização *backstepping*, que considera estratégias de adaptação *on-line* dos parâmetros estimados. A novidade proposta pelos autores é a utilização de um filtro com decaimento de memória, utilizado para calcular duas variáveis virtuais de controle e suas derivadas. Essas variáveis são utilizadas nas leis de adaptação e no cálculo do sinal efetivo de controle, realizado por meio de um controlador *backstepping* revisado, que utiliza as variáveis virtuais calculadas em conjunto com os parâmetros estimados. Os autores mostram que essa estratégia

constrói sinais de controle melhores que a estratégia *backstepping* tradicional. Resultados experimentais, realizados por meio do seguimento de trajetórias senoidais no espaço de juntas, mostram a efetividade do controlador mediante um controlador PID e um controlador *backstepping* tradicional.

A estratégia do controle por modos deslizantes (SMC) [Slotine e Li, 1991; Utkin, 1999] também é muito utilizada no controle de atuadores hidráulicos. Essa estratégia consiste em manter o erro de seguimento de trajetória em uma superfície de deslizamento, na qual o mesmo tenderá de forma assintótica a zero. Para forçar o erro a manter-se nessa superfície, normalmente é utilizado um controlador com estrutura variável.

Resume-se à seguir alguns trabalhos que utilizam a técnica do controle por modos deslizantes aplicada a atuadores hidráulicos:

- a) **Guan e Pan, 2008:** um controlador do tipo modo deslizante é aplicado a um atuador hidráulico constituído de um cilindro de haste dupla comandado por uma válvula do tipo servo solenoide. O pistão move uma massa de 100 kg, que está conectada a uma mola. O sistema é modelado matematicamente como sendo de terceira ordem, desconsiderando a dinâmica da válvula. Para a aplicação da lei de controle por modos deslizantes, a equação de estados é escrita considerando a posição, velocidade e aceleração como variáveis de estado. O controlador de modos deslizantes é elaborado contando com uma superfície de deslizamento de segunda ordem mais um termo integral do erro. Um controlador robusto com estrutura variável é projetado de modo a manter os estados dentro da superfície de deslizamento. É utilizada uma equação de suavização para atenuar as oscilações de alta frequência (*chattering*) resultante da ação de controle chaveada, um problema observado nos controladores com estrutura variável. O controlador de modos deslizantes é elaborado com base no método direto de Lyapunov, o que facilita a prova de estabilidade do mesmo. A inovação do artigo, porém, consiste na inclusão de uma nova incerteza no algoritmo de controle adaptativo, utilizado para a estimação das incertezas paramétricas que são inseridas na lei de controle. As incertezas paramétricas trabalhadas são semelhantes àquelas encontradas em outros trabalhos como Yao et al., 2000, e Yao et al., 2014b, porém, os autores incluem

também os volumes de óleo das linhas como incertezas, alegando que são difíceis de mensurar e que, quando significativos, afetam o desempenho do controle. A estabilidade assintótica global do sistema é provada. Resultados experimentais são apresentados com e sem a adaptação dos parâmetros, utilizando trajetórias senoidais de posição desejadas. É demonstrado que, se for utilizado um valor incorreto atribuído para o volume das linhas, o controlador sem adaptação aumenta consideravelmente os erros de seguimento. Não foi apresentada uma comparação em relação a um controlador PI ou PID, o que não possibilita saber o quanto a proposta dos autores representa em termos de melhora dos erros de seguimento em relação a um controlador clássico. O pico do erro de seguimento apresentado é de 0,05 mm para uma trajetória senoidal de 0,5 Hz e 100 mm de amplitude.

- b) **Xinliang et al., 2013**: um cilindro de haste simples com curso de 100 mm é acionado por uma servoválvula e move uma massa de 4 kg. Essa massa está conectada a um cilindro pneumático, o qual simula um distúrbio de força na carga. O sistema é modelado matematicamente como sendo de terceira ordem (desconsiderando a dinâmica da válvula) tendo como variáveis de estado a posição, a velocidade e a aceleração. O modelo é parametrizado em relação a um vetor de parâmetros incertos e são propostas leis de adaptação estáveis utilizando o método direto de Lyapunov. Um controlador por modos deslizantes, utilizando uma trajetória de deslizamento de segunda ordem, é proposto. Resultados experimentais são apresentados para uma trajetória senoidal de posição angular desejada de amplitude de 35 mm e frequência angular de 1 rad/s. A resolução apresentada pelos autores não permite quantificar com clareza os erros, mas percebe-se *chattering* importante presente nos resultados, o que é típico de controladores com estrutura variável. Os erros são comparados com a resposta de um controlador PID, sintonizado no limite dos modos oscilatórios, concluindo-se que uma melhora significativa de desempenho é percebida utilizando o controlador proposto. Na presença de uma perturbação de força, através do acionamento do cilindro pneumático, o controlador PID apresenta uma resposta oscilatória, enquanto o controlador proposto mantém-se operando com baixos erros de seguimento. Quando

na inserção da perturbação de força, o *chattering* parece tornar-se mais intenso nas curvas experimentais.

Uma estratégia de controle também utilizada em atuadores hidráulicos é a da divisão do sistema que constitui o modelo do atuador em subsistemas, de forma que leis de controle mais adequadas possam ser elaboradas para cada um desses subsistemas. Essa estratégia é denominada de Estratégia do Laço Interno e Externo (*inner loop/ outer loop*) ou Estratégia em Cascata. Os trabalhos de Heintze, 1997, Guenther e De Pieri, 1997, Honegger e Corke, 2001, são baseados nessa estratégia de controle. Cunha, 2001, mostra que é possível obter controladores similares utilizando tanto a abordagem em cascata quanto a técnica do *Backstepping*.

Resume-se à seguir alguns trabalhos que utilizam a estratégia em cascata aplicada a atuadores hidráulicos:

- a) **Guo et al., 2015:** nesse trabalho é realizado o controle de trajetória de posição de um cilindro hidráulico de haste simples acionado por uma válvula do tipo servo solenoide. A massa do sistema é conectada a um absorvedor de choque hidráulico. O controlador utilizado é sintetizado a partir de uma Estratégia em Cascata, onde no laço interno (subsistema hidráulico) utiliza-se a técnica do *Backstepping* e no laço externo (subsistema mecânico) utiliza-se o Controle de Modos Deslizantes. Ambas as estratégias são sistematizadas com base no método direto de Lyapunov, o que facilita a prova de estabilidade global do controlador. O modelo matemático considerado é de quarta ordem, sendo desconsiderada a dinâmica da válvula, a qual tem banda de passagem de aproximadamente 80 Hz. As equações de estado são escritas de modo que as pressões nas câmaras, a velocidade e a posição são os estados do sistema. A inovação proposta é a utilização de um observador de distúrbios estendido. Através desse observador, obtém-se o valor estimado da força de carga somada a distúrbios observados na mesma, como o atrito e perturbações de força. A força de carga é aquela fornecida pelo absorvedor de choque, que é modelado como um sistema de segunda ordem somado a uma parcela que concentra os demais distúrbios de força. Os parâmetros iniciais do observador são ajustados através de uma curva experimental. Um algoritmo de adaptação em tempo real

baseado no método direto de Lyapunov é então utilizado para observar a variação dessa força e ajustar os parâmetros. A estratégia é semelhante ao controle adaptativo por modelo de referência, utilizando-se, porém, o erro da força medida em relação à força estimada para o ajuste. A Força estimada pelo observador é utilizada na lei de controle, de modo a compensar os distúrbios de força e as variações paramétricas que afetam essa força. A estratégia é semelhante a uma compensação de atrito adaptativa, porém, efeitos de variação na carga oriundos do absorvedor de choque são também compensados. Resultados experimentais são apresentados comparando o controlador proposto com a mesma estratégia sem adaptação de parâmetros e também com a resposta de um controlador PI. Para todas as comparações são utilizadas trajetórias senoidais de posição desejada de 0,97 rad/s e 0,125 m de amplitude (pistão de 0,7 m de curso). Os resultados para o controlador com adaptação e sem adaptação são semelhantes para a situação onde não ocorre variação de carga, ou seja, quando o solenoide que aciona o absorvedor de choque está desligado. Os resultados para o controlador PI apresentam maiores erros de seguimento em relação aos demais controladores. Quando o solenoide é acionado, os resultados para o controlador com adaptação de parâmetros permanecem constantes, com erro máximo de aproximadamente 0,3 mm. Os resultados apresentados para o controlador sem adaptação sofrem um acréscimo importante em relação aos erros de seguimento. Utilizando uma mesma configuração experimental, são comparados os resultados do controlador ARC, proposto em Yao et al., 2000, com o controlador adaptativo proposto no artigo. A conclusão dos autores é que os resultados são semelhantes. Trajetórias onde o pistão permanece em regulação (parado na mesma posição) não são utilizadas e, portanto, não é possível analisar o controlador nessa situação.

- b) **Prabel e Aschemann, 2014:** dois cilindros hidráulicos são acoplados em série, cada um deles acionado por uma servoválvula diferente. Os cilindros movem, conjuntamente, uma massa acoplada a ambos (acoplada ao pistão do segundo cilindro). O modelo matemático do sistema é originalmente considerado de sexta ordem (desconsiderando a dinâmica das válvulas), mas, através do uso da pressão diferencial como variável de estado, é reduzido para quarta ordem. A equação da

vazão de controle das válvulas não é baseada na abordagem usual (que considera a função de vazão turbulenta em orifícios), utilizando uma função experimental, mediante um gráfico tridimensional que relaciona a vazão volumétrica, pressão e tensão de controle, uma abordagem semelhante à adotada em atuadores pneumáticos, como em Perondi, 2002. Um controlador baseado na Estratégia em Cascata é utilizado para o seguimento de trajetórias de força e de posição. A técnica do *Backstepping*, juntamente com um observador adaptativo de força, é utilizada no subsistema mecânico para fornecer a diferença de pressão desejada ao subsistema hidráulico. Um controlador baseado no *Backstepping* sem adaptação é utilizado no subsistema hidráulico. Com o auxílio da sistematização do *Backstepping*, leis de controle que garantem a estabilidade do controlador segundo o método direto de Lyapunov são propostas e leis de adaptação para o observador de força são elaboradas, possibilitando que a estabilidade assintótica global seja provada. Os resultados experimentais são referentes ao seguimento de trajetórias de posição e de força desejadas que compreendem uma combinação de funções polinomiais variadas, incluindo posições de regulação (pistão parado). Os resultados apresentam erros de posição na ordem de 0,05 mm. Os autores não apresentam os valores numéricos utilizados, nem os valores do conjunto de ganhos do controlador. Além disso, também não são fornecidos detalhes sobre os sensores utilizados.

- c) **Coelho e Cunha, 2011**: esses autores apresentam uma otimização no desempenho de um controlador em cascata, usando algoritmos evolucionários. A estratégia de controle é baseada em trabalhos anteriores [Cunha et al., 1998; Cunha et al., 2000; Cunha e Guenther, 2005; Cunha e Guenther, 2006] que apresentavam resultados experimentais e provas formais de estabilidade de controladores em cascata. Coelho e Cunha, 2011, utilizam o mesmo modelo teórico desses trabalhos, que representa um sistema no qual uma válvula proporcional com zona morta de cerca de 20% do curso do carretel aciona um cilindro hidráulico de haste dupla de 1 m de curso conectado a uma massa de 20,4 kg. Um controlador baseado na Estratégia em Cascata utiliza no subsistema mecânico uma lei de controle de Slotine e Li [Slotine e Li, 1991] e no subsistema hidráulico uma lei de controle baseada na linearização por realimentação. O modelo é de quarta ordem, com uma dinâmica de primeira

ordem atribuída à válvula. Um controle adaptativo por modelo de referência é utilizado, onde leis de adaptação baseadas no método direto de Lyapunov são elaboradas de modo a provar que o controlador apresenta estabilidade assintótica global. As incertezas adaptadas são os limites superior e inferior da zona morta, o coeficiente da válvula, a constante de tempo da válvula, a massa do sistema e o coeficiente de atrito viscoso. A novidade apresentada pelos autores é a inclusão de um algoritmo genético, que sintoniza os ganhos do controlador, de modo a minimizar os erros de posição. Resultados estatísticos utilizando o ITSE (*Integral Time Squared Error*) do erro de seguimento de posição mostram um melhor desempenho em simulações utilizando a sintonia automática dos ganhos em relação a uma sintonia manual. É importante a observação de que, como nesse artigo os autores usaram apenas simulações, o método carece de uma validação experimental, pois observa-se crescimento considerável de alguns ganhos que, em aplicações práticas, poderiam superar os valores aceitáveis.

A zona morta, presente principalmente nas válvulas proporcionais, é uma não linearidade bastante importante em relação à obtenção de um resultado de controle preciso. Uma metodologia simples e eficaz, bastante utilizada, é forçar o carretel a trabalhar fora da zona morta, por meio de uma função inversa da mesma, como por exemplo em Bu e Yao, 2000, Cunha, 2001, Valdiero, 2005 e Machado, 2010.

Resume-se à seguir alguns trabalhos que optam por compensar a zona morta em estratégias de controle aplicadas a atuadores hidráulicos:

- a) **Mohanti e Yao, 2011:** um controlador denominado *Integrated Direct Indirect Adaptive Robust Control* (DIARC), uma variação do conhecido ARC de Yao et al., 2000, utiliza um algoritmo adaptativo para estimar os limites da zona morta da válvula. O esquema é aplicado no controle de um manipulador hidráulico com dois graus de liberdade. Os resultados experimentais mostram que a adaptação proposta é efetiva e representa melhorias em relação ao *Indirect Adaptive Robust Control* (IARC), um algoritmo de adaptação indireta proposto pelos mesmos autores.

- b) **Bessa et al., 2010:** um controlador baseado na Linearização por Realimentação é aplicado em um atuador hidráulico constituído por uma válvula proporcional acionando um cilindro de haste dupla. Um termo de estimação de perturbações, composto por um algoritmo *fuzzy*, é proposto na lei de controle do sistema linearizado. Esse termo é estimado por uma lei de adaptação elaborada a partir do método direto de Lyapunov, garantindo a estabilidade do sistema. A lei de adaptação é vinculada ao erro do sistema. Segundo os autores, a função de estimação das perturbações proposta compensa os efeitos de uma zona morta desconhecida sem a necessidade de se dispor de uma inversa da mesma. Somente resultados de simulação mostrando a efetividade do esquema são apresentados.

Outra não linearidade importante advém dos efeitos dissipativos associados ao atrito. Testes experimentais mostram que efeitos referentes ao atrito viscoso, somam-se às características do atrito de Coulomb, do atrito estático e do efeito Stribeck [Canudas de Wit et al., 1995]. Assim, um modelo de atrito que seja capaz de representar esses fenômenos pode ser utilizado para compensar tais efeitos na lei de controle, como em Machado, 2003 e Valdiero, 2005. Um modelo usualmente utilizado em atuadores hidráulicos é o modelo Lugre, proposto por Canudas de Wit et al., 1995. Como trabalho recente pode ser citado Yao et al., 2015, (já comentado).

Conforme já apresentado, diversos controladores não lineares vêm sendo utilizados em atuadores hidráulicos em conjunto com estratégias de controle adaptativo, como o controle adaptativo por modelo de referência, com o intuito de superar o problema das incertezas paramétricas do modelo.

No caso dos chamados sistemas inteligentes, as estratégias mais utilizadas em controle de atuadores hidráulicos são a lógica *fuzzy* e as Redes Neurais Artificiais. Esses métodos alternativos representam funções não lineares, com a vantagem de possuírem estruturas mais simples (com menor complexidade matemática) e de necessitarem apenas de amostras do comportamento do sistema para serem desenvolvidos.

Os seguintes trabalhos utilizam esquemas de controle aplicados a atuadores hidráulicos com a utilização de lógica *fuzzy*:

- a) **Zhang e Gui, 2008:** um atuador hidráulico de haste dupla é utilizado para mover uma massa sobre um carro móvel. O sistema modelado é de terceira ordem (desconsiderando a dinâmica da válvula), sendo as equações de estado escritas considerando como variáveis a posição, velocidade e aceleração. Uma lei de controle baseada no Controle por Modos Deslizantes é proposta. As funções não lineares, utilizadas na lei de controle, são representadas por uma rede *neuro-fuzzy* recorrente, tendo como entradas posição, velocidade e aceleração. Esse tipo de rede é adaptativa. A inovação proposta é a utilização de uma lei de adaptação baseada no método direto de Lyapunov, na qual somente a última camada de pesos da rede, que é linear, é adaptada, sendo os demais pesos da rede mantidos fixos. Os autores provam a estabilidade do sistema de forma semelhante àquela do controle adaptativo por modelo de referência, apresentada por Slotine e Li, 1991, construída com base em uma função candidata a função de Lyapunov. É importante salientar que a única entrada medida é o deslocamento obtido por meio de um sensor indutivo de alto desempenho. A rede recorrente encarrega-se de construir os estados do sistema baseando-se em medidas de atraso dessa entrada e realimentações da saída da própria rede. Uma superfície deslizante de segunda ordem é utilizada em conjunto com um controlador com estrutura variável com ganho adaptativo, que também está incluído na prova de estabilidade do sistema. Resultados experimentais são apresentados para uma trajetória de seguimento de posição desejada senoidal, de 150 mm de amplitude e 0,3 rad/s de frequência (o curso do pistão é de 305 mm). Não são feitas comparações com controladores clássicos. Os autores mostram que o *chattering* do erro é reduzido consideravelmente quando o ganho do controlador com estrutura variável é adaptativo.
- b) **Bai e Li, 2010:** esses autores dão sequência ao trabalho de Zhang e Gui, 2008. A inovação proposta é a síntese do controlador com estrutura variável da lei de controle através de uma lógica *fuzzy* estática que, utilizando funções tangente hiperbólica, suaviza o *chattering* desse controlador. Os autores apresentam apenas resultados de simulação usando o modelo apresentado por Zhang e Gui, 2008, para uma trajetória senoidal. Comparações com um controlador clássico também não são apresentadas.

Alguns dos trabalhos utilizando Redes Neurais em atuadores hidráulicos tem-se baseado na teoria proposta por Naredra e Parthasarathy, 1990, segundo a qual um controlador neural, representado por uma rede recorrente, recebe um treinamento *on-line* que tem como função objetivo a minimização do erro do modelo de referência, retropropagado por meio de outra rede neural. Essa última representa o modelo do sistema. O erro é retropropagado para ajuste do controlador, que, usualmente, utiliza o algoritmo de *Levenberg-Marquardt* para ajuste dos pesos *on-line*. O controlador neural age como um controlador baseado na dinâmica inversa, representando a inversa do modelo. A estabilidade do sistema não é provada pelo método direto de Lyapunov, porém, em Levin e Naredra, 1996, os autores provam que, com amostras suficientes, o modelo é localmente observável e inversível e, portanto, a rede neural do controlador converge. Trabalhos nessa linha podem ser encontrados em Huang, et al, 1997, He e Sepehri, 1999, Knohl e Unbehauen, 2000, Hong et al, 2002.

Resume-se à seguir alguns trabalhos que utilizam esquemas de controle aplicados a atuadores hidráulicos com a utilização de redes neurais:

- a) **Pedro e Dahunsi, 2011:** nesse trabalho deseja-se controlar uma suspensão ativa constituída de uma servoválvula e um pistão de haste simples, posicionados entre o corpo do carro e o conjunto de rodas, as quais são representadas por duas massas. O modelo matemático do sistema é de sexta ordem. O objetivo do controle é que o pistão hidráulico siga um curso desejado para a suspensão, independente de distúrbios determinísticos provocados pela estrada. O curso da suspensão consiste em variações de posição ponto a ponto que devem obedecer a critérios pré-determinados como: tempo de subida, sobrepasso e erro de regime. Como controlador, é proposto um esquema baseado na Linearização por Realimentação, onde as funções utilizadas nessa estratégia são representadas por duas redes neurais recorrentes, treinadas *off-line* para obter os valores iniciais para os pesos e posteriormente adaptadas *on-line*. Como controlador virtual linear é utilizado uma estratégia de alocação de polos via realimentação de estados através de um polinômio Hurwitz, contendo as derivadas até terceira ordem do erro de posição, somadas à derivada de quarta ordem da referência. Não é apresentada prova de estabilidade. Simulações são apresentadas e comparações com o desempenho de um

controlador PID são realizadas. Uma melhora nos resultados da resposta da suspensão ativa em uma simulação considerando perturbações da estrada em relação à resposta de um controlador PID é apresentada.

- b) **Li et al., 2013:** nesse trabalho a rede neural recorrente normalmente utilizada como controlador para representar a inversa do modelo é substituída por um tipo de rede chamada *small-world neural network*. Essa rede necessita somente do sinal de erro como entrada. O restante do esquema é semelhante ao proposto por Naredra e Parthasarathy, 1990. Resultados experimentais são apresentados para um atuador hidráulico acionado por um motor DC (*pumped controlled*) e demonstram a efetividade do método para uma controle de posição ponto a ponto.
- c) **Yao et al., 2011:** nesse artigo uma servoválvula de dois estágios aciona um cilindro de haste simples. Como esquema de controle é utilizada uma rede neural Adeline recorrente que representa a inversa da planta. A rede Adeline tem somente uma camada e é treinada *on-line* através do algoritmo Widrow-Hoff LMS. O esquema é bastante semelhante ao proposto em Naredra e Parthasarathy, 1990. Resultados experimentais de erro de posição em relação ao seguimento de uma trajetória senoidal desejada são apresentados, mas não há comparações com outros controladores, o que dificulta quantificar esse erro.
- d) **Park et al., 2017:** os autores utilizam uma *echo-state network* (ESN), uma classe de rede neural recorrente, na qual os pesos internos não necessitam de treinamento supervisionado, sendo configurados para representarem um *reservoir*, que é conectado a uma camada externa linear, treinada por qualquer algoritmo de ajuste por regressão linear. Os pesos internos das ESN são em grande quantidade e permitem conexões recorrentes, o que proporciona memória à rede. Uma escavadeira, que é um manipulador hidráulico, é controlado por meio de um *framework* de duas ESN ajustadas *on-line*, sendo uma delas utilizada para representar a dinâmica inversa da planta e a outra para fornecer o sinal de controle. A planta é considerada totalmente desconhecida. Os autores não apresentam prova

formal de estabilidade do controlador. Resultados experimentais mostram a efetividade da estratégia quando comparada com um controlador PD.

- e) **Daachi et al., 2001**: os autores utilizam um controlador composto por uma rede neural que representa a inversa da planta e por um controlador linear. O esquema de controle é aplicado no seguimento de valores de força desejados para um atuador hidráulico. Uma lei de adaptação estável é proposta através da linearização da rede neural por séries de Taylor, levando em conta que os dois primeiros termos da série são suficientes para aproximação do comportamento da rede. Essa lei de adaptação baseia-se no método direto de Lyapunov. Desta forma, todos os pesos da rede são adaptados em tempo real. A estabilidade assintótica global do controlador é provada. Esse trabalho é baseado em Lewis et al., 1996.

Outro esquema de controle que vem sendo utilizado para atuadores hidráulicos é o uso de redes neurais do tipo RBF para a representação de não linearidades e elaboração de leis de controle. O uso de redes RBF para controladores não lineares foi proposto por Sanne e Slotine, 1992. A rede RBF apresenta somente duas camadas, sendo que a primeira camada não possui pesos, mas sim, funções gaussianas de base radial, cujos centros são definidos com base no comportamento não linear que se deseja reproduzir. O treinamento é não supervisionado. A camada de saída é uma combinação linear dessas funções de base, e seus pesos recebem um treinamento supervisionado, que pode ser realizado por meio de algoritmos de regressão linear (mínimos quadrados recursivo, média dos mínimos quadrados, etc) ou mesmo o *Backpropagation*. É uma Rede Neural que tem por característica velocidade maior de treinamento, mas, em contrapartida, seu espaço de pesos mapeia apenas uma região local no espaço de estados (consultar Haykin, 2001, por exemplo).

Resume-se à seguir alguns trabalhos que utilizam esquemas de controle aplicados a atuadores hidráulicos com a utilização de redes neurais do tipo RBF:

- a) **Zibin et al., 2008**: uma rede RBF é utilizada para estimação de incertezas em um esquema de controle utilizando o *Backstepping*. O atuador hidráulico é constituído por um cilindro de haste dupla, acionado por uma servoválvula. Os autores não fornecem detalhes e nem referências de como foi treinada a rede RBF (ou seja, como foram definidos os parâmetros das funções de base), mas estabelecem que os

pesos da camada de saída são incertezas do modelo. Para o ajuste dos pesos, uma lei de adaptação estável, dependente dos erros de posição, baseada no método direto de Lyapunov, é utilizada. A rede RBF não representa a inversa da planta, sendo essa função representada por meio de funções analíticas. A rede RBF considera todas as diferenças observadas entre os parâmetros nominais e os parâmetros estimados. A prova de estabilidade é semelhante à apresentada em outros trabalhos envolvendo *Backstepping*, como em Yao et al, 2000. São apresentados apenas resultados de simulação para trajetórias senoidais mistas de seguimento de posição desejada, que não oferecem uma idéia clara da dimensão do erro de posição. É possível identificar, apenas, que o controlador converge para um erro baixo de seguimento.

- b) **Yang et al., 2013:** uma rede neural do tipo RBF é utilizada para produzir um sinal de controle que minimiza o vetor de erros medido entre os estados oriundos de um observador linear de estados e os estados efetivamente medidos. Uma lei de adaptação, obtida pelo método direto de Lyapunov, é aplicada aos pesos da camada de saída linear da rede RBF. A novidade do esquema é a utilização conjunta com esse sinal de controle de um controlador linear somado a uma superfície de deslizamento de segunda ordem, em uma estratégia de controle de modos deslizantes. O controlador com estrutura variável que força o erro à superfície é suavizado por meio de funções tangente hiperbólicas. A estratégia trata-se, portanto, da combinação de três estratégias de controle. A estabilidade global assintótica é provada pelos autores. Experimentos são realizados em uma bancada que consiste de uma servoválvula e um pistão de haste simples movendo uma massa de 3,85 kg. Os resultados experimentais apresentam apenas erros de posição estatísticos utilizando como indicador o *absolute steady state error* e indicam que a resposta ao erro de seguimento de trajetórias senoidais de posição desejadas do controlador proposto possui resultados com melhor desempenho em relação à mesma estatística oriunda da resposta de um controlador PI.

As redes neurais também são utilizadas em atuadores hidráulicos para a compensação da zona morta como em Knohl e Unbehauen, 2000, e do atrito como em Machado et al., 2006. Outras estratégias de controle podem ser encontradas para atuadores hidráulicos como: controle robusto [Fales e Kelkar, 2009], controlador baseado na passividade [Kim et al., 2012], controlador por impedância [Heintze, 1997], entre outros. São estratégias menos utilizadas que as anteriormente citadas.

As tabelas 1.1, 1.2 e 1.3 sumarizam os artigos apresentados.

Tabela 1.1 – Contribuições de maior relevância de 2015 a 2017.

artigo	modelo	contribuição	prova de estabilidade
Gosh et al., 2015	haste simples, linearizado	lógica fuzzy para sintonia PID	não
Guan e Pan, 2015	haste simples, 4° ordem	esquema <i>backstepping</i> utilizando SMC. Utilização de um observador de força adaptativo com um absorvedor de choque para perturbações de força.	sim
Guo e PingSun et al., 2016	manipulador hidráulico, 2° L. haste simples, 4° ordem	esquema <i>backstepping</i> modificado, utilizando um filtro de decaimento de memória.	sim
Guo e Zhang et al., 2016	haste simples, 4° ordem	esquema de Yao et al., 2014a considerando a dinâmica da válvula e perturbações desconhecidas.	sim
Park et al., 2017	escavadeira, 2° L. haste simples, 3° ordem.	controlador baseado na dinâmica inversa utilizando uma rede neural adaptativa do tipo <i>echo-state network</i> .	não
Yang et al., 2016	haste dupla, 3° ordem	esquema de Yao et al., 2014b utilizando um termo adaptativo de compensação de perturbações de força desconhecidas.	sim
Yao et al., 2015	haste dupla, 3° ordem	controlador adaptativo robusto com modelo Lu Gre modificado, utilizando <i>backstepping</i> .	sim

Tabela 1.2 – Contribuições de maior relevância de 2011 a 2014.

artigo	modelo	contribuição	prova de estabilidade
Coelho e Cunha, 2011	haste dupla, 4° ordem	controlador em cascata com adaptação de parâmetros da válvula, zona morta, atrito e massa, com ganhos sintonizados por algoritmo genético.	em artigos anteriores
Honkakorpi et al., 2013	manipulador robótico, 2° L. haste simples, linearizado	efetividade de um PVA mediante um encoder de baixo ruído	não
Ishak, et al., 2011	haste simples, linearizado	lógica fuzzy para sintonia PID	não
Kassidi, et al., 2011	motor hidráulico, 4° ordem	controlador adaptativo auto-ajustável utilizando <i>backstepping</i> .	sim
Li et al., 2013	<i>pumped controlled</i> , 3° ordem	controlador baseado na dinâmica inversa utilizando uma rede neural adaptativa do tipo <i>small world</i> .	não
Mintsa, et al., 2012	motor hidráulico, 4° ordem	estimação da Pressão de suprimento e bulk modulus. <i>feedback linearization</i> .	sim
Mohanti e Yao, 2011	manipulador hidráulico, 2° L. haste simples, 3° ordem	um controlador denominado Integrated Direct Indirect Adaptive Robust Control (DIARC), uma variação do conhecido ARC de Yao et al., 2000, utiliza um algoritmo adaptativo para estimar os limites da zona morta da válvula.	sim
Pedro e Dahunsi, 2011	suspensão ativa	<i>feedback linearization</i> por meio de um controlador <i>neural</i> adaptativo <i>MLP</i> .	não
Prabel e Aschemann, 2014	dois cilindros de haste dupla em série, 4° ordem	observador de força adaptativo com <i>backstepping</i> . Função experimental de representação do difeomorfismo.	sim
Xiliang, et al., 2013	haste simples, 3° ordem	SMC testado mediante perturbações de força geradas por um atuador pneumático.	sim
Yang et al., 2013	haste simples, 3° ordem	rede RBF adaptativa ajustada pelo erro de um observador linear de estados, somada a outras duas entradas de controle: um controlador linear e um SMC.	sim
Yao et al., 2011	haste simples, 3° ordem	controlador baseado na dinâmica inversa utilizando uma rede neural adaptativa do tipo Adeline.	não
Yao et al., 2014a	motor hidráulico, 3° ordem	observador de estados estendido, controlador adaptativo robusto, utilizando <i>backstepping</i> .	sim
Yao et al., 2014b	motor hidráulico, 3° ordem	esquema de Yao et al., 2014a com um termo RISE e considerando os vazamentos internos.	sim

Tabela 1.3 – Contribuições de maior relevância anteriores a 2011.

artigo	modelo	contribuição	prova de estabilidade
Bai e Li, 2010	haste dupla, 3° ordem	esquema de Zhang e Gui, 2008, propondo um SMC <i>fuzzy</i> para redução do <i>chattering</i> .	sim
Bessa et al., 2010	haste dupla, 3° ordem	Utiliza <i>feedback linearization</i> . Um termo de estimação de perturbações, ajustado por um algoritmo <i>fuzzy</i> , é proposto na lei de controle do sistema linearizado, compensando a zona morta.	sim
Daachi e Sirdi, 2001*	não apresentado	controlador baseado na dinâmica inversa utilizando uma rede neural adaptativa do tipo <i>MLP</i> .	sim
Fales e Kelkar, 2009	escavadeira, 2° L. haste simples, 3° ordem.	controlador H infinito em conjunto com <i>feedback linearization</i> .	não
Guan e Pan, 2008	haste dupla, 3° ordem	SMC em conjunto com controlador adaptativo que estima o volume nas linhas.	sim
Seo, et al., 2007	motor hidráulico, 4° ordem	referência para aplicação do <i>feedback linearization</i> .	não
Zhang e Gui, 2008	haste dupla, 3° ordem	<i>feedback linearization</i> por meio de um controlador <i>neuro-fuzzy</i> adaptativo. SMC é utilizado para conferir robustez em malha fechada.	sim
Zibin et al, 2008	haste dupla, 3° ordem	rede RBF adaptativa para compensação de erros e perturbações em uma estratégia <i>backstepping</i> .	sim

1.4. Organização do Trabalho

Este trabalho está dividido como segue: No Capítulo 2, o modelo matemático do sistema e todos os levantamentos necessários ao mesmo são apresentados. Um modelo utilizando redes neurais para a função da vazão de controle da válvula e para a representação da força de atrito também é proposto. No Capítulo 3, são abordadas as técnicas de controle mais utilizadas em atuadores hidráulicos. No Capítulo 4, os controladores propostos no presente trabalho e as respectivas metodologias de projeto são descritas. No Capítulo 5, são apresentados os resultados experimentais obtidos. No Capítulo 6, as conclusões sobre a contribuição do presente trabalho são apresentadas e propostas futuras de trabalho são discutidas.

2. MODELAGEM DO SISTEMA DINÂMICO.

O procedimento de modelagem matemática de um atuador hidráulico já é conhecido, sendo descrito em trabalhos como Merrit, 1967, Heintze, 1997, De Negri, 2001, Cunha, 2001, Valdiero, 2005 e Watton, 2012. Esses autores dividem o modelo em dois conjuntos distintos de equações: um conjunto relativo aos fenômenos inerentes à parte hidráulica, onde são tratados os fenômenos relativos às vazões e às pressões, e um outro conjunto relativo à parte mecânica, onde a modelagem trata dos fenômenos relativos à posição, força, velocidade e aceleração do pistão hidráulico. O conjunto completo de equações de ambas as formas forma o modelo matemático completo do atuador hidráulico. Em adição a essas equações as quais regem o comportamento dinâmico do sistema, alguns termos adicionais estarão presentes. Dentre esses, destacam-se a dinâmica da válvula proporcional que dirige o pistão hidráulico, a zona morta existente no carretel da válvula, a dinâmica das tubulações que interligam a unidade hidráulica com a válvula e essa com o pistão, os vazamentos internos e externos da válvula, o atrito existente entre o êmbolo do pistão e a parede do cilindro hidráulico e as variações de temperatura do fluido hidráulico. A abordagem dispensada a esses termos adicionais no modelo matemático determina a maior ou menor complexidade do mesmo.

Neste capítulo, apresenta-se a modelagem matemática do servoposicionador hidráulico utilizado no presente trabalho, onde se descreve os processos de equacionamento e validação utilizados.

O presente capítulo é organizado da seguinte maneira: Na Seção 2.1 são descritos os procedimentos e hipóteses adotadas para a obtenção de um modelo matemático que represente o tipo de servoposicionador hidráulico utilizado no presente trabalho. Na Seção 2.2, descreve-se o equacionamento de um modelo linearizado para o servoposicionador da Seção 2.1. Na Seção 2.3, aborda-se a bancada experimental utilizada no presente trabalho, onde descreve-se o processo de equacionamento e obtenção dos parâmetros do modelo da Seção 2.1 aplicado a essa bancada. Na Seção 2.4, o modelo obtido na Seção 2.3 é validado por meio de simulações e medidas experimentais. Na Seção 2.5, adota-se uma abordagem ao modelo da Seção 2.3 na qual alguns termos não lineares do mesmo são substituídos por redes neurais, embasando, desta forma, a proposta desta tese. Na Seção 2.6, uma comparação entre os modelos analítico e neural da bancada experimental, utilizando simulações e medidas experimentais, é estabelecida. Na Seção 2.7 são apresentadas as discussões finais do capítulo.

2.1. Modelo analítico não linear do servoposicionador hidráulico.

O modelo matemático desenvolvido no presente trabalho é baseado nos trabalhos de Merrit, 1967, Heintze, 1997, De Negri, 2001, Cunha, 2001, Valdiero, 2005, Watton, 2012 e mais especificamente no trabalho de Pereira, 2006, que trata da modelagem em cilindros diferenciais ou assimétricos. A Figura 2.1 mostra o diagrama hidráulico no qual se baseia o modelo e que serve de referência para o mesmo.

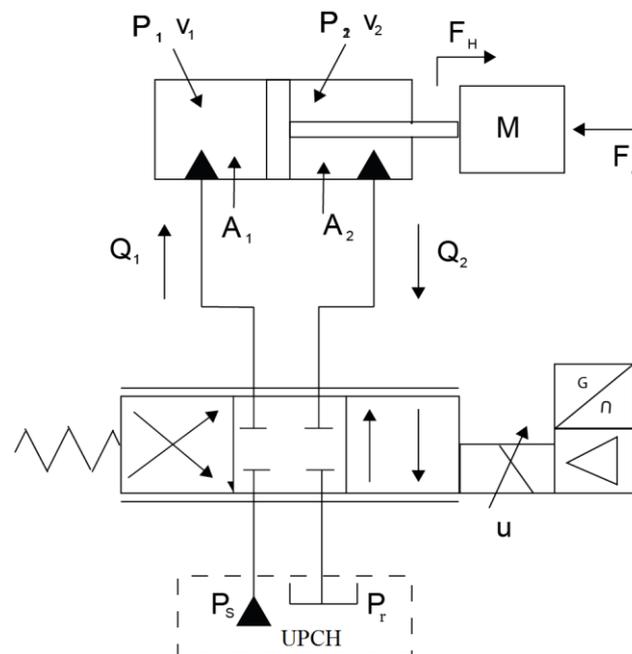


Figura 2.1 - Circuito hidráulico da bancada experimental.

Na Figura 2.1, as pressões P_1 e P_2 são as pressões nas câmaras do cilindro hidráulico (Pa), os volumes V_1 e V_2 são os volumes de fluido hidráulico nas respectivas câmaras (m^3), as áreas A_1 e A_2 são as áreas de secção transversal do pistão hidráulico, do lado do êmbolo e do lado da haste, respectivamente (m^2), Q_1 e Q_2 são as vazões volumétricas nas vias 1 e 2 (m^3/s), P_s é a pressão de suprimento (Pa), P_r a pressão de referência (Pa), F_H é a força hidráulica (N), F_A é a Força de atrito (N), u é o sinal de entrada da servoválvula (V).

Para fins de modelagem do sistema, as seguintes hipóteses simplificadoras são assumidas:

- 1) Todos os orifícios da válvula são iguais e simétricos;
- 2) A válvula e o cilindro não apresentam vazamentos internos e externos;
- 3) A dinâmica das tubulações existentes entre a unidade de potência hidráulica e a válvula e entre a válvula e o cilindro não influenciam na resposta dinâmica do sistema;
- 4) A resposta da válvula é considerada ideal (o movimento do carretel da mesma responde imediatamente às variações do sinal de entrada na válvula) ;
- 5) A pressão de suprimento é constante;
- 6) A temperatura do fluido hidráulico é constante;
- 7) A zona morta ou *overlap* entre o carretel e o orifício de passagem é desprezível;
- 8) O centro hidráulico da válvula é considerado ideal;
- 9) A histerese da válvula é desconsiderada.

A seguir, detalha-se alguns dos fenômenos envolvidos nessas hipóteses simplificadoras e o equacionamento dos subsistemas hidráulico e mecânico, chegando-se, por fim, ao modelo completo do servoposicionador hidráulico:

2.1.1. Efeito da dinâmica nas tubulações.

Um estudo mais detalhado sobre a dinâmica das tubulações pode ser encontrado em Watton, 2012. O efeito dessas dinâmicas é considerado significativo em linhas de transmissão longas. O autor apresenta um método prático de determinação da influência dessas dinâmicas baseando-se na razão entre a largura de banda do sistema mecânico e a largura de banda do sistema hidráulico. No presente trabalho, não foi feito um estudo em relação às dinâmicas das linhas, mas a utilização de linhas de transmissão curtas entre os elementos permite considerar a hipótese que esse efeito é pequeno, podendo ser desconsiderado.

2.1.2. Vazamentos internos da válvula.

Os efeitos dos vazamentos internos da válvula são, de acordo com Linsingen, 2001, mais significativos em válvulas de centro crítico e subcrítico e alteram o comportamento do sistema quando o carretel encontra-se próximo da posição central. Existem modelos que consideram os vazamentos internos da válvula, como em Pereira, 2006. O autor mostra que a consideração de tal efeito proporciona uma melhora nos resultados experimentais do controle de trajetória de posição do atuador hidráulico. Conforme se observa nos trabalhos experimentais de Pereira, 2006 e Szpack, 2008, a fidedignidade observada com essa modificação não compensa o seu custo em relação ao aumento da complexidade do modelo e da prova de estabilidade. Por essa razão os vazamentos internos da válvula não são considerados no presente trabalho.

2.1.3. Dinâmica associada à válvula

As válvulas proporcionais e as servoválvulas trabalham com um sinal elétrico aplicado em sua entrada, que é traduzido por um circuito eletrônico e por solenoides ou motores de torque em um deslocamento do carretel. Segundo Merrit, 1967, Virvalo, 2002, e Watton, 2012, a esse processo está associada uma dinâmica que, dependendo da aplicação do controle, deve ou não ser considerada. Alguns trabalhos [Valdiero, 2005; Muraro, 2010; Szpack, 2008; Kim et al., 2012] consideram uma dinâmica de segunda ordem dada pela Equação (2.1) como uma representação adequada para a dinâmica da válvula:

$$x_v(s) = \frac{K\varpi_v^2}{s^2 + 2\zeta_v\varpi_v s + \varpi_v^2} u(s), \quad (2.1)$$

onde x_v é a posição do carretel (m), u é o sinal de entrada da válvula (V ou A), ζ_v é o coeficiente de amortecimento e ϖ_v é a frequência natural da válvula (rad/s).

Os parâmetros ζ_v e ϖ_v são obtidos experimentalmente ou através do catálogo do fabricante. O ganho K normalmente é incorporado ao coeficiente da válvula, que é descrito posteriormente. Em Cunha, 2001, afirma-se que, em alguns casos, desconsidera-se a dinâmica da válvula se essa é cerca de 20 vezes superior à largura de banda desejada do sistema. O

autor fornece um estudo detalhado da influência da dinâmica da válvula no sistema e conclui que a mesma limita os valores máximos dos ganhos dos controladores em cascata utilizados por aquele autor. De acordo com Furst, 2001, em projetos hidráulicos costuma-se relacionar a escolha da válvula com a frequência natural do cilindro hidráulico. Furst, 2001, recomenda para o projeto hidráulico a escolha de uma válvula cuja frequência natural seja no mínimo três vezes superior a frequência natural não amortecida do cilindro hidráulico utilizado.

Para os casos em que se considera a dinâmica da válvula ideal, atribui-se que $x_v = Ku$, ou seja, o deslocamento do carretel é proporcional ao sinal de entrada. No presente trabalho, como o ganho K é incorporado ao coeficiente da válvula, considera-se $x_v = u$.

O Apêndice A descreve o processo de determinação experimental da dinâmica da servoválvula utilizada no presente trabalho.

2.1.4. Zona morta

A zona morta é uma relação estática entrada-saída na qual para uma faixa de valores de entrada não há saída [Merrit, 1967; Valdiero, 2005]. A zona morta ocorre principalmente em válvulas com centro supercrítico, onde há sobreposição (*overlap*) do carretel sobre o orifício, mas pode ocorrer também devido a imperfeições na construção da válvula [Merrit, 1967]. Segundo Cunha, 2001, as cartelas eletrônicas utilizadas no acionamento das válvulas proporcionais normalmente possuem ajustes que permitem a compensação de sua zona morta. Em servoválvulas, onde a zona morta não passa de 3% do curso máximo do carretel [Johnson, 2011], observa-se em trabalhos como Yao et al., 2015, Guo et al., 2015, Xinliang et al., 2013, que a mesma é normalmente desconsiderada no modelo. No presente trabalho desconsidera-se a zona morta devido ao fato da mesma possuir dimensão reduzida (entre -1% e 2% do curso total do carretel), conforme pode ser constatado por meio da determinação experimental da zona morta, apresentada no Apêndice A.

2.1.5. Centro Hidráulico da Válvula e Histerese.

O centro hidráulico da válvula (*null*) é o ponto onde, com o carretel centralizado, as pressões nas portas A e B da válvula são iguais [Muraro, 2010]. O centro hidráulico em uma válvula simétrica pode ser identificado quando, no ensaio com as portas 1 e 2 bloqueadas,

tendo como referência a norma ISO 10770-1, 2009, mede-se a pressão na porta A como sendo igual à pressão na porta B. O sinal elétrico de entrada u deve corresponder a zero volts nessa situação, caso contrário, um ajuste de *offset* deve ser realizado [Muraro 2010]. O mesmo ensaio pode ser utilizado para determinar também a histerese da válvula.

2.1.6. Temperatura do fluido hidráulico.

Segundo Martin, 1995, a temperatura do fluido hidráulico influencia principalmente em sua viscosidade, que é a característica do mesmo que determina a sua resistência ao escoamento. O escoamento é, portanto, facilitado ou retardado de acordo com a viscosidade do fluido hidráulico.

A Figura 2.2 ilustra graficamente as faixas ideais de temperatura e correspondente viscosidade de alguns fluidos hidráulicos comerciais utilizados.

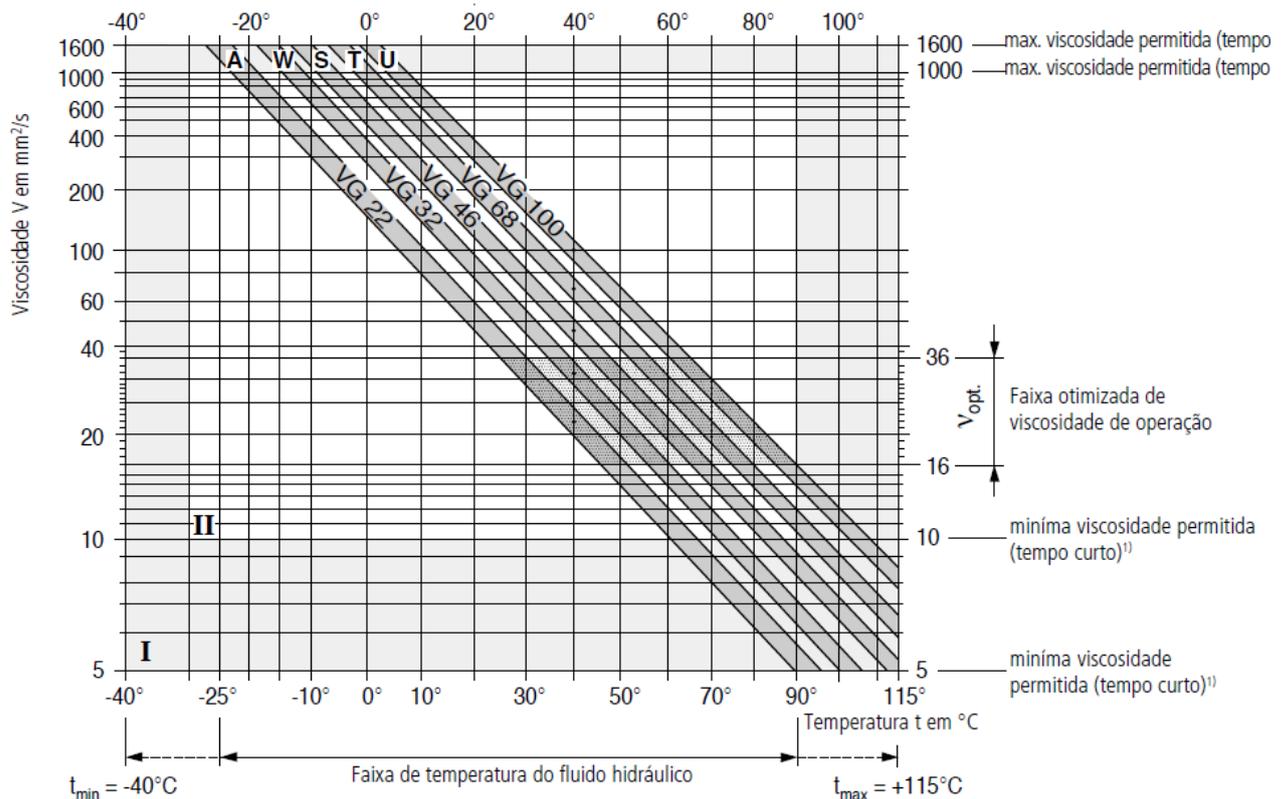


Figura 2.2 – Viscosidade versus temperatura de alguns fluidos hidráulicos (Bosch Rexroth).

Com base em Watton, 2012, afirma-se que a escolha adequada do fluido hidráulico é parte importante do projeto hidráulico.

Com base em Fitch, 2002, afirma-se que uma solução típica, normalmente aplicada em projetos hidráulicos, é o controle da temperatura do fluido por meio de um trocador de calor, mantendo o mesmo em uma temperatura estável de operação.

No presente trabalho, considera-se a temperatura do fluido hidráulico constante para efeitos de modelagem. Posteriormente, no Capítulo 4, são apresentadas estratégias de controle que consideram a variação de temperatura no fluido hidráulico.

2.1.7. Equacionamento do subsistema hidráulico.

Como comentado anteriormente, adota-se no presente trabalho o procedimento de divisão do modelo completo do servoposicionador hidráulico em dois subsistemas: o subsistema hidráulico e o subsistema mecânico. O subsistema hidráulico será dividido também em dois conjuntos de equações. O primeiro conjunto trata do equacionamento dos fenômenos relativos à vazão nos orifícios da válvula de 4 vias. O tratamento matemático dispensado a outros tipos de válvulas como, por exemplo, a válvula de 3 vias, pode ser encontrado em autores como Merrit, 1967, e não é abordado no presente trabalho. O segundo conjunto de equações trata da dinâmica das pressões no cilindro hidráulico, sendo desenvolvido de forma semelhante para todos os tipos de cilindros.

2.1.7.1. Equacionamento da vazão nos orifícios da válvula direcional.

Por meio da Figura 2.3, ilustra-se a operação de uma válvula de 4 vias. Esse tipo de válvula possui 4 orifícios de passagem que são bloqueados pelo carretel na posição central.

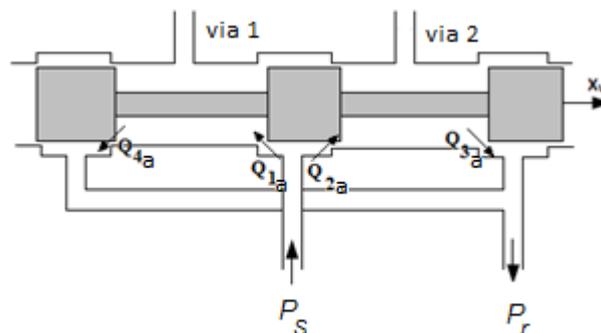


Figura 2.3 - Válvula de 4 vias.

Na Figura 2.3, Q_{1a} , Q_{2a} , Q_{3a} e Q_{4a} são as vazões volumétricas nos orifícios de 1 a 4 da servoválvula (m^3/s).

O equacionamento desenvolvido, nesta seção, tem como referência o trabalho de Merrit, 1967, que posteriormente é replicado por outros autores, como De Negri, 2001. Em relação às perdas nas mangueiras e conexões, o equacionamento é baseado nos trabalhos de Spazk, 2008, e Muraro, 2010.

Tomando-se por base a Figura 2.3 e considerando que o carretel da válvula sofre um deslocamento x_v positivo, os orifícios 1 e 2 são então parcialmente desobstruídos pelos ressaltos do mesmo, liberando as vazões Q_{1a} e Q_{3a} , as quais obedecem à equação da vazão em orifícios [Watton, 2012] descrita por meio da Equação (2.2). Com base nessa equação, as vazões Q_{1a} e Q_{3a} são descritas por meio das equações (2.3) e (2.4). De forma análoga, ao se acionar o carretel, estabelecendo um deslocamento x_v negativo, as vazões Q_{4a} e Q_{2a} serão liberadas. Ambas são descritas respectivamente por meio das equações (2.5) e (2.6).

$$Q = C_d A_0 \sqrt{\frac{2(\Delta P)}{\rho}}, \quad (2.2)$$

onde Q é vazão no orifício (m^3/s), C_d é o coeficiente de descarga, A_0 é a área do orifício (m^2), ρ é a massa específica do fluido (kg/m^3) e ΔP é a diferença de pressão entre a montante e a jusante do orifício (Pa). As vazões Q_{1a} a Q_{4a} podem ser, portanto, expressas por:

$$Q_{1a} = C_d A_{01} \sqrt{\frac{2(P_s - P_1)}{\rho}}, \quad (2.3)$$

$$Q_{3a} = C_d A_{03} \sqrt{\frac{2(P_2)}{\rho}}, \quad (2.4)$$

$$Q_{2a} = C_d A_{02} \sqrt{\frac{2(P_s - P_2)}{\rho}}, \quad (2.5)$$

$$Q_{4a} = C_d A_{04} \sqrt{\frac{2(P_1)}{\rho}}, \quad (2.6)$$

onde P_S é a pressão de suprimento (Pa), P_1 é pressão na Câmara 1 (Pa) e P_2 é a pressão na Câmara 2 (Pa). Q_{1a} é a vazão no orifício 1 (m^3/s), Q_{2a} é a vazão no orifício 2 (m^3/s), Q_{3a} é a vazão no orifício 3 (m^3/s), Q_{4a} é a vazão no orifício 4 (m^3/s). A_{01} é a área do orifício 1 (m^2), A_{02} é a área do orifício 2 (m^2), A_{03} é a área do orifício 3 (m^2) e A_{04} é a área do orifício 4 (m^2).

Como os quatro orifícios são considerados iguais, se pode concluir que as áreas A_{01} e A_{03} serão iguais, bem como as áreas A_{02} e A_{04} . Considerando ainda que a válvula não apresenta vazamentos internos, tem-se as seguintes expressões para as vazões nas vias 1 e 2:

$$Q_1 = C_d A_{01} \sqrt{\frac{2}{\rho}} h_1, \quad (2.7)$$

$$Q_2 = C_d A_{02} \sqrt{\frac{2}{\rho}} h_2, \quad (2.8)$$

onde Q_1 é a vazão volumétrica na via 1 (m^3/s), Q_2 é a vazão volumétrica na via 2 (m^3/s) e as funções h_1 e h_2 são expressões não lineares dependentes da direção x_v do carretel, definidas por meio das equações (2.9) e (2.10) :

$$h_1 = \begin{cases} x_v \geq 0 \rightarrow \sqrt{P_S - P_1} \\ x_v < 0 \rightarrow \sqrt{P_1} \end{cases}, \quad (2.9)$$

$$h_2 = \begin{cases} x_v \geq 0 \rightarrow \sqrt{P_2} \\ x_v < 0 \rightarrow \sqrt{P_S - P_2} \end{cases}, \quad (2.10)$$

onde x_v = deslocamento do carretel (m).

Considerando que os orifícios sejam retangulares, as áreas A_{01} e A_{02} podem ser expressas pela Equação (2.11) [De Negri, 2001].

$$A_{01} = A_{02} = w_p x_v, \quad (2.11)$$

onde w_p é a largura do pÓrtico (igual ao perÍmetro da camisa ou uma fração desse) (m) e x_v é o deslocamento do carretel da vÁlvula (m).

O coeficiente da vÁlvula K_v , cuja obtenção é descrita a seguir, é normalmente usado na modelagem matemática em substituição aos parÁmetros geométricos da vÁlvula.

Para se obter K_v , considera-se que as vazões Q_1 e Q_2 sejam iguais e que exista uma pressão diferencial constante ΔP entre os orifícios. A vazão da vÁlvula, nessa condição, pode ser determinada por:

$$Q_v = C_d w_p \cdot x_v \sqrt{\frac{\Delta P}{\rho}}. \quad (2.12)$$

Por meio de experimentos descritos na norma ISO-10770-1, 2009, a condição descrita anteriormente citada é reproduzida e são obtidos valores experimentais e uma representação gráfica da Equação (2.12), representação essa que é geralmente fornecida nos *data-sheets* das vÁlvulas. Segundo o procedimento descrito na referida norma, o sinal de entrada u da vÁlvula sofre uma variação do valor mÍnimo até o seu valor mÁximo para uma mesma pressão diferencial, medindo-se os pares vazão e sinal de entrada, obtendo-se, dessa forma, o gráfico de vazão versus sinal de entrada da vÁlvula para uma determinada pressão diferencial fixada. A vazão nominal da vÁlvula é obtida quando o sinal de entrada u se encontra em seu valor mÁximo, operando na pressão diferencial estabelecida. O coeficiente da vÁlvula K_v é então determinado por:

$$K_v = \frac{Q_{vn}}{\sqrt{\Delta P_{vn}}} = C_d w_p \cdot x_{v_{max}} \sqrt{\frac{1}{\rho}}, \quad (2.13)$$

onde K_v é o coeficiente da vÁlvula ($m^3/s/Pa^{1/2}$), Q_{vn} é a vazão nominal da vÁlvula (m^3/s), ΔP_{vn} é a pressão diferencial para qual a vazão nominal foi medida (Pa) e $x_{v_{max}}$ o deslocamento mÁximo do carretel (m).

O coeficiente da vÁlvula K_v pode ser determinado para uma queda de pressão total na vÁlvula ou para uma queda de pressão parcial, por via, conforme descrito por Furst, 2001. A relação entre um dado coeficiente da vÁlvula por via e o coeficiente total K_v para uma vÁlvula de 4 vias é determinado por [Furst, 2001]:

$$K_{v,via} = \sqrt{2}K_v, \quad (2.14)$$

onde $K_{v,via}$ é o coeficiente da válvula por via ($\text{m}^3/\text{s}/\text{Pa}^{1/2}$).

O coeficiente da válvula K_v definido em Furst, 2001, e por meio da Equação (2.13) é utilizado para a escolha da válvula no projeto hidráulico conforme o referido autor, porém, a sua utilização na substituição dos parâmetros geométricos nas equações (2.7) e (2.8) requer a normalização do sinal de entrada da válvula u em relação ao seu valor máximo u_{max} .

Sendo a válvula considerada ideal, as equações (2.7) e (2.8) que expressam as vazões nas vias podem ser reescritas adotando os coeficientes da válvula por via e diretamente o sinal de entrada da válvula normalizado, resultando nas seguintes expressões:

$$Q_1 = K_{v1,via} \frac{u}{u_{max}} h_1, \quad (2.15)$$

$$Q_2 = K_{v2,via} \frac{u}{u_{max}} h_2, \quad (2.16)$$

onde u é o sinal de entrada da válvula (V) e u_{max} é o sinal máximo de entrada da válvula (V), $K_{v1,via}$ é o coeficiente da válvula na via 1 ($\text{m}^3/\text{s}/\text{Pa}^{1/2}$) e $K_{v2,via}$ é o coeficiente da válvula na via 2 ($\text{m}^3/\text{s}/\text{Pa}^{1/2}$).

As funções h_1 e h_2 são expressões não lineares dependentes agora da entrada u , descritas por:

$$h_1 = \begin{cases} u \geq 0 \rightarrow \sqrt{P_s - P_1} \\ u < 0 \rightarrow \sqrt{P_1} \end{cases}, \quad (2.17)$$

$$h_2 = \begin{cases} u \geq 0 \rightarrow \sqrt{P_2} \\ u < 0 \rightarrow \sqrt{P_s - P_2} \end{cases}. \quad (2.18)$$

O equacionamento das vazões nos orifícios nos trabalhos de Cunha, 2001, Valdiero, 2005, Pereira, 2006, Yao, Deng e Jiao, 2015, Prabel e Aschemann, 2014, não leva em consideração as perdas de carga referentes as mangueiras e conexões. Essa simplificação

deve-se ao fato de haver um adequado dimensionamento do diâmetro desses elementos no projeto hidráulico dos atuadores utilizados, de modo que tais perdas são consideradas pequenas. O presente trabalho, assim como em Spazk, 2008, e Muraro, 2010, tem como aparato experimental bancadas didáticas que utilizam mangueiras, subplacas de montagem e conexões de engate rápido, elementos que, segundo os autores supracitados, provocam perdas de carga no sistema.

Em Muraro, 2010 e Szpack, 2008 as perdas de carga são modeladas considerando a equação que descreve matematicamente o comportamento das perdas de carga contínuas através das mangueiras e dutos do sistema, de Linsingen, 2001. Porém, segundo Linsingen, 2001, existem também outras perdas, não lineares, associadas ao circuito hidráulico. A consideração somente das perdas contínuas constitui, portanto, uma linearização do comportamento das perdas de carga do sistema, onde um fator de perda C_l , proporcional a vazão, é definido, de acordo com a Equação (2.19), para a pressão de entrada e saída da tubulação.

$$\Delta P_l = P_{in} - P_{out} = \frac{1}{C_l} \cdot Q, \quad (2.19)$$

onde ΔP_l é a perda de carga na tubulação (Pa) e C_l o coeficiente de perda de carga na tubulação ($\text{m}^3/\text{s}/\text{Pa}$).

Adota-se, no presente trabalho, a representação das perdas de carga por meio da Equação (2.19). Esse procedimento é justificado pela dificuldade de ajuste dos termos não lineares referentes às perdas de carga, dificuldades essas atribuídas à medição experimental das mesmas, como é discutido na Seção 2.3.5.

Com base na Equação (2.19), propõe-se, no presente trabalho, o dimensionamento das perdas de carga por meio da divisão dos trechos de perda em 4 trechos distintos, ilustrados pelas cores azul, roxo, amarelo e vermelho, na Figura 2.4.

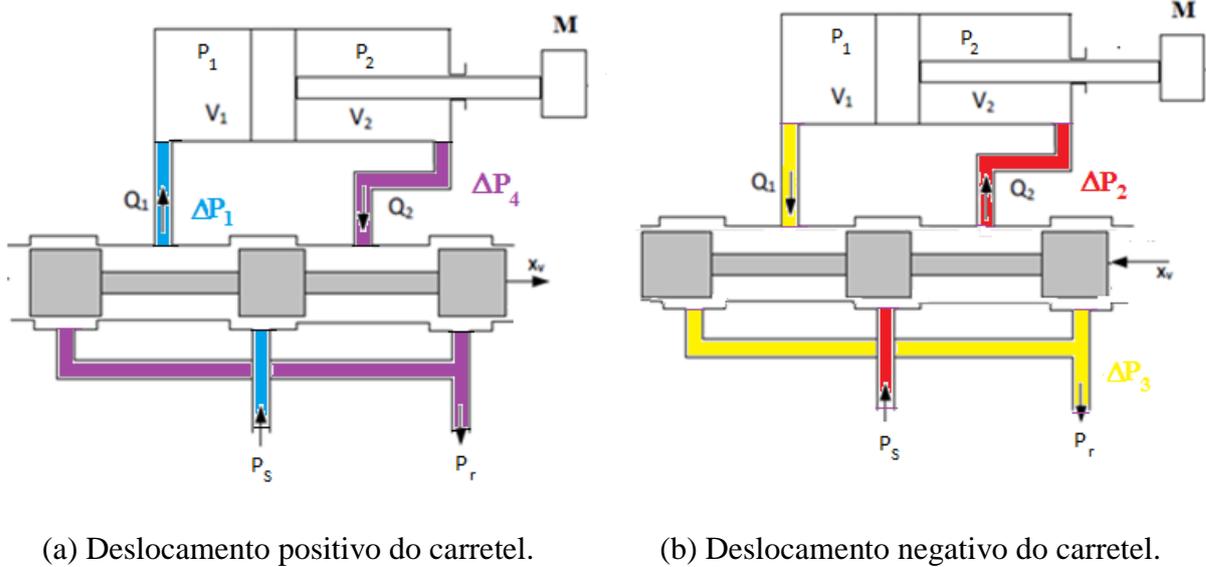


Figura 2.4 – Trechos com perdas de carga.

Considerando uma única perda de carga e um único coeficiente C_l em cada trecho ilustrado na Figura 2.4, tem-se que estas perdas podem ser representadas por meio das equações (2.20) a (2.23):

$$\Delta P_1 = \frac{1}{C_{l1}} \cdot Q_1, \quad (2.20)$$

onde ΔP_1 é a perda de carga do trecho 1 (azul) (Pa) e C_{l1} é o coeficiente de perda de carga ($\text{m}^3/\text{s}/\text{Pa}$).

$$\Delta P_2 = \frac{1}{C_{l2}} \cdot Q_2, \quad (2.21)$$

onde ΔP_2 é a perda de carga do trecho 2 (vermelho) (Pa) e C_{l2} é o coeficiente de perda de carga ($\text{m}^3/\text{s}/\text{Pa}$).

$$\Delta P_3 = \frac{1}{C_{l3}} \cdot Q_1, \quad (2.22)$$

onde ΔP_3 é a perda de carga do trecho 3 (amarelo) (Pa) e C_{l3} é o coeficiente de perda de carga ($\text{m}^3/\text{s}/\text{Pa}$).

$$\Delta P_4 = \frac{1}{C_{l4}} \cdot Q_2, \quad (2.23)$$

onde ΔP_4 é a perda de carga do trecho 4 (roxo) (Pa) e C_{l4} é o coeficiente de perda de carga ($\text{m}^3/\text{s}/\text{Pa}$).

As Equações (2.17) e (2.18) do sistema sem perdas de carga são redefinidas de modo a considerarem as perdas em cada trecho ilustrado na Figura 2.4:

$$g_1 = \begin{cases} u \geq 0 \rightarrow \sqrt{(P_s - P_1 - \Delta P_1)} \\ u < 0 \rightarrow \sqrt{P_1 - \Delta P_3} \end{cases}, \quad (2.24)$$

$$g_2 = \begin{cases} u \geq 0 \rightarrow \sqrt{P_2 - \Delta P_4} \\ u < 0 \rightarrow \sqrt{(P_s - P_2 - \Delta P_2)} \end{cases}. \quad (2.25)$$

2.1.7.2. Equacionamento das pressões no cilindro assimétrico.

Com base no princípio da conservação de massa, que estabelece que o fluxo líquido de massa através de uma superfície de controle é igual à variação de massa no interior de um volume de controle [Linsingen, 2001], considerando a hipótese de que o cilindro não possui vazamentos internos, pode-se usar a Equação (2.26), definida como Equação da Continuidade [Watton, 2012], a fim de se obter a expressão das vazões em função das variações de pressão nas câmaras do cilindro:

$$Q_{in} - Q_{out} = \dot{V}_c + \frac{V_c}{\beta} \dot{P}_{ac}, \quad (2.26)$$

onde Q_{in} é a vazão de entrada no acumulador (m^3/s), Q_{out} é a vazão de saída no acumulador (m^3/s), V_c é o volume de controle do acumulador (m^3) e P_{ac} é a pressão no acumulador (Pa) e β é o módulo de compressibilidade volumétrica efetivo (Pa).

Aplicando-se a equação da continuidade para o volume das câmaras 1 e 2 do cilindro, obtém-se:

$$Q_1 = \dot{V}_1 + \frac{V_1}{\beta} \dot{P}_1, \quad (2.27)$$

$$-Q_2 = \dot{V}_2 + \frac{V_2}{\beta} \dot{P}_2, \quad (2.28)$$

onde V_1 é o Volume total da Câmara 1 (m^3), V_2 é o Volume total da Câmara 2 (m^3).

Os volumes das câmaras, V_1 e V_2 , são expressos em função dos volumes iniciais V_{10} e V_{20} , os quais incluem os volumes das tubulações que ligam essas câmaras às saídas da válvula e dos volumes gerados pelo deslocamento y do êmbolo do cilindro em relação à posição inicial de referência, resultando em:

$$V_1 = V_{10} + A_1 y, \quad (2.29)$$

$$V_2 = V_{20} - A_2 y, \quad (2.30)$$

onde V_{10} é o volume inicial da câmara 1 do cilindro mais o volume das tubulações (m^3) e V_{20} é o volume inicial da câmara 2 do cilindro mais o volume das tubulações (m^3), A_1 é a área da secção transversal do êmbolo do pistão (m^2), A_2 é a área da secção transversal do êmbolo do pistão menos a área da secção transversal da haste do pistão (m^2) e y é o deslocamento do êmbolo do cilindro em relação à posição de referência (m).

As derivadas das vazões volumétricas em relação ao tempo são:

$$\dot{V}_1 = A_1 \dot{y}, \quad (2.31)$$

$$\dot{V}_2 = -A_2 \dot{y}, \quad (2.32)$$

onde \dot{y} é a velocidade do êmbolo do cilindro.

Aplicando as equações (2.15) e (2.16) em (2.27) e (2.28), tem-se:

$$\dot{P}_1 = \left(K_{v1,via} \frac{u}{u_{max}} g_1 - A_1 \dot{y} \right) \frac{\beta}{V_1}, \quad (2.33)$$

$$\dot{P}_2 = - \left(K_{v2,via} \frac{u}{u_{max}} g_2 - A_2 \dot{y} \right) \frac{\beta}{V_2}, \quad (2.34)$$

onde \dot{P}_1 é a derivada da pressão na câmara 1 (Pa/s) e \dot{P}_2 é a derivada da pressão na câmara 2 (Pa/s).

Por meio da Equação (2.35) determina-se o valor da força hidráulica no pistão em função das pressões P_1 e P_2 :

$$F_H = P_1 A_1 - P_2 A_2, \quad (2.35)$$

onde F_H é a Força Hidráulica no pistão (N).

Por conveniência, considera-se:

$$K_{VA} = \frac{K_{v1,via}}{u_{max}}, \quad (2.36)$$

$$K_{VB} = \frac{K_{v2,via}}{u_{max}}, \quad (2.37)$$

onde K_{VA} é o coeficiente da válvula considerando u_{max} para a via 1 ($m^3/s/V/(Pa)^{1/2}$) e K_{VB} é o coeficiente da válvula considerando u_{max} para a via 2 ($m^3/s/V/(Pa)^{1/2}$).

A derivada da Equação (2.35) permite a simplificação das equações (2.33) e (2.34) em uma só expressão, sendo tal expressão descrita por meio da Equação (2.38). Essa representação é importante para a utilização do controlador em cascata, sendo utilizada por Pereira, 2006.

$$\dot{F}_H = \dot{P}_1 A_1 - \dot{P}_2 A_2 = (A_1 f_1 K_{VA} g_1 + A_2 f_2 K_{VB} g_2) u - (A_1^2 f_1 + A_2^2 f_2) \dot{y}, \quad (2.38)$$

onde as expressões f_1 e f_2 são determinadas por meio de (2.39) e (2.40):

$$f_1 = \frac{\beta}{V_{10} + A_1 y}, \quad (2.39)$$

$$f_2 = \frac{\beta}{V_{20} - A_2 y}. \quad (2.40)$$

2.1.8. Equacionamento do subsistema mecânico.

O movimento do pistão do cilindro hidráulico diferencial é modelado através da Segunda Lei de Newton (Equação do Movimento) e resulta em:

$$F_H = M\ddot{y} + F_A + F_L, \quad (2.41)$$

onde M é a massa da carga + massa do pistão (kg), F_A é a força de atrito do pistão (N), F_L é uma força que atua sobre a carga (N) e \ddot{y} é a aceleração do êmbolo do pistão (m/s^2). OBS: o cilindro encontra-se na horizontal e não sofre os efeitos da força de gravidade.

Maiores detalhes em relação ao comportamento da força de atrito, com os diferentes fenômenos que compõem a mesma, poderão ser encontrados no Apêndice B.

Devido a sua simplicidade em relação a outros modelos de atrito, como o modelo Lugre [Perondi, 2002, Canudas de Witt, 1995], o modelo do coeficiente de atrito viscoso variável proposto por Gomes e Da Rosa, 2003, é utilizado no presente trabalho como representação do atrito para simulações (não é utilizado na compensação do atrito no controle da trajetória de posição). A descrição detalhada desse modelo pode ser encontrada em Machado, 2003. Tal modelo propõe um mapeamento estático para o atrito, sendo que o coeficiente de mapeamento entre entrada e saída é variável e dependente da velocidade e da força instantâneas medidas na massa deslocada, como é ilustrado por meio da Figura 2.5, que representa as trajetórias possíveis seguidas pela força de atrito.

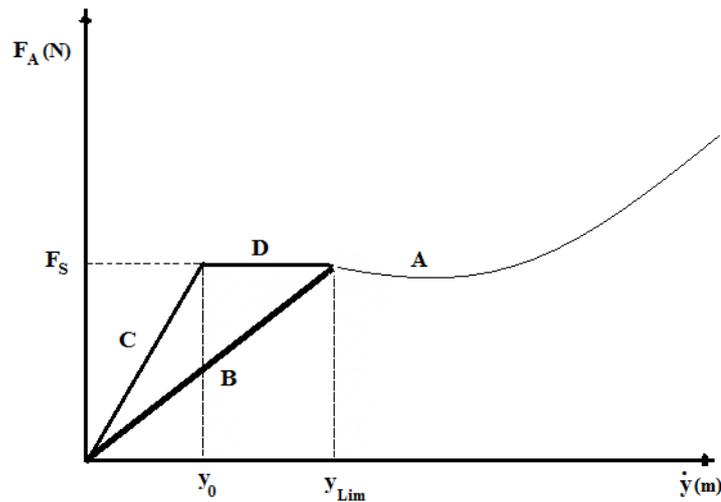


Figura 2.5 - Modelo do coeficiente de atrito viscoso variável.

De acordo com a Figura 2.5, o atrito é descrito por meio das diferentes trajetórias A, B, C e D, que são comutadas entre si de acordo com a velocidade e a força aplicada ao corpo.

A Equação (2.42) descreve o modelo:

$$F_A = f_v(\dot{y}, F)\dot{y}, \quad (2.42)$$

onde \dot{y} é a velocidade do corpo (m/s) e F é a força aplicada no corpo (N);

O parâmetro f_v é variável e dependente da velocidade \dot{y} e da força F . O mapeamento entre entrada e saída é não linear. As trajetórias A, B, C ou D ilustradas por meio da Figura 2.5 podem ser descritas por meio das equações (2.43) a (2.46).

$$\dot{y} \geq \dot{y}_{\text{lim}} \rightarrow F_A = f_{vA}(\dot{y}). \quad \text{Trajetória A.} \quad (2.43)$$

$$\dot{y} < \dot{y}_{\text{lim}} \text{ e } F \geq F_S \rightarrow F_A = f_{vB}\dot{y}. \quad \text{Trajetória B (região desliza),} \quad (2.44)$$

$$\text{sendo } f_{vB} = \frac{F_S}{\dot{y}_{\text{lim}}}.$$

$$\dot{y}_0 \leq \dot{y} < \dot{y}_{\text{lim}} \text{ e } F < F_S \rightarrow F_A = F_S. \quad \text{Trajetória D (região adere).} \quad (2.45)$$

$$\dot{y} < \dot{y}_0 \text{ e } F < F_s \rightarrow F_A = f_{vc}\dot{y}. \quad \text{Trajetória C (região adere),} \quad (2.46)$$

sendo $f_{vc} = \frac{F_s}{\dot{y}_0}$.

Os efeitos dos atritos de Coulomb, estático, viscoso e o efeito de Stribeck, descritos no apêndice B, são reproduzidos pela trajetória A, que é baseada em um mapa estático de atrito obtido através de dados experimentais. As trajetórias B, C e D podem ser ajustadas por simulação como apresentado por Machado, 2003, e reproduzem o efeito adere-desliza (*stick-slip*) observado no atrito e descrito também no Apêndice B.

2.1.9. Modelo completo não linear do servoposicionador hidráulico.

De acordo com as considerações e o equacionamento obtido ao longo da Seção 2.1, a Tabela 2.1 apresenta um resumo das equações do modelo de 4° ordem do servoposicionador hidráulico ilustrado na Figura 2.1.

Tabela 2.1 – Resumo das equações do modelo não linear do servoposicionador hidráulico.

Equação	Número
$P_1A_1 - P_2A_2 = M\ddot{y} + F_A + F_L$	(2.41)
$\dot{P}_1A_1 - \dot{P}_2A_2 = (A_1f_1K_{VA}g_1 + A_2f_2K_{VB}g_2)u - (A_1^2f_1 + A_2^2f_2)\dot{y}$	(2.38)
$g_1 = \begin{cases} u \geq 0 \rightarrow \sqrt{(P_s - P_1 - \Delta P_1)} \\ u < 0 \rightarrow \sqrt{P_1 - \Delta P_3} \end{cases}$	(2.24)
$g_2 = \begin{cases} u \geq 0 \rightarrow \sqrt{P_2 - \Delta P_4} \\ u < 0 \rightarrow \sqrt{(P_s - P_2 - \Delta P_2)} \end{cases}$	(2.25)
$f_1 = \frac{\beta}{V_{10} + A_1y}$	(2.39)
$f_2 = \frac{\beta}{V_{20} - A_2y}$	(2.40)

Conforme visualizado por meio da Tabela 2.1, as não linearidades envolvidas no modelo estão presentes na expressão F_A em (2.41), nas expressões g_1 , g_2 em (2.38) e na multiplicação dos termos f_1 e f_2 por g_1 , g_2 e \dot{y} em (2.38).

2.2. Modelo Analítico Linear do servoposicionador Hidráulico.

Uma abordagem que pode ser adotada para o projeto de controladores para atuadores hidráulicos é a obtenção de um modelo linearizado das equações descritas na Tabela 2.1. O procedimento de linearização adotado pode ser encontrado em Merrit, 1967, e consiste na expansão utilizando séries de Taylor da Equação (2.38) em um determinado ponto i de linearização, considerando somente o primeiro termo da expressão resultante [Ogata, 1990]. O modelo linearizado é utilizado para o cálculo dos controladores lineares que são apresentados no Capítulo 3. A estratégia de projeto envolvendo a linearização do modelo do atuador hidráulico possui limitações (consultar, por exemplo Paim, 1997, Cunha, 1997), cabendo destacar:

- A frequência natural do cilindro altera-se com o deslocamento do pistão, sendo o modelo válido, portanto, para pequenos deslocamentos do pistão em torno da posição adotada para o mesmo na linearização;
- O modelo é válido apenas para pequenos deslocamentos do carretel da válvula em relação à posição adotada para o mesmo na linearização;
- O projeto de controladores lineares baseado em um modelo linearizado é pouco robusto em relação a variações paramétricas no atuador hidráulico .

Em Cunha, 1997, é demonstrado que, em aplicações do controle de trajetória de posição, o projeto de controladores utilizando o modelo linearizado apresenta resultados inferiores a controladores projetados utilizando o modelo não linear.

Nas seções seguintes será descrito o equacionamento pertinente a linearização do modelo descrito por meio das equações da Tabela 2.1.

2.2.1. Coeficientes de vazão e de vazão-pressão

Merrit, 1967, introduz o conceito de dois coeficientes que devem ser utilizados para a substituição das equações não lineares que descrevem a vazão nos orifícios da válvula direcional.

Considerando o caso abordado em Merrit, 1967, onde o cilindro e a válvula são simétricos e o fluido hidráulico é incompressível, a equação que relaciona a vazão volumétrica em um orifício em função do deslocamento do carretel e da diferença de pressão a montante e a jusante do orifício considerando a válvula como de centro crítico ideal é:

$$Q_L = C_d w_p x_v \sqrt{\frac{1}{\rho} \left(P_s - \frac{x_v}{|x_v|} \Delta P \right)}, \quad (2.47)$$

onde Q_L é a vazão volumétrica na válvula (m^3/s), que nesse caso é igual a Q_1 e a Q_2 e $\Delta P = P_1 - P_2$ a pressão diferencial (Pa).

A Equação (2.47) em Merrit, 1967, é linearizada em torno de um ponto de operação desejado utilizando expansão por Séries de Taylor. O resultado do primeiro termo desta expansão em relação à $x_v|_i$ (ponto de linearização) chama-se coeficiente de vazão e é descrito na Equação (2.48). A Equação (2.49) representa a mesma operação em relação à $\Delta P|_i$ e chama-se coeficiente de vazão-pressão. A linearização de (2.47) resulta no seguinte equacionamento:

$$K_q = \frac{\partial Q_L}{\partial x} x_v|_i = C_d w_p \sqrt{\frac{1}{\rho} (P_s - \Delta P|_i)}, \quad (2.48)$$

$$K_c = \frac{\partial Q_L}{\partial x} \Delta P|_i = \frac{C_d w_p x_v|_i}{2(P_s - \Delta P|_i)} \sqrt{\frac{1}{\rho} (P_s - \Delta P|_i)}, \quad (2.49)$$

$$Q_L = K_q \delta x_v - K_c \delta \Delta P, \quad (2.50)$$

onde: $\delta x_v = x_v - x_{v0}$; $\delta \Delta P = \Delta P - \Delta P_0$, K_q é o coeficiente de vazão ($\text{m}^3/\text{s}/\text{m}$), K_c é o coeficiente de vazão-pressão ($\text{m}^3/\text{s}/\text{Pa}$), $x_v|_i$ ou x_{v0} é a posição do carretel no ponto de linearização (m) e $\Delta P|_i$ ou ΔP_0 é a pressão diferencial no ponto de linearização (Pa).

O coeficiente de vazão pode ser determinado analiticamente pela Equação (2.48) com uma boa aproximação [Merrit, 1967]. O coeficiente de vazão-pressão é uma consequência do vazamento interno da válvula e sua determinação analítica por meio da Equação (2.49) é geralmente imprecisa [Merrit, 1967]. Merrit, 1967, propõe um coeficiente experimental K_{pa} chamado de ganho de pressão. Por meio do ganho de pressão é possível calcular o coeficiente de vazão-pressão pela relação:

$$K_c = \frac{K_q}{K_{pa}}, \quad (2.51)$$

onde K_{pa} é o ganho de pressão (Pa/m).

2.2.2. Linearização do equacionamento da vazão nos orifícios da válvula direcional

No caso do servoposicionador hidráulico representado na Figura 2.1, as equações (2.15) e (2.16) são linearizadas substituindo os termos h_1 e h_2 pelos termos g_1 e g_2 (equações (2.24) e (2.25)). Aplicando-se expansão por séries de Taylor nessas equações os coeficientes de vazão são expressos por intermédio das equações (2.52) e (2.53).

$$K_{q1} = \begin{cases} u \geq 0 \rightarrow \frac{\partial Q_1(u, P_1)}{\partial u} = K_{VA} \sqrt{(P_s - P_1|_i - \Delta P_1|_i)} \\ u < 0 \rightarrow \frac{\partial Q_1(u, P_1)}{\partial u} = K_{VB} \sqrt{P_1|_i - \Delta P_3|_i} \end{cases}, \quad (2.52)$$

$$K_{q2} = \begin{cases} u \geq 0 \rightarrow \frac{\partial Q_2(u, P_2)}{\partial u} = K_{VA} \sqrt{P_2|_i - \Delta P_4|_i} \\ u < 0 \rightarrow \frac{\partial Q_2(u, P_2)}{\partial u} = K_{VB} \sqrt{(P_s - P_2|_i - \Delta P_2|_i)} \end{cases}, \quad (2.53)$$

Os coeficientes de vazão-pressão são calculados indiretamente a partir do ganho de pressão, cujo valor é determinado por meio de experimentos ou utilizando informações do

fabricante. Uma vez conhecidos os ganhos de pressão, os coeficientes de vazão-pressão são calculados através das equações (2.54) e (2.55).

$$K_{c1} = \frac{K_{q1}}{K_{pa1}}, \quad (2.54)$$

$$K_{c2} = \frac{K_{q2}}{K_{pa2}}, \quad (2.55)$$

onde K_{q1} , K_{q2} são os coeficientes normalizados de vazão por via ($\text{m}^3/\text{s}/\text{V}$), K_{c1} , K_{c2} são os coeficientes de vazão-pressão por via ($\text{m}^3/\text{s}/\text{Pa}$), K_{pa1} , K_{pa2} são os ganhos de pressão normalizados por via (Pa/V), $P_1|_i$, $P_2|_i$ são as pressões nas câmaras no ponto de linearização (Pa), $\Delta P_1|_i$, $\Delta P_2|_i$, $\Delta P_3|_i$, $\Delta P_4|_i$ são as perdas de carga no ponto de linearização (Pa).

As vazões linearizadas são determinadas por:

$$Q_1 = K_{q1}\delta u - K_{c1}\delta P_1, \quad (2.56)$$

$$Q_2 = K_{q2}\delta u + K_{c2}\delta P_2, \quad (2.57)$$

onde $\delta u = u - u_0 / u_{\max}$, $\delta P_1 = P_1 - P_{10}$ e $\delta P_2 = P_2 - P_{20}$, u_0 é o sinal de entrada no ponto de linearização (V) e P_{10} , P_{20} são as pressões nas câmaras menos perdas de carga no ponto de linearização (Pa);

De acordo com Furst, 2001, o ponto de linearização escolhido depende da tarefa a ser executada pelo servoposicionador hidráulico. As recomendações de projeto apresentadas por Furst, 2001, indicam a escolha do ponto de pressão diferencial onde ocorre a maior abertura da válvula, ou seja, no ponto de maior vazão. No caso dos cilindros assimétricos acionados por válvulas simétricas, regidos pelas equações (2.56) e (2.57), e, portanto, Q_1 não é igual a Q_2 , têm-se quatro valores de vazão máxima diferentes, dois para cada sentido do movimento. Esses valores podem ser identificados por simulação utilizando-se o modelo não linear descrito na Tabela 2.1.

2.2.3. Linearização das pressões no cilindro assimétrico.

Aplicando-se (2.56) e (2.57) em (2.27) e (2.28) e considerando pequenos deslocamentos do pistão, de modo que y mantenha-se próximo de zero, resulta nas seguintes equações linearizadas:

$$\dot{P}_1 = \left(K_{q1} \delta u - K_{c1} \delta p_1 - A_1 \dot{y} \right) \frac{\beta}{V_{10}}, \quad (2.58)$$

$$\dot{P}_2 = \left(-K_{q2} \delta u - K_{c2} \delta p_2 + A_2 \dot{y} \right) \frac{\beta}{V_{20}}. \quad (2.59)$$

2.2.4. Linearização do subsistema mecânico.

Linearizar o subsistema mecânico significa, neste caso, adotar uma representação linear para o atrito. Uma solução que pode ser encontrada em Guenther e De Pieri, 1997, e Cunha, 1997, é considerar somente a parcela do atrito referente ao atrito viscoso, que pode ser representado por uma reta passando pela origem que corresponde a uma aproximação do coeficiente de atrito viscoso B multiplicada pela velocidade.

Considerando que as perdas de carga no subsistema hidráulico são significativas, o efeito das mesmas na dinâmica do sistema reflete-se como um amortecimento adicional, que se soma, no subsistema mecânico, ao amortecimento referente ao atrito viscoso. Considerando o fluido hidráulico como incompressível, pode-se reescrever as equações linearizadas do sistema como:

$$P_{va} A_1 - P_{vb} A_2 = M \ddot{y} + B \dot{y} + H \dot{y}, \quad (2.60)$$

$$\dot{P}_{va} A_1 - \dot{P}_{vb} A_2 = \frac{\beta}{V_0} \left[(K_{q1} A_1 + K_{q2} A_2) \delta u - (K_{c1} A_1 P_{va} - K_{c2} A_2 P_{vb}) - (A_1^2 + A_2^2) \dot{y} \right], \quad (2.61)$$

$$H_m = \begin{cases} u \geq 0 \rightarrow \frac{1}{Cl_1} A_1^2 + \frac{1}{Cl_4} A_2^2 \\ u < 0 \rightarrow \frac{1}{Cl_3} A_1^2 + \frac{1}{Cl_2} A_2^2 \end{cases}, \quad (2.62)$$

onde, considerando as conexões da válvula com as mangueiras, P_{va} é a pressão imediatamente a jusante da saída 1 da válvula (via 1) (Pa), P_{vb} é a pressão imediatamente a montante da saída 2 da válvula (via 2) (Pa) e H_m é o coeficiente de amortecimento no subsistema mecânico resultante das perdas de carga (Ns/m). O coeficiente total de amortecimento equivalente é descrito por meio da equação:

$$B_{eq} = B + H_m. \quad (2.63)$$

A força equivalente é descrita por meio da equação:

$$F_{eq} = P_{va}A_1 - P_{vb}A_2. \quad (2.64)$$

Assim, o sistema linearizado pode ser descrito por meio das equações:

$$F_{eq} = M\ddot{y} + B_{eq}\dot{y}, \quad (2.65)$$

$$\dot{F}_{eq} = \frac{\beta}{V_0} \left[(K_{q1}A_1 + K_{q2}A_2) \delta u - (K_{c1}A_1 \delta P_{va} - K_{c2}A_2 \delta P_{vb}) - (A_1^2 + A_2^2) \dot{y} \right], \quad (2.66)$$

onde B_{eq} é o coeficiente de amortecimento equivalente (Ns/m).

2.2.5. Modelo completo linear do servoposicionador hidráulico.

Considerando a posição do pistão na Figura 2.1. Se a posição de linearização for escolhida em um ponto tal que $V_{10} = V_{20} = V_0$, uma simplificação pode ser feita, tal como proposto em Pereira, 2006, ao se considerar uma constante K_{cp} , definida como:

$$K_{cp} = (K_{c1} + K_{c2}) / 2, \quad (2.67)$$

onde K_{cp} é o coeficiente de vazão-pressão simplificado ($m^3/s/Pa$).

Substituindo K_{c1} e K_{c2} em (2.66) por K_{cp} e aplicando a transformada de Laplace nas equações (2.65) e (2.66) para condições iniciais nulas, obtém-se:

$$y(s)(Ms^2 + B_{eq}s)\left(s + \frac{\beta}{V_0}K_{cp}\right) = \frac{\beta}{V_0}\left[(K_{q1}A_1 + K_{q2}A_2)u(s) - s(A_1^2 + A_2^2)y(s)\right]. \quad (2.68)$$

A função de transferência entre o sinal de entrada $u(s)$ e a posição de saída $y(s)$, denominada $G(s)$, pode ser expressa por meio da equação [Pereira, 2006]:

$$G(s) = \frac{\frac{\beta}{MV_0}(K_{q1}A_1 + K_{q2}A_2)}{s^3 + \left(\frac{B_{eq}}{M} + \frac{\beta}{V_0}K_{cp}\right)s^2 + \left(\frac{\beta}{MV_0}(B_{eq}K_{cp} + A_1^2 + A_2^2)\right)s}. \quad (2.69)$$

A função de transferência $G(s)$ possui um polo na origem, um ganho que depende do ponto de linearização e dois polos, que, normalmente, são polos complexos conjugados pouco amortecidos.

Um caso particular do presente trabalho é que o pistão diferencial trabalha em conjunto com uma válvula simétrica. Esse efeito resulta em duas funções de transferência $G(s)$ distintas, uma para cada sentido do movimento do pistão, pois ocorrem mudanças importantes nos parâmetros K_{q1} , K_{q2} e K_{cp} da situação de movimento positivo para a situação de movimento negativo do pistão.

2.3. Modelo Analítico da bancada experimental.

Os parâmetros que constam nas equações do modelo analítico não linear são determinados por meio de experimentos e da consulta ao catálogo dos fabricantes dos equipamentos [Pereira, 2006]. Nesta seção são descritos os procedimentos experimentais adotados para a determinação dos parâmetros do modelo descrito por meio da Tabela 2.1 aplicado à bancada experimental utilizada no presente trabalho.

2.3.1. Descrição da bancada experimental do servoposicionador hidráulico.

O servoposicionador hidráulico utilizado na bancada experimental é composto de um cilindro diferencial, de uma servoválvula, de sensores de pressão e posição, de mangueiras flexíveis e de uma unidade de potência hidráulica.

A válvula utilizada é uma servoválvula simétrica de controle direcional de 4 vias tipo servo solenoide, diretamente operada, com realimentação elétrica de posição e eletrônica embarcada, produzida pelo fabricante Bosch Rexroth (ref. 4WRPEH 6). Essa válvula, segundo consta em catálogo, possui uma vazão nos orifícios aproximadamente linear em relação à variação do sinal de entrada aplicado quando operando em pressão diferencial constante (diferença de pressão nos orifícios). O sinal de entrada pode variar entre -10 V e +10 V. Essa válvula é descrita pelo fabricante como de centro crítico. Em Linsingen, 2001, afirma-se que construtivamente esse tipo de válvula sempre apresenta algum tipo de *overlap* entre o carretel e o pórtico para diminuir os vazamentos devido à intrínseca folga radial existente entre os mesmos. Em termos práticos, portanto, é uma válvula de centro supercrítico com uma sobreposição muito pequena.

A servoválvula comanda o deslocamento do pistão de um cilindro diferencial de 200 mm de curso do tipo CDT3MS22518200, com 25 mm de diâmetro de seção transversal para o pistão e 18 mm para a haste, fabricado também pela Bosch Rexroth. Acoplado ao pistão do cilindro hidráulico encontra-se uma massa de 14,34 kg, que desliza ao longo do curso do mesmo por meio de um carro com rolamentos esféricos, conectado a um trilho de madeira, diminuindo assim o atrito decorrente do deslocamento da massa, resultando em uma configuração na qual o atrito mais significativo consiste daquele entre o êmbolo e as paredes do cilindro.

A conexão entre as portas da válvula e o cilindro é realizada através de mangueiras flexíveis de 1,5 m de comprimento e um quarto de polegada de diâmetro, onde conexões de engate rápido são utilizadas. As conexões entre as portas de pressão e de tanque também são realizadas utilizando as mesmas mangueiras.

A temperatura do fluido hidráulico é medida por meio de um transmissor de temperatura Novus 8803829780, conectado diretamente ao tanque da UPCH.

A estratégia de controle em cascata, como será descrita na Seção 4.1, exige medições de posição e de força hidráulica. Para a medição de posição é utilizado um transdutor de posição linear resistivo de 300 mm de curso fabricado pela Novotechnic, modelo TLH 300, o qual foi adaptado para uso em 200 mm. Para as medições de pressões são utilizados dois transmissores de pressão. O transmissor do tipo HM 18, do fabricante Bosch Rexroth, de 210 bar de fundo de escala e saída 0 a 10 V é utilizado para medir a pressão na câmara 1 do cilindro, sendo conectado ao mesmo por uma conexão do tipo T de engates rápidos. O transmissor do tipo TP-691, do fabricante Huba, de 400 bar de fundo de escala e saída 4 a 20 mA é utilizado para medir a pressão na câmara 2 do cilindro, sendo também conectado ao mesmo por uma conexão do tipo T de engates rápidos. Para a diminuição do ruído nas medidas de cada um dos sensores supracitados e, pelo mesmo motivo, para as respectivas derivadas numéricas calculadas com base nas medidas obtidas por meio dos mesmos, utilizam-se filtros digitais, descritos com maior detalhe no Apêndice C. No presente trabalho, com base nas baixas frequências das trajetórias a serem controladas, de no máximo 0,15 Hz, assume-se, como em outros trabalhos como Cunha, 2001, e Pereira, 2006, que os atrasos de fase desses filtros não têm efeito nos resultados experimentais obtidos.

Para a adaptação às entradas da placa de aquisição, que são de -10 V a +10 V, são utilizados circuitos condicionadores de sinal. A placa de aquisição A/D e D/A utilizada é do tipo DS1104, do fabricante dSpace. Esse fabricante fornece, juntamente com a placa, um pacote de *software* que proporciona uma fácil interação do *hardware* com o *software* Simulink, do Matlab. Desta forma, é possível exportar e importar dados entre a placa e o Simulink utilizando somente blocos de conexão virtuais no mesmo com as entradas e saídas da placa. As figuras 2.5 e 2.6 ilustram a bancada hidráulica utilizada.

No presente trabalho, assim como em grande parte dos trabalhos na área de sistemas de controle pesquisados (pode-se enumerar quase a totalidade das referências bibliográficas), com exceção dos trabalhos de Rost, et. al., 2016 e Santolaria e Gines, 2013, não são consideradas nas medições experimentais a incerteza presente devido aos vários sensores utilizados. Segundo JCGM, 2008a, incerteza é o parâmetro não negativo que caracteriza a dispersão dos valores atribuídos a um mesurando, com base nas informações utilizadas, em uma faixa de dispersão estatística com um determinado nível de confiança. Considerando, porém, que o objetivo dos trabalhos desenvolvidos em controle, bem como do presente trabalho, é testar a efetividade dos controladores apresentados (robustez, estabilidade, etc) e

que as comparações entre os mesmos são realizadas dentro da mesma planta experimental, considerando as mesmas condições de repetibilidade [JCGM 2008a], assume-se, como na maioria dos trabalhos de controle, que a omissão da incerteza não prejudica esses objetivos.

Com o intuito de quantificar a incerteza envolvida na medida instantânea do erro de posição e mostrar que a distribuição de probabilidade da mesma ao longo da trajetória controlada possui média muito próxima a zero, realiza-se, no presente trabalho, um estudo de incertezas para o controlador em cascata neural considerando o método Monte Carlo [JCGM, 2008b]. Esse estudo, bem como as características técnicas, incertezas de medição e representação fotográfica dos elementos envolvidos na bancada experimental (sensores, válvula proporcional, cilindro, sistema de aquisição de dados) estão disponibilizados no Apêndice C.

A Figura 2.6 apresenta uma ilustração fotográfica da bancada experimental onde estão destacados os vários elementos que foram descritos na presente seção.

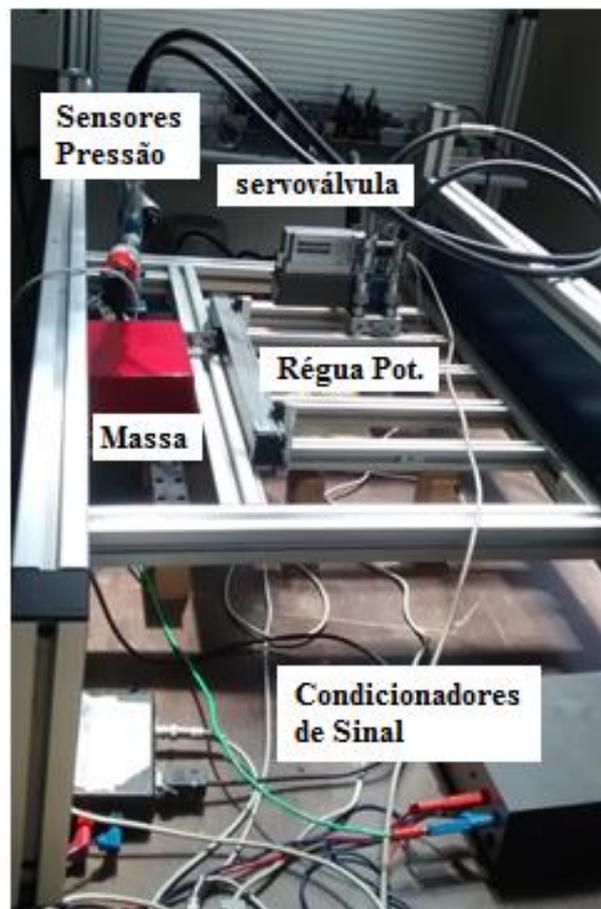


Figura 2.6 - Bancada Hidráulica Experimental

A Figura 2.7 apresenta um diagrama descritivo onde é possível visualizar mais facilmente cada um dos elementos destacados e sua função na bancada experimental.

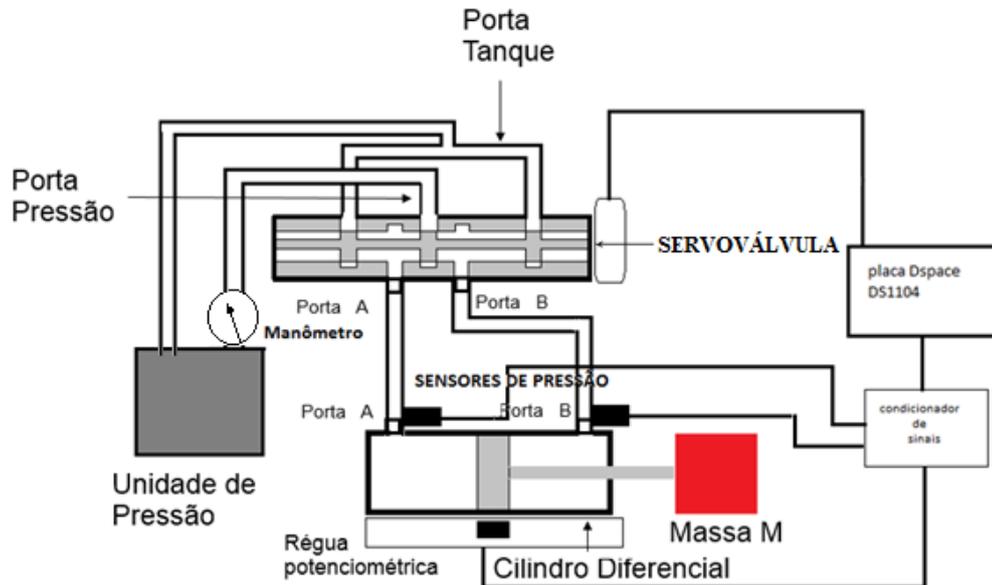


Figura 2.7 – Diagrama descritivo dos componentes da bancada hidráulica experimental

2.3.2. Obtenção do coeficiente da válvula.

O coeficiente da válvula K_v utilizado no presente trabalho foi obtido por meio da utilização dos dados de catálogo do fabricante de válvula em conjunto com a aplicação da Equação (2.13), reescrita a seguir:

$$K_v = \frac{Q_{vn}}{\sqrt{\Delta P_{vn}}} \quad (2.70)$$

Os parâmetros Q_{vn} e ΔP_{vn} são, respectivamente, a vazão nominal da válvula e a pressão diferencial total nos orifícios da válvula. Para a válvula utilizada tem-se, do catálogo do fabricante, $\Delta P_{vn} = 7$ MPa e $Q_{vn} = 24$ L/min, para $u_{max} = 10$ V. Assim, resulta $K_v = 151,1 \cdot 10^{-9} \text{ m}^3/(\text{s}\sqrt{\text{Pa}})$.

O parâmetro $K_{v,via}$, utilizado no modelo analítico, é obtido diretamente por intermédio da aplicação da Equação (2.14).

2.3.3. Determinação dos parâmetros do modelo de atrito.

Para o levantamento dos parâmetros do modelo de atrito descrito na Seção 2.1, é necessário realizar o levantamento do mapa estático de atrito do sistema. O mapa estático é obtido fazendo com que o cilindro mova uma massa a uma velocidade aproximadamente constante. Nessa situação, a componente dinâmica vinculada à aceleração na Equação (2.41) anula-se, podendo-se calcular a força de atrito diretamente pela relação entre as áreas do cilindro e as pressões nas câmaras:

$$F_A = A_1 P_1 - A_2 P_2. \quad (2.71)$$

Conforme citado na Seção 2.3.1, utiliza-se uma conexão T de engates rápidos em ambos os transmissores de pressão, de modo a realizar a conexão dos mesmos com as portas 1 e 2 do cilindro hidráulico. Essas conexões possuem perdas de carga significativas. As equações (2.72) e (2.73) descrevem o valor das pressões P_1 e P_2 em função das pressões medidas P_A e P_B considerando uma vazão positiva (sentido do avanço do cilindro) e considerando a mesma função de perda para ambos os conectores:

$$P_1 = P_A - j(Q_1), \quad (2.72)$$

$$P_2 = P_B + j(Q_2), \quad (2.73)$$

onde $j(Q)$ é uma função que fornece a perda de pressão na conexão em função da vazão (Pa), P_1 e P_2 são as pressões nas portas 1 e 2 do cilindro hidráulico (Pa) e P_A e P_B são as pressões medidas por meio das conexões em T (Pa).

Substituindo (2.72) e (2.73) em (2.71) tem-se:

$$F_A + [j(Q_1)A_1 + j(Q_2)A_2] = A_1 P_A - A_2 P_B. \quad (2.74)$$

De acordo com a Equação (2.74), a medição da força de atrito por meio das pressões P_A e P_B considera um termo relativo à perda de pressão nas conexões em T.

No presente trabalho, optou-se por incorporar ao mapa estático do atrito a representação do termo relativo à perda de pressão nas conexões, estimando esse mapa estático por meio das medidas de P_A e P_B . Essa escolha deve-se ao fato de que a estimação das perdas nas conexões separadas do mapa estático de atrito exigiria o ajuste de uma equação não linear para as perdas nas conexões em T. Essa equação seria necessária também para o cálculo das pressões P_1 e P_2 por meio das equações (2.72) e (2.73), sendo um elemento não linear adicional a ser acrescentado ao modelo final. OBS: a configuração padrão da bancada experimental mantém as conexões em T, mesmo quando utilizados controladores clássicos.

Uma força hidráulica modificada passa então a considerar também a medida das perdas nas conexões dos sensores de pressão, sendo descrita por meio da equação:

$$F_H' = A_1 P_A - A_2 P_B \quad (2.75)$$

onde F_H' é a força hidráulica modificada, que corresponde à força hidráulica no pistão somada às perdas de pressão nas conexões em T traduzidas em perdas de força (N).

As perdas de pressão traduzidas em perdas de força e somadas às forças de atrito são descritas por meio da equação:

$$F_A' = F_A + F_p \quad (2.76)$$

onde F_A' é a força de atrito modificada, que incorpora as perdas de força nas conexões dos sensores de pressão (N) e F_p são as perdas de força oriundas das perdas de pressão nas conexões em T (N).

Para a geração dos valores de força versus velocidade, utiliza-se um controlador proporcional de posição. Um valor constante de velocidade desejado é integrado para gerar uma trajetória de posição desejada, no caso uma rampa, que será aplicada na entrada da malha fechada de controle. Nessa condição, o atrito modificado é igual à força hidráulica modificada.

Os valores de pressão e velocidade armazenados são correspondentes aos trechos da trajetória em regime permanente, desprezando-se o transitório. Por essa razão, o experimento é repetido a cada novo valor de velocidade, permitindo um deslocamento suficiente da massa para que a curva de resposta assumira um comportamento de regime permanente. Em Machado, 2003, o levantamento do mapa estático é feito com o servoposicionador em malha aberta, aplicando sinais de tensão constante na entrada da válvula. A diferença significativa aqui observada entre os dois procedimentos é a ocorrência de um tempo de convergência maior ao regime permanente quando são aplicadas tensões em malha aberta.

A Figura 2.8 ilustra o mapa estático obtido por meio da Equação (2.75) aplicada a diferentes valores constantes de velocidade no pistão hidráulico. É importante ressaltar que a bancada experimental não conta com controle de temperatura e que os testes foram realizados para temperaturas do fluido hidráulico entre 30 °C e 40 °C.

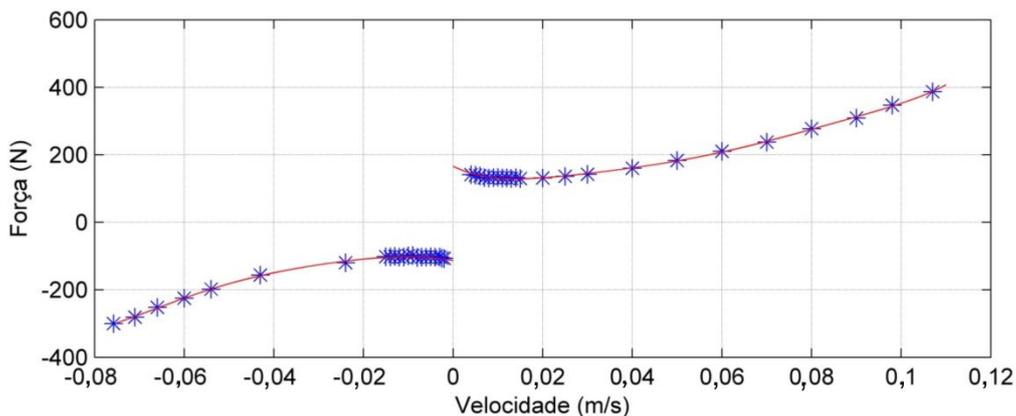


Figura 2.8 - Mapa estático de F_A' .

O modelo de atrito descrito na Seção 2.1.8 por meio das equações (2.43) a (2.46) é utilizado considerando o mapa estático ilustrado na Figura 2.8.

Para determinação da expressão utilizada na trajetória A em (2.43) utiliza-se uma função polinomial de aproximação obtida com auxílio da função POLYFIT do Matlab. Foi verificado que uma função polinomial de sexta ordem para velocidades positivas e de quinta ordem para velocidades negativas reproduzem adequadamente o traçado do mapa estático, conforme pode ser visualizado na Figura 2.8. As seguintes equações descrevem os polinômios ajustados:

$$F_A' = c_6\dot{y}^6 + c_5\dot{y}^5 + c_4\dot{y}^4 + c_3\dot{y}^3 + c_2\dot{y}^2 + c_1\dot{y} + c_0 \quad ; \quad \dot{y} > 0, \quad (2.77)$$

$$F_A' = d_5\dot{y}^5 + d_4\dot{y}^4 + d_3\dot{y}^3 + d_2\dot{y}^2 + d_1\dot{y} + d_0 \quad ; \quad \dot{y} < 0, \quad (2.78)$$

sendo:

$$\mathbf{c}^T = [3616055991,90211 \quad -1259149259,42947 \quad 171035516,506081$$

$$-1509039,8703813 \quad 424512,463097214 \quad -6778,25791735762 \quad 166,069950482143]^T,$$

$$\mathbf{d}^T = [-338186182,095526 \quad -65714639,6349697 \quad -4701264,37738616 \quad -194099,979524457$$

$$-2677,58352606057 \quad -113,147119937170]^T.$$

As trajetórias para a região onde foi verificada a presença do fenômeno de *adere-desliza (stick-slip)* ocorrem em velocidades próximas a zero. Estas trajetórias são definidas baseando-se nos valores obtidos em Szpack 2008. Tal autor utiliza um cilindro hidráulico semelhante ao utilizado no presente trabalho, sendo os parâmetros \dot{y}_{lim} e \dot{y}_0 , em ambos os sentidos, obtidos com base nos valores praticados pelo mesmo. A força F_S é obtida com base no ensaio experimental ilustrado na Figura 2.8, por meio do valor de F_A' obtido substituindo-se \dot{y}_{lim} em ambos os sentidos nas equações (2.77) e (2.78). A Tabela 2.2 apresenta os valores dos parâmetros do modelo de atrito viscoso variável aplicado ao mapa estático da Figura 2.8.

Tabela 2.2 - Parâmetros do modelo de atrito viscoso variável aplicados à Equação (2.76).

Parâmetro	Valor	Condição de operação
F_S	145 N	$\dot{y} > 0$
\dot{y}_{lim}	0,004 m/s	
\dot{y}_0	0,004*0,95 m/s	
F_S	-108 N	$\dot{y} < 0$
\dot{y}_{lim}	-0,002 m/s	
\dot{y}_0	-0,002*0,95 m/s	

A parcela viscosa do atrito, como em Cunha, 2001, é representada pelo coeficiente B . No mapa estático ilustrado na Figura 2.8, a parcela linear pode ser descrita por:

$$Z = B + C, \quad (2.79)$$

onde C é o coeficiente linear de amortecimento referente às perdas nas conexões de pressão (Ns/m) e Z representa a soma do termo linear referente à parcela viscosa do atrito com o termo linear que representa a perda de carga nas conexões de pressão (Ns/m).

No caso específico do presente trabalho, os valores de B e C são desconhecidos. Para o cálculo de Z , pode-se utilizar o gráfico da Figura 2.8, de forma que o coeficiente descrito por meio da Equação (2.79) é aproximado por uma reta que passa pela origem, conforme ilustra a Figura 2.9. Neste caso, $Z = 3.600$ Ns/m, onde a equação de uma reta passando pela origem foi sobreposta aos dados experimentais. O valor da inclinação da reta foi ajustado para o menor valor de erro quadrado médio calculado entre os dados experimentais e a reta de ajuste.

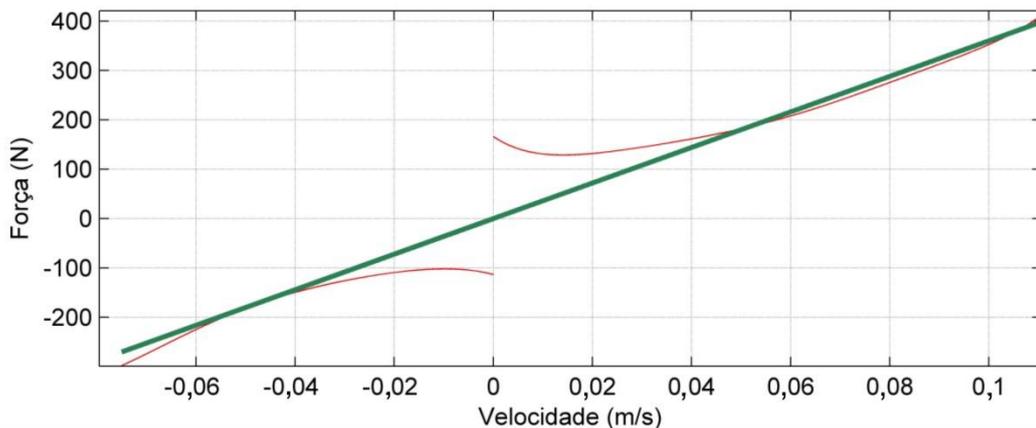


Figura 2.9 - Aproximação do coeficiente Z por uma reta que passa pela origem.

2.3.4. Parâmetros diretamente mensuráveis e módulo de compressibilidade volumétrica efetivo.

As áreas e volumes do cilindro e mangueiras e a massa do conjunto carga e pistão, considerada fixa ao longo de sua operação, são fornecidos pelos fabricantes. Essas informações são apresentadas posteriormente na Tabela 2.3. O módulo de compressibilidade volumétrica efetivo (*Bulk Modulus*) depende principalmente do tipo de fluido, da pressão e temperatura e da quantidade de ar na tubulação. Um estudo detalhado sobre a obtenção desse parâmetro é realizado em Wang et al., 2008. Com base nesse autor, afirma-se que a medida real do módulo de compressibilidade volumétrica efetivo é de difícil obtenção. Assim

como nos trabalhos de Valdiero, 2005, Cunha, 2001, Cunha e Guenther, 2006, Muraro, 2010, adota-se no presente trabalho o valor de $1 \cdot 10^9$ Pa para o mesmo.

2.3.5. Perdas de carga

Os coeficientes de perda de carga, cujos valores são necessários para incorporação no modelo do servoposicionador, são aqueles apresentados nas equações (2.20) a (2.23). No trabalho de Szpack, 2008, os coeficientes de perda de carga são obtidos experimentalmente por meio da medição da pressão a montante e a jusante onde ocorre a perda de carga. Para realizar essas medições, o autor aplicou várias entradas senoidais na válvula, proporcionando diferentes vazões circulantes. O coeficiente final considerado é o coeficiente médio entre todas as vazões medidas contrapostas as respectivas quedas de pressão.

O procedimento em Szpack, 2008, não foi aplicado no presente trabalho devido às dificuldades encontradas na medição das perdas de carga utilizando esse método, principalmente devido ao fato da necessidade de inserir conexões em T para colocação dos sensores de pressão, pois essas conexões apresentam perdas de carga que também necessitam serem estimadas e alteram os valores dos coeficientes de perda medidos para os trechos. Optou-se, portanto, por efetuar o ajuste dos valores das perdas de carga utilizando o resultado iterativo de simulações usando o modelo, uma vez que os demais parâmetros desse modelo, que estão listados mais adiante na Tabela 2.3, são considerados conhecidos nessas simulações.

O processo de obtenção individual dos coeficientes C_{11} a C_{14} pode ser resumido por meio dos seguintes passos:

- Conhecendo a resposta experimental de pressão para entradas do tipo degrau positivas aplicadas por meio do sinal de entrada da válvula de 1 V e 5 V e os demais parâmetros do modelo, ajusta-se C_{11} e C_{14} interativamente de forma que a simulação do modelo aproxime essa resposta;
- Testa-se os valores de C_{11} e C_{14} para os valores de degrau positivo de 1,5 V, 3 V e 10 V e verifica-se se a resposta de simulação é satisfatória, procurando um novo ajuste caso a aproximação possa ser melhorada em relação a esses valores e aos anteriores de degrau em relação à resposta experimental;
- Conhecendo a resposta experimental de pressão para entradas do tipo degrau negativas aplicadas por meio do sinal de entrada da válvula de -1 V e -5 V e

os demais parâmetros do modelo, ajusta-se C_{12} e C_{13} interativamente de forma que a simulação do modelo aproxime essa resposta;

- Testa-se os valores de C_{12} e C_{13} para os valores de degrau negativo de -1,5 V, -3 V e -10 V e verifica-se se a resposta é satisfatória, procurando um novo ajuste caso a aproximação possa ser melhorada em relação a esses valores e aos valores anteriores de degrau em relação a resposta experimental;
- Verifica-se a resposta de força e posição do modelo ajustado aplicando-se as mesmas entradas anteriores e verificando a resposta da simulação em relação à resposta experimental, procedendo-se a novos ajustes caso necessário.

2.3.6. Ganho de pressão, zero hidráulico e histerese.

O resultado do ensaio do ganho de pressão realizado pelo fabricante da válvula segundo a norma ISO 10770-1, 2009, é descrito por meio da Figura 2.10. Esse experimento foi também efetuado para a válvula utilizada no presente trabalho. Os resultados desses ensaios podem ser visualizados nas figuras 2.11 e 2.12 para uma pressão de suprimento de 5 MPa.

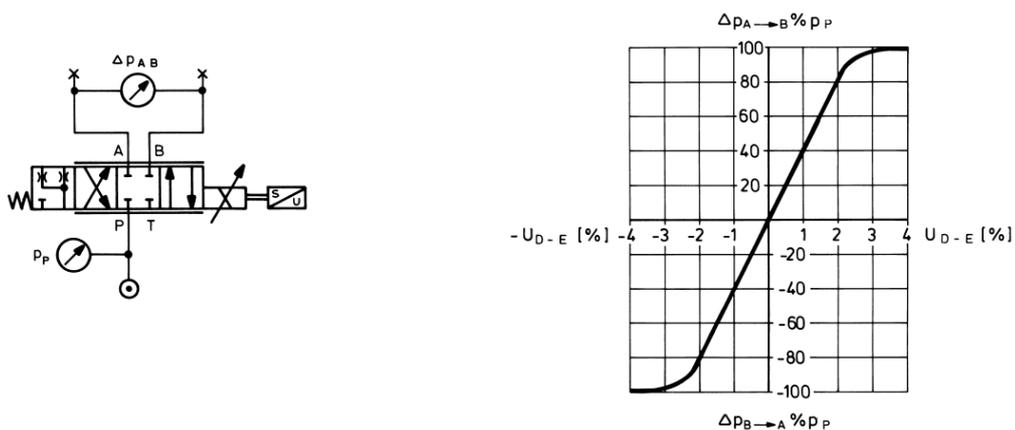


Figura 2.10 - Ganho de pressão extraído do catálogo.

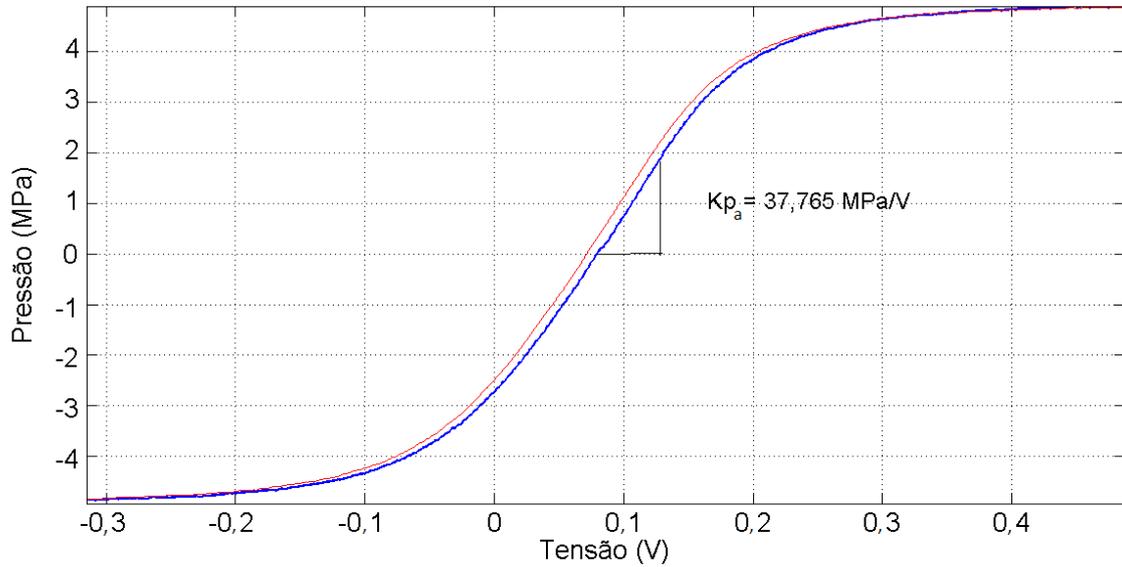


Figura 2.11 - Ensaio experimental dos ganhos de pressão da válvula.

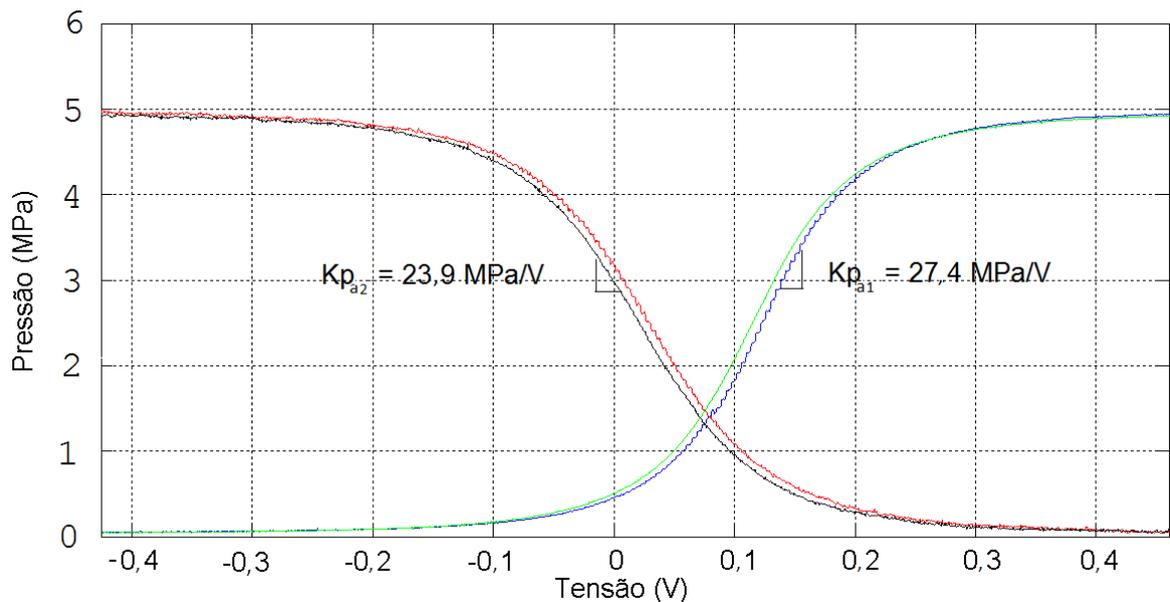


Figura 2.12 - Ensaio experimental dos ganhos de pressão da válvula por via.

A histerese da válvula tem valor máximo de 6,88%, divergindo, assim, do valor do catálogo, que indica um máximo de 0,2%. O desvio do zero (centralização do carretel da válvula) é especificado pelo fabricante como no máximo 1%. Como é verificado por meio do experimento, o zero hidráulico dessa válvula tem um valor de 0,079 V, dentro, portanto, da faixa de valores especificada no catálogo. O ganho de pressão total medido é de 37,765 MPa/V e os ganhos de pressão por via são $K_{pa1}=27,3$ MPa/V e $K_{pa2}=23,89$ MPa/V. A Figura

2.10, reproduzida do catálogo, não mostra ser suficientemente precisa para permitir a realização de um cálculo comparativo, mas, por inspeção, verifica-se que o ganho total de catálogo, medido com $P_S = 7$ MPa, seria aproximadamente 28 MPa/V, diferente daquele medido. Os ganhos por via calculados a partir do catálogo são estimados por alguns autores como Furst, 2001, e Muraro, 2010, como metade do ganho total. OBS: é importante considerar que esse ensaio no presente trabalho não conta com um controle da temperatura do fluido hidráulico, estando esse entre 30 °C e 40 °C durante tal ensaio, o que, além da particularidade dos valores de ganho para cada válvula, pode ter influência no fato do resultado ser diferente do ensaio do fabricante, realizado com uma temperatura de 40 °C para o fluido hidráulico.

2.4. Validação do Modelo Analítico

Para verificação da validade do modelo matemático obtido, foram realizados ensaios em malha aberta, aplicando na entrada da válvula uma tensão constante durante um intervalo de tempo de 0,5 s. Os valores dessas tensões aplicadas foram de 1 V, 1,5 V, 3 V, 5 V, 10 V e -1 V, -1,5 V, -3 V, -5 V, -10 V. A válvula permanece, portanto, aberta durante 0,5 s, a partir de 9 s, e fechada no restante do tempo.

O objetivo, no presente trabalho, é o de obter um modelo que forneça uma resposta, por inspeção dos resultados, semelhante ao comportamento do servoposicionador da bancada experimental. Dentro desse contexto, assim como em Pereira, 2006, Szpack, 2008 e Muraro, 2010, não foram utilizados métodos estatísticos de avaliação com o objetivo de comparar as simulações com os dados experimentais, sendo consideradas suficientes as comparações realizadas mediante inspeção dos gráficos obtidos. Modelos que tenham por objetivo oferecer informações detalhadas (calibração do sistema, comparação com outras plantas, etc) devem utilizar procedimentos semelhantes aos descritos nos trabalhos de Rost, et. al., 2016 e Santolaria e Gines, 2013.

A Tabela 2.3 apresenta os parâmetros do modelo do atuador hidráulico da bancada experimental, obtidos por meio dos procedimentos descritos ao longo da Seção 2.3.

O modelo analítico da bancada experimental pode ser descrito por meio das equações sumarizadas na Tabela 2.4.

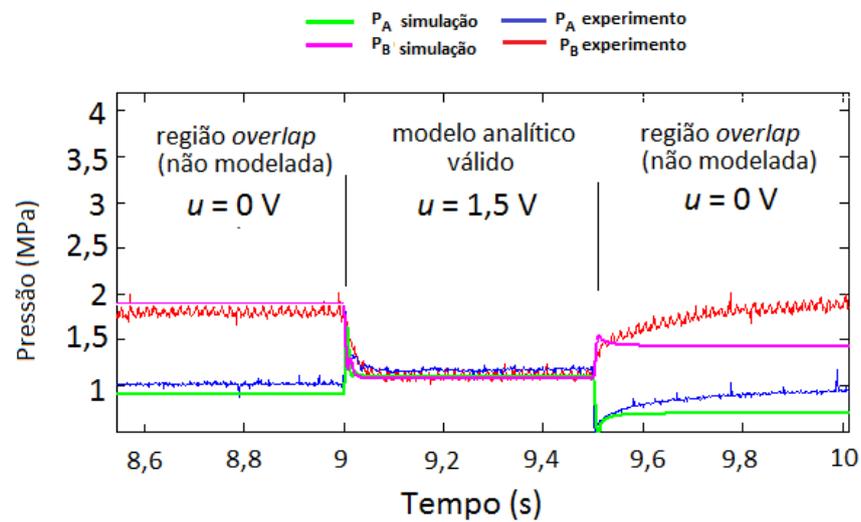
Tabela 2.3 – Parâmetros do modelo da bancada experimental.

Parâmetro	Valor
V_{I0}	$12,446 \cdot 10^{-5} \text{ m}^3$
V_{20}	$9,9060 \cdot 10^{-5} \text{ m}^3$
$y_0 = \mathbf{0}$	0,1 m (pistão centralizado)
$K_{VA}; K_{VB}$	$\sqrt{2} \cdot 15,11 \cdot 10^{-9} \text{ m}^3 / (\text{sV}\sqrt{\text{Pa}})$
C_{I1}	$1,7598 \cdot 10^{-11} \text{ (m}^3/\text{s)/Pa}$
C_{I2}	$2,2985 \cdot 10^{-11} \text{ (m}^3/\text{s)/Pa}$
C_{I3}	$2,7833 \cdot 10^{-11} \text{ (m}^3/\text{s)/Pa}$
C_{I4}	$2,7833 \cdot 10^{-11} \text{ (m}^3/\text{s)/Pa}$
M	14,54 kg
A_1	$4,91 \cdot 10^{-4} \text{ m}^2$
A_2	$2,37 \cdot 10^{-4} \text{ m}^2$
β	$1,0 \cdot 10^9 \text{ N/m}^2$
P_s	5 MPa

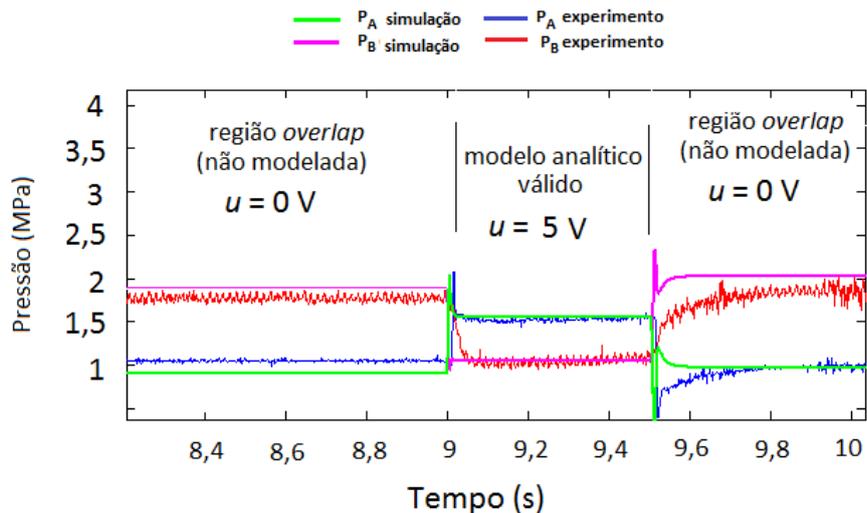
Tabela 2.4 - Equações do modelo analítico da bancada experimental.

Equação	número
$P_A A_1 - P_B A_2 = M\dot{y} + F_A' + F_L$	(2.80)
$F_A' = F_A + F_p$	(2.76)
$\dot{P}_A A_1 - \dot{P}_B A_2 = (A_1 f_1 K_{VA} g_A + A_2 f_2 K_{VB} g_B)u - (A_1^2 f_1 + A_2^2 f_2)\dot{y}$	(2.81)
$Q_1 = K_{VA} g_A u$	(2.82)
$Q_2 = K_{VB} g_B u$	(2.83)
$g_A = \begin{cases} u \geq 0 \rightarrow \sqrt{(P_s - P_A - \Delta P_1)} \\ u < 0 \rightarrow \sqrt{P_A - \Delta P_3} \end{cases}$	(2.84)
$g_B = \begin{cases} u \geq 0 \rightarrow \sqrt{P_B - \Delta P_4} \\ u < 0 \rightarrow \sqrt{(P_s - P_B - \Delta P_2)} \end{cases}$	(2.85)
$f_1 = \frac{\beta}{V_{I0} + A_1 y}$	(2.39)
$f_2 = \frac{\beta}{V_{20} - A_2 y}$	(2.40)

As figuras 2.13 e 2.14 ilustram o comportamento das pressões P_A e P_B medidas no experimento e na simulação. Pode ser verificado por meio da inspeção dessas figuras que o modelo oferece respostas semelhantes àsquelas das pressões medidas na bancada experimental durante o período de 0,5 s de abertura da válvula em malha aberta. Antes e após esse instante, tem-se que $u = 0$ e o carretel da válvula encontra-se na região de *overlap*. Conforme discutido na Seção 2.1.2, optou-se por não representar os vazamentos da válvula nessa região. Conseqüentemente, visualiza-se nas figuras 2.13 e 2.14 que as pressões experimentais são diferentes das pressões do modelo quando o carretel encontra-se na região de *overlap*.

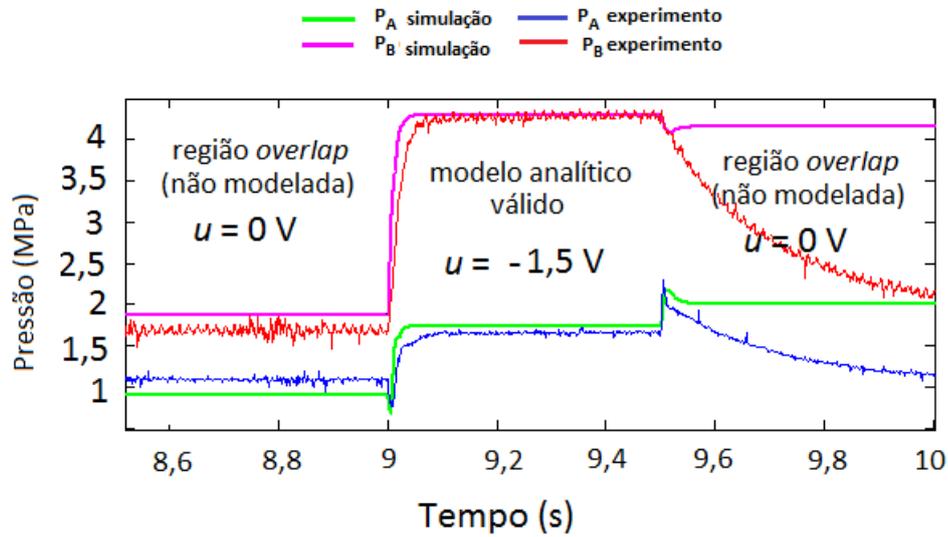


(a) Resposta para 1,5V.

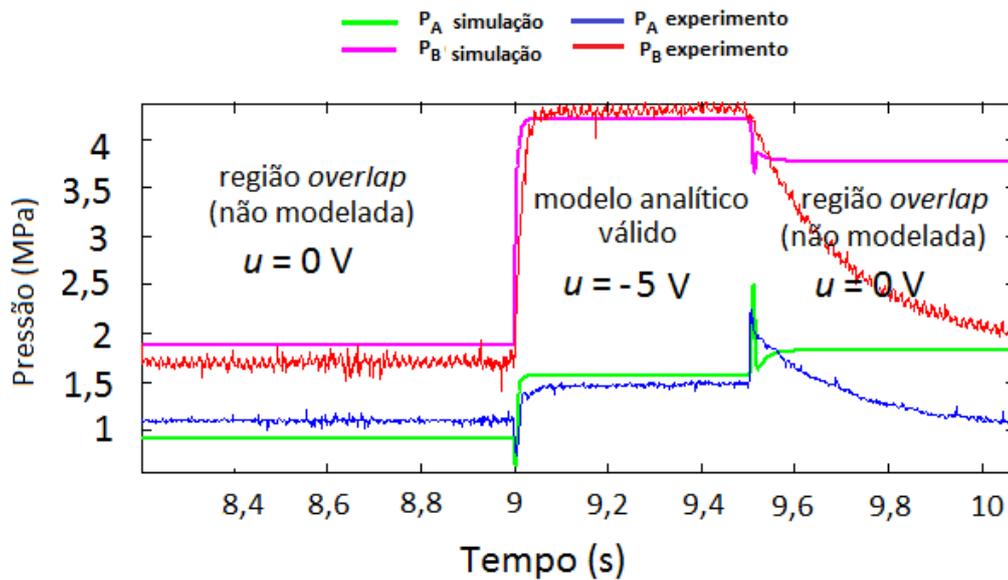


(b) Resposta para 5 V.

Figura 2.13 - Respostas do modelo analítico e dos experimentos – pressões medidas nos sensores de pressão (sinal positivo na válvula).



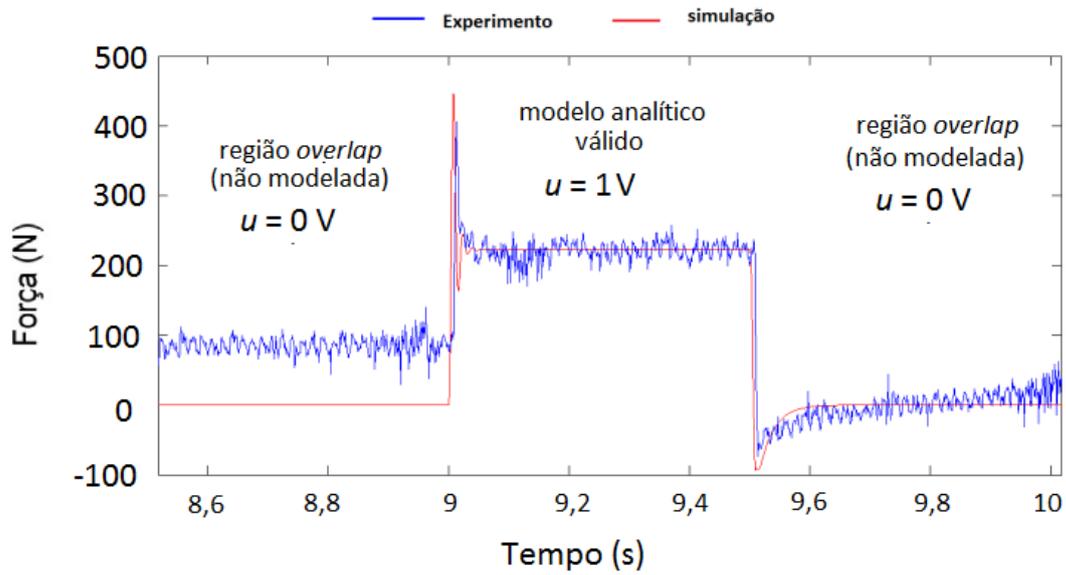
(a) Resposta para -1,5 V.



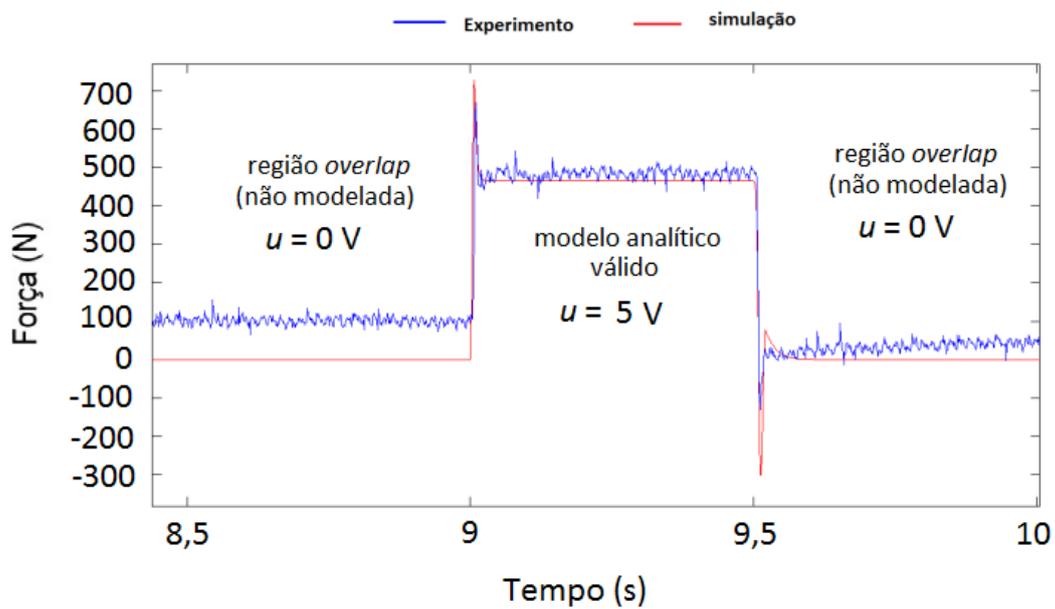
(b) Resposta para -5 V.

Figura 2.14 - Respostas do modelo analítico e dos experimentos – pressões medidas nos sensores de pressão (sinal negativo na válvula).

Os resultados experimentais da força hidráulica modificada no pistão (Equação (2.75)) e da resposta do modelo podem ser visualizados nas figuras 2.15 e 2.16.

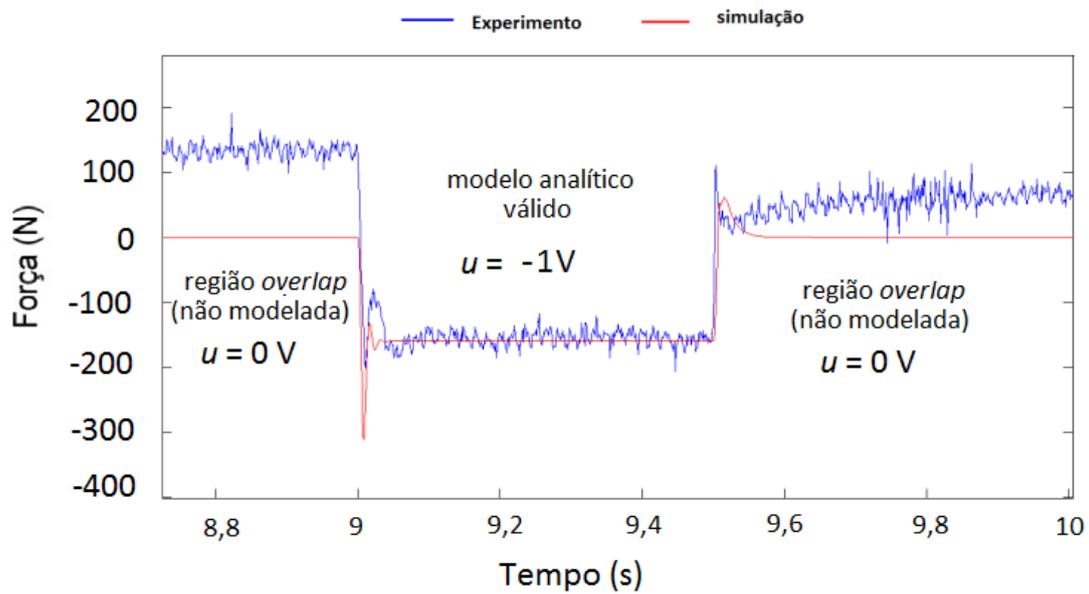


(a) Resposta para 1 V.

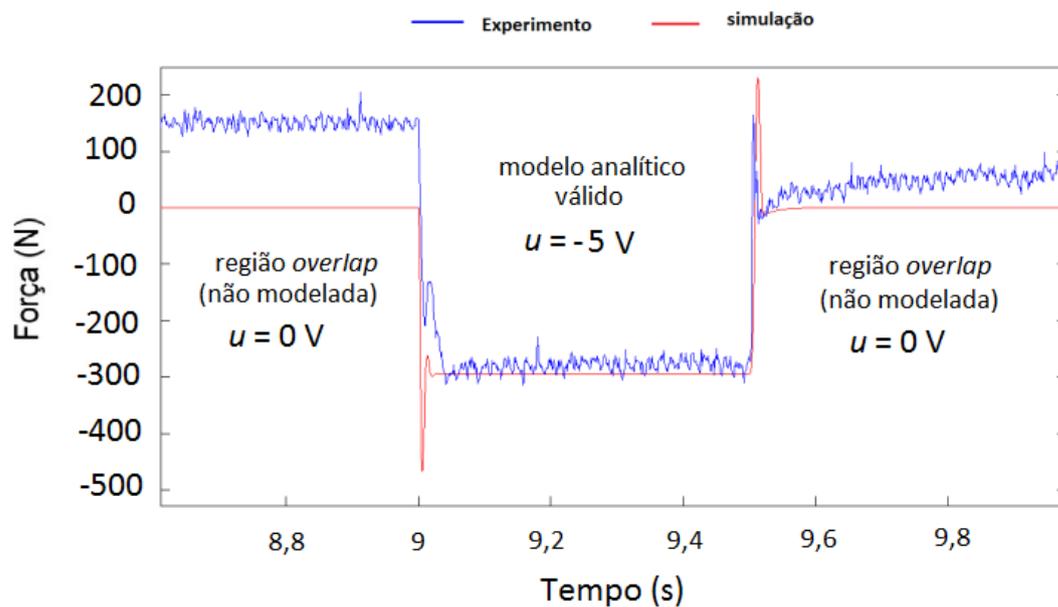


(b) Resposta para 5 V.

Figura 2.15 - Respostas do modelo analítico e dos experimentos – força hidráulica modificada F_H (sinal positivo na válvula).



(a) Resposta para -1 V.



(b) Resposta para -5 V.

Figura 2.16 - Respostas do modelo analítico e dos experimentos – força hidráulica modificada F_H (sinal negativo na válvula).

Os resultados experimentais da posição do pistão (referenciada pelo início do curso do mesmo como posição zero) e da resposta do modelo podem ser visualizados na Figura 2.17.

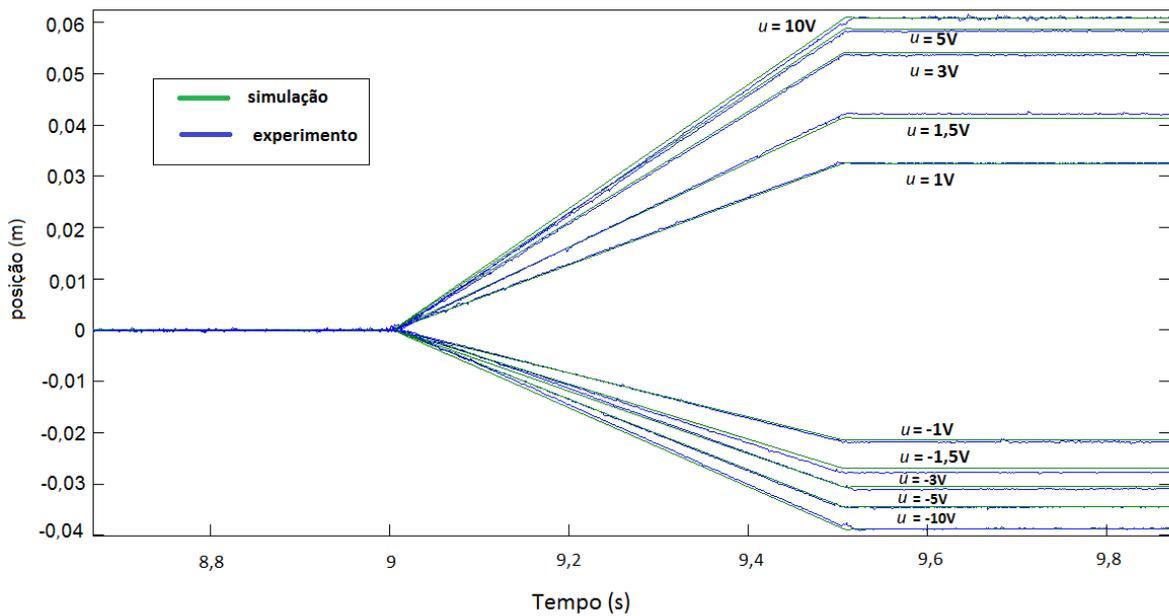


Figura 2.17 - Respostas do modelo analítico e dos experimentos - posição do pistão y .

Observa-se por meio da Figura 2.17 que não ocorrem variações na posição do pistão quando o mesmo encontra-se na região de *overlap*. Para possibilitar tal comportamento foi realizada a compensação do zero hidráulico da válvula, conforme discutido na Seção 2.3.6.

Com base na inspeção dos gráficos apresentados nas Figuras 2.13 a 2.17, pode-se concluir que o modelo oferece uma resposta semelhante à resposta dinâmica do servoposicionador da bancada experimental (com exceção da região de *overlap* do carretel da válvula).

Dentro do contexto do presente trabalho, baseando-se nos resultados e critérios de modelagem obtidos nos trabalhos de Watton, 2012, Pereira, 2006, Szpack, 2008 e Muraro, 2010, considera-se os resultados de validação apresentados suficientes para que o modelo descrito por meio das equações listadas na Tabela 2.4, cujos parâmetros são listados por meio da Tabela 2.3, possa ser utilizado para fins de simulação, com o objetivo de testar controladores e, também, para fins de utilização em estratégias de controle baseadas em modelo aplicadas à bancada experimental. Ressalta-se que, nesse caso, é necessário ainda considerar a compensação de atrito constituída somente da parcela de atrito viscoso, pois o modelo de Gomes e da Rosa, 2003, é descontínuo.

2.5. Modelo neural do Servoposicionador Hidráulico

Nesta seção é desenvolvido um modelo matemático para a bancada experimental onde a representação da força de atrito modificada (Equação (2.76)) e das vazões da válvula (equações (2.82) e (2.83)) será realizada por meio de redes neurais estáticas do tipo MLP (vide Apêndice D).

2.5.1. Identificação de sistemas utilizando RN.

Esta seção baseia-se no trabalho de Naredra, 1996, o qual consiste de um estudo clássico sobre os aspectos teóricos do uso de RN para identificação de sistemas.

Um sistema dinâmico autonomo não linear pode ser descrito pelo modelo do espaço de estados por meio das equações:

$$\mathbf{x}(k+1) = f(\mathbf{x}(k), \mathbf{u}(k)), \quad (2.86)$$

$$\mathbf{y}(k) = h(\mathbf{x}(k)), \quad (2.87)$$

onde k equivale ao instante de tempo amostrado e f e h são funções não lineares desconhecidas que necessitam ser identificadas. Além disso, tem-se que $\mathbf{u}(k), \mathbf{y}(k) \in \mathfrak{R}^m$, $\mathbf{x}(k) \in \mathfrak{R}^n$, e a função $f: \mathfrak{R}^n \times \mathfrak{R}^m \rightarrow \mathfrak{R}^n$ e $h: \mathfrak{R}^n \rightarrow \mathfrak{R}^m$. Se $m = 1$, o sistema tem uma única entrada e uma única saída (SISO). Se $m > 1$, o sistema tem múltiplas entradas e múltiplas saídas (MIMO). A constante n determina a ordem do sistema.

Supondo que o sistema seja identificado utilizando RN, então ele passa a poder ser descrito por meio das equações:

$$\hat{\mathbf{x}}(k+1) = N_f(\mathbf{x}(k), \mathbf{u}(k)), \quad (2.88)$$

$$\hat{\mathbf{y}}(k) = N_h(\mathbf{x}(k)), \quad (2.89)$$

onde N_f é uma RN que representa a função f e N_h é uma RN que representa a função h , o vetor $\hat{\mathbf{x}}(k+1)$ é a saída de N_f , os vetores $\mathbf{x}(k)$ e $\mathbf{y}(k)$ são as entradas, o vetor $\hat{\mathbf{y}}(k)$ é a saída de N_h e o

vetor $\mathbf{x}(k)$ é a entrada. Se todos os estados do vetor $\mathbf{x}(k)$ são acessíveis fisicamente, as Redes Neurais N_f e N_h podem ser representadas por RNs do tipo MLP estáticas. Para esta aplicação, o treinamento das mesmas é feito em função da minimização dos erros $\|\mathbf{x}(k+1) - \hat{\mathbf{x}}(k+1)\|$ e $\|\mathbf{y}(k) - \hat{\mathbf{y}}(k)\|$. Caso o sistema seja BIBO estável em malha aberta, é possível realizar um treinamento prévio *off line* usando pares de treinamento desse sistema.

2.5.2. Modelagem neural da válvula.

Conforme visto na Seção 2.1, o modelo analítico descrito por meio da Tabela 2.1 utiliza as seguintes equações para o cálculo das vazões da servoválvula:

$$Q_1 = K_{v1,via} \frac{u}{u_{\max}} g_1, \quad (2.90)$$

$$Q_2 = K_{v2,via} \frac{u}{u_{\max}} g_2. \quad (2.91)$$

É importante destacar que essas equações não utilizam informações dos parâmetros geométricos da válvula e sim o coeficiente da válvula K_v , obtido por meio de ensaios experimentais realizados pelo fabricante. Algumas observações devem ser feitas em relação a esse coeficiente:

a) **O coeficiente da válvula não é constante para valores de abertura do orifício inferiores a 40%**. Conforme Furst, 2001, quando na elaboração do projeto hidráulico, procura-se escolher uma válvula cujo coeficiente permita operar o servoposicionador com uma abertura superior a 40% da abertura máxima permitida pelo deslocamento do carretel, em acordo com as demais especificações do projeto, com a finalidade de evitar essa região não linear. Em Valdiero, 2005, essa característica é confirmada por meio de um ensaio experimental onde é variada a entrada u de uma válvula proporcional de centro fechado. O coeficiente da válvula, o qual o autor chama de K_{su} , é calculado através da Equação (2.92) mantendo a pressão de suprimento constante e medindo as demais grandezas. Assim,

$$K_{su} = \frac{Q_c}{u\sqrt{P_s - \text{sgn}(P_c)}}, \quad (2.92)$$

onde K_{su} é o coeficiente da válvula ($\text{m}^3/\text{s}/\text{V}/\sqrt{\text{Pa}}$), u é a entrada de controle (V), P_s é a pressão de suprimento (Pa), P_c é a pressão de carga (Pa) e Q_c é a vazão de controle (m^3/s).

O resultado do ensaio realizado em Valdiero, 2005, é ilustrado na Figura 2.18 e confirma variação significativa de K_{su} abaixo de 4 V, o que corresponde a 40% de abertura do orifício da válvula utilizada por esse autor.

b) O coeficiente da válvula é uma incerteza do modelo – Os dados de catálogo não são precisos quanto ao valor do coeficiente da válvula, o qual pode variar de válvula para válvula. Isso faz com que, mesmo na região onde se pode considerá-lo constante, o coeficiente da válvula possua uma incerteza paramétrica. Em Cunha, 2005, um controlador adaptativo por modelo de referência é utilizado para ajustar o coeficiente da válvula, melhorando os resultados obtidos nas simulações.

Algumas outras observações podem ser feitas também em relação ao modelo descrito por meio da Tabela 2.4:

a) As perdas de carga são difíceis de serem diretamente medidas – conforme discutido na Seção 2.3.5 foram encontradas dificuldades na realização de medição direta das perdas de carga, o que motivou adotar um procedimento de linearização dessas perdas e a obtenção das mesmas iterativamente via simulações sucessivas, o que constitui um exaustivo procedimento experimental.

b) Os dados fornecidos nos catálogos dos fabricantes podem não refletir os valores reais dos parâmetros – como exemplo, pode-se citar os parâmetros experimentais obtidos na Seção 2.3.6.

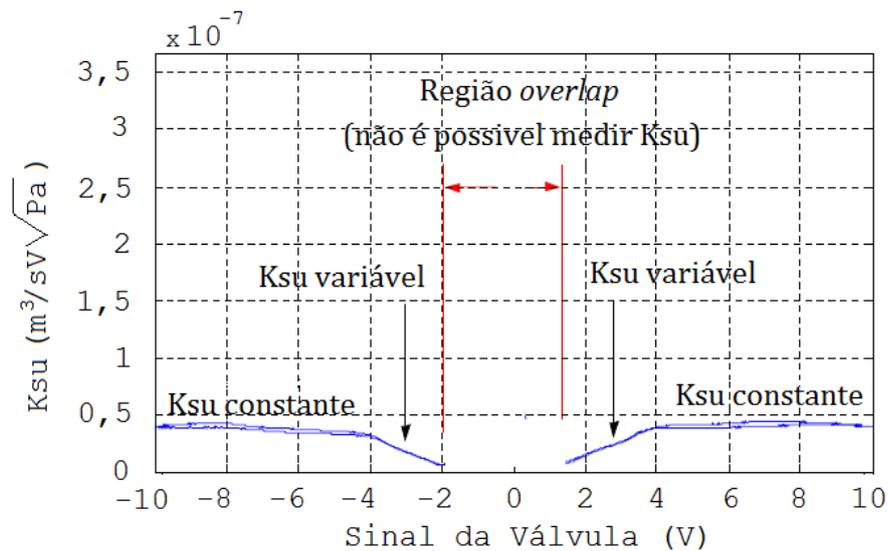


Figura 2.18 - Coeficiente da válvula com a variação do sinal de entrada [Valdiero, 2005]

As observações supracitadas motivam a utilização de ferramentas alternativas de modelagem. Neste caso, dois objetivos podem ser traçados:

- Simplificar o exaustivo processo experimental envolvido (considerando a obtenção fidedigna do coeficiente da válvula, perdas de carga e parâmetros de atrito), mantendo a efetividade;
- Melhorar a resposta do modelo matematicamente descrito pelas equações (2.90) e (2.91), buscando alternativas que ofereçam respostas mais próximas às medidas experimentais.

Nesse sentido, propõe-se substituir as equações (2.90) e (2.91), por uma função não linear na forma:

$$\Upsilon(u_{\max}, K_{v1,via}, K_{v2,via}, P_s, P_1, P_2, C_{l1}, C_{l2}, C_{l3}, C_{l4}, \dot{y})u = \begin{bmatrix} Q_1 \\ Q_2 \end{bmatrix}, \quad (2.93)$$

onde Υ é a função não linear que representa as vazões de controle.

Como as informações de entrada e saída são mensuráveis (por medição e estimação), é possível que a função descrita por meio da Equação (2.93) seja representada por uma RN do tipo MLP estática. Do ponto de vista de uma RN, as informações referentes a constantes (coeficientes de perdas de carga, coeficientes da válvula e pressão de suprimento) podem ser

incorporadas aos pesos sinápticos através do treinamento. As vazões de controle da servoválvula podem, então, ser representadas pela MLP da Equação (2.94):

$$\begin{bmatrix} Q_1 \\ Q_2 \end{bmatrix} = \mathbf{N}_r(\dot{y}, P_1, P_2)u, \quad (2.94)$$

onde N_r é a RN que representa as vazões de controle ($\text{m}^3/\text{s}/\text{V}$).

As equações (2.95) e (2.96) são utilizadas para estimar as vazões Q_1 e Q_2 , necessárias para o treinamento da rede neural:

$$Q_1 = \frac{(V_{10} + A_1 y) \dot{P}_1}{\beta} + A_1 \dot{y}, \quad (2.95)$$

$$Q_2 = \frac{(A_2 y - V_{20}) \dot{P}_2}{\beta} + A_2 \dot{y}. \quad (2.96)$$

onde as derivadas das pressões \dot{P}_1 e \dot{P}_2 (Pa/s) e a velocidade do pistão \dot{y} (m/s) são estimadas por derivação numérica.

A Equação (2.38) torna-se:

$$\dot{P}_1 A_1 - \dot{P}_2 A_2 = [A_1 f_1 N_{11r}(\dot{y}, P_1, P_2) + A_2 f_2 N_{21r}(\dot{y}, P_1, P_2)]u - (A_1^2 f_1 + A_2^2 f_2) \dot{y}. \quad (2.97)$$

2.5.3. Modelagem neural do atrito

Modelos neurais de representação do atrito para atuadores hidráulicos já são encontrados na literatura [Zibin et al, 2008, Machado, 2003, Gervini, 2014]. Com relação a esses tópicos, o presente trabalho baseia-se parcialmente em Machado, 2003 e Gervini, 2014.

É importante, no contexto, lembrar que o modelo do coeficiente de atrito viscoso variável apresentado na Seção 2.1 tem características estáticas mapeadas por uma função não linear cujas entradas são F_H e \dot{y} (força hidráulica e velocidade do pistão, respectivamente). Conhecendo-se a massa do pistão e calculando-se, a partir do sinal medido de posição, por derivação numérica, a aceleração do pistão, a força de atrito pode ser estimada indiretamente por meio da aplicação da Equação (2.98), uma vez que a força hidráulica pode ser calculada

por meio dos sinais das pressões P_1 e P_2 , conforme a Equação (2.35). A força de atrito pode, portanto, ser expressa por:

$$F_A = F_H - M\ddot{y}. \quad (2.98)$$

Propõe-se, nesta seção, a representação da força de atrito por meio da Equação (2.99), a qual esta grandeza é representada por uma RN do tipo MLP estática, onde tal rede é treinada utilizando valores experimentais da velocidade do pistão \dot{y} como entrada e a força de atrito estimada por meio da Equação (2.98) como saída:

$$F_A = N_{\Delta}(\dot{y}), \quad (2.99)$$

onde N_{Δ} é a RN que representa o atrito.

2.5.4. Modelo neural da bancada experimental.

Conforme descrito na Seção 2.4, para obtenção do conjunto de treinamento *off-line* para N_{γ} , é necessária a aplicação de uma entrada e a medição das grandezas de interesse em um sistema BIBO estável. No caso da bancada experimental do presente trabalho, um controlador proporcional em malha fechada é capaz de estabilizar o sistema mediante um ganho proporcional limitado, conforme demonstrado, por exemplo, em Paim, 1997, e por meio de experimentos no Capítulo 5. O conjunto de treinamento é obtido mediante o controle de posição em malha fechada, cujo diagrama de blocos está apresentado na Figura 2.19.

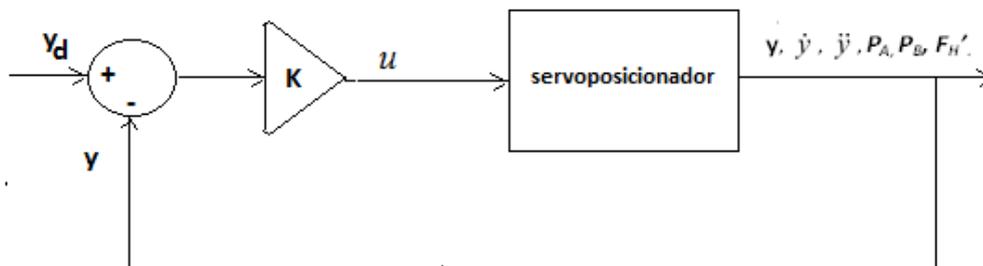


Figura 2.19 - Treinamento da RN

O modelo neural proposto para a bancada experimental é descrito por meio das equações da Tabela 2.5.

Tabela 2.5 – Equações do modelo neural da bancada experimental.

Equação	número
$P_A A_1 - P_B A_2 = M\dot{y} + F_A' + F_L$	(2.80)
$F_A' = N_\Delta(\dot{y})$	(2.76)
$\dot{P}_A A_1 - \dot{P}_B A_2 = [A_1 f_1 N_{11Y}(\dot{y}, P_A, P_B) + A_2 f_2 N_{21Y}(\dot{y}, P_A, P_B)]u - (A_1^2 f_1 + A_2^2 f_2)\dot{y}$	(2.100)
$\begin{bmatrix} Q_1 \\ Q_2 \end{bmatrix} = N_Y(\dot{y}, P_A, P_B)u$	(2.101)
$f_1 = \frac{\beta}{V_{10} + A_1 y}$	(2.39)
$f_2 = \frac{\beta}{V_{20} - A_2 y}$	(2.40)

Os dados u, \dot{y}, P_A, P_B medidos determinam os pares de treinamento de N_Y . O domínio dessa RN depende dos valores atribuídos para y_d e para o ganho K utilizado.

Uma trajetória descrita por um polinômio de sétima ordem para y_d , representada por meio da Equação (2.102), e um conjunto de diferentes ganhos proporcionais K para o controlador são utilizados. Os ganhos K utilizados são de 10, 20, 50, 100, 200, 250, 400, 500, 600, 1000, sempre com a mesma entrada y_d .

$$y(t) = 0,9(-2t^7 + 7t^6 - 8,4t^5 + 3,5t^4),$$

$$y_d = \begin{cases} y(0,75t) & t < 1,5 \\ 0,09 & 1,5 \leq t < 4 \\ -y(0,5t - 2) + 0,09 & 4 \leq t < 6 \\ 0 & 6 \leq t < 8 \\ -y(0,5t - 4) & 8 \leq t < 10 \\ -0,09 & 10 \leq t < 12 \\ y(0,75t - 9) - 0,09 & 12 \leq t < 13,5 \\ 0 & 13,5 \leq t < 16 \end{cases} \quad (\text{m}). \quad (2.102)$$

Para cada ensaio realizado é armazenado o valor referente à entrada u gerada pelo controlador. A trajetória proposta tem por objetivo reproduzir as trajetórias de velocidade,

pressões medidas, posição e aceleração as quais o sistema estará submetido em seu uso típico, procurando, por meio da variação do ganho do controlador, obter as variações destas grandezas desde seus valores mínimos até os seus valores máximos.

Os valores armazenados são utilizados como entradas para o sistema experimental, que opera com o servoposicionador hidráulico em malha aberta. Os resultados experimentais referentes aos valores das entradas de N_Y , que são \dot{y} , P_A , P_B e referente aos valores das saídas, que são Q_1/u e Q_2/u , formam o conjunto de pares de treinamento, onde Q_1 e Q_2 são obtidos por meio das equações (2.95) e (2.96) substituindo as derivadas de P_1 e P_2 pelas derivadas de P_A e P_B . Um subconjunto desses valores, onde o ganho K utilizado é 300, é reservado para formar o conjunto de pares de teste do treinamento.

A arquitetura da rede foi escolhida visando proporcionar o menor erro em relação ao conjunto de teste. Os procedimentos adotados foram baseados em Masters, 1993, onde são apresentadas e discutidas possibilidades de ação visando à composição da arquitetura de uma RN MLP. As principais premissas são as seguintes:

- ✓ Uma MLP com duas camadas escondidas pode representar a maioria dos processos físicos existentes. Quando se coloca mais de duas camadas escondidas, a tendência é que os pesos da terceira camada em diante tenham pouca ou nenhuma representatividade, tendendo a valores muito baixos.
- ✓ A rede não deve ter mais neurônios que o mínimo necessário, pois nesse caso pode ocorrer sobre treinamento.

Seguindo-se as referidas premissas supracitadas, a rede foi gradualmente aumentada, inicialmente utilizando somente uma camada escondida e, mais tarde, aumentando para duas, até que um valor satisfatório foi alcançado para o erro de teste. Para que esse valor fosse atingido, foi necessário dividir a RN em duas, uma aplicada a valores positivos para a força hidráulica e outra aplicada a valores negativos. Essa divisão foi necessária porque os efeitos dinâmicos são diferentes para ambas as direções do movimento do pistão, conforme comentado na Seção 2.2. A arquitetura final das RN MLP, em ambos os sentidos, foi definida como 3-20-20-2, ou seja, três entradas, vinte neurônios na primeira camada escondida, vinte neurônios na segunda camada escondida e dois neurônios na camada de saída.

A Tabela 2.6 mostra as normalizações propostas para as entradas e saídas.

Tabela 2.6 - Parâmetros de normalização para as RN da válvula

<i>Parâmetro</i>	<i>Valor máximo</i>	<i>Valor mínimo</i>
Q_1/u	$5,0 \cdot 10^{-5} \text{ m}^3/\text{s}/\text{V}$	$-1,0 \cdot 10^{-5} \text{ m}^3/\text{s}/\text{V}$
Q_2/u	$5,0 \cdot 10^{-5} \text{ m}^3/\text{s}/\text{V}$	$-1,0 \cdot 10^{-5} \text{ m}^3/\text{s}/\text{V}$
P_A	2,5 MPa	0,01 MPa
P_B	50 MPa	0,01 MPa
\dot{y}	0,15 m/s	-0,1 m/s

O treinamento foi realizado utilizando o algoritmo *Quickprop*, descrito no Apêndice D. A Tabela 2.7 mostra os parâmetros de treinamento para a rede positiva e a Tabela 2.8 para a rede negativa.

Tabela 2.7 – Parâmetros referentes ao treinamento: RN positiva

Erro de treinamento normalizado	$10,05 \cdot 10^{-5}$
Pares de treinamento	1800
Pares de teste	1000
Erro de teste normalizado	$1,1 \cdot 10^{-3}$
Constante de treinamento	$1,0 \cdot 10^{-4}$
Número de épocas	110

A Figura 2.20 mostra, para a rede positiva, a razão da vazão nominal com a amplitude da tensão aplicada obtida pela Rede Neural e por experimentos, utilizando, como dados de entrada, o conjunto de teste. A Figura 2.21 mostra a mesma razão referente à rede negativa, utilizando, também como dados de entrada, o conjunto de teste.

Tabela 2.8 – Parâmetros referentes ao treinamento: RN negativa

Erro de treinamento normalizado	$34,5 \cdot 10^{-5}$
Pares de treinamento	1200
Pares de teste	1000
Erro de teste normalizado	$1,105 \cdot 10^{-3}$
Constante de treinamento	$1,0 \cdot 10^{-4}$
Número de épocas	88

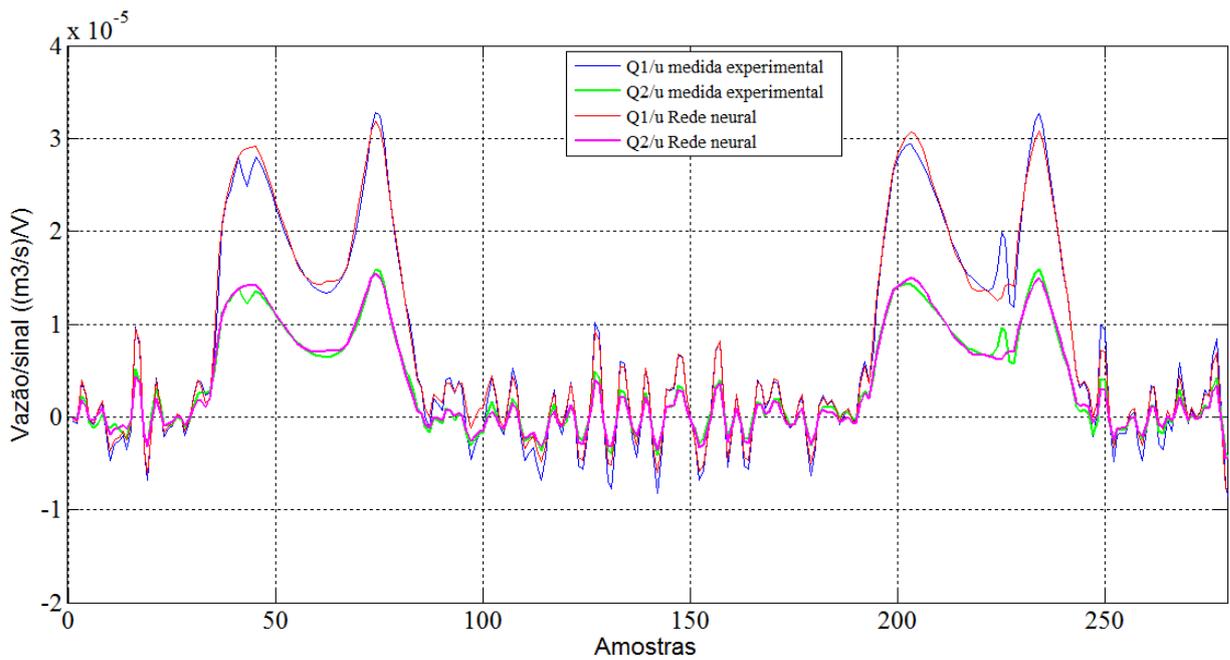


Figura 2.20- Comparação entre conjunto de teste e saídas da Rede Neural positiva.

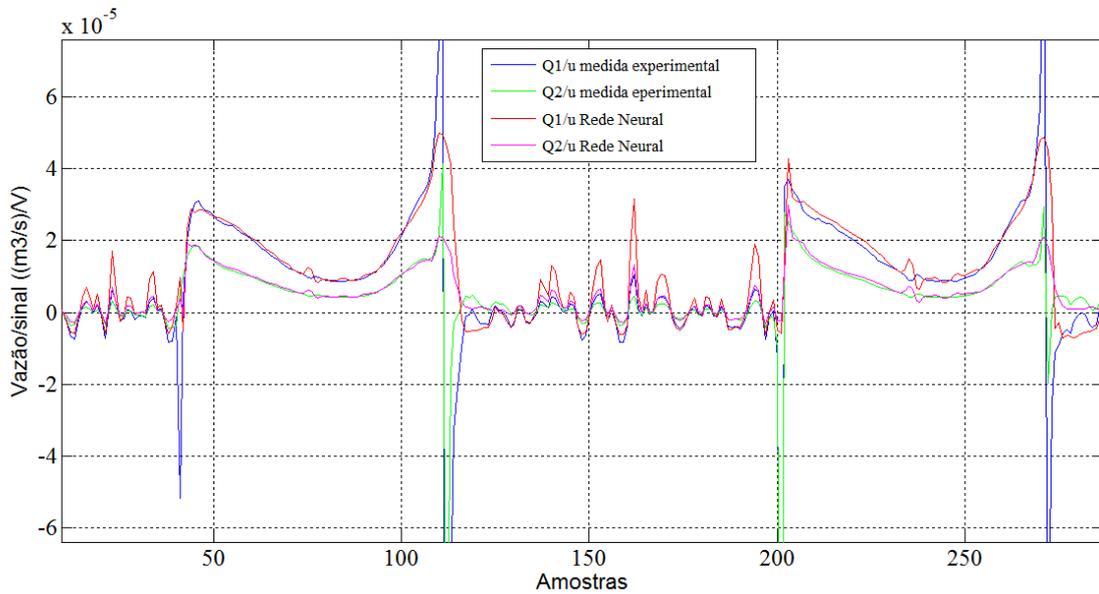


Figura 2.21 - Comparação entre o conjunto de teste e saídas da Rede Neural negativa.

Observa-se pelas figuras 2.20 e 2.21 que a saída de N_ψ é semelhante a medida experimental das grandezas Q_1/u e Q_2/u da válvula.

Para o atrito modificado, os pares de treinamento foram obtidos utilizando os dados oriundos dos mesmos experimentos da RN apresentados anteriormente. A entrada da rede neural corresponde à medida da velocidade do pistão e a saída é o atrito modificado, obtido por meio de:

$$F_A' = F_H' - M\ddot{y}. \quad (2.103)$$

A definição da arquitetura da RN seguiu as mesmas premissas do caso anterior, tendo sido definida uma RN de configuração 1-10-10-1. O treinamento foi também realizado utilizando o algoritmo *Quickprop*.

Na Tabela 2.9 são apresentados os valores de normalização para as entradas e saídas da RN que representa a força de atrito modificada. Na Tabela 2.10 são apresentados os parâmetros de treinamento para a mesma RN.

A Figura 2.22 mostra a saída objetivo sobreposta com a saída da RN para o conjunto de teste. Através da análise das curvas apresentadas, é possível concluir que N_Δ apresenta uma resposta semelhante ao da força de atrito modificada.

Tabela 2.9 - Parâmetros de normalização para a RN do atrito modificado.

<i>Parâmetro</i>	<i>Valor máximo</i>	<i>Valor mínimo</i>
\dot{y}	0,2 m/s	-0,2 m/s
$F_{\text{atrito modificada}}$	500 N	-400 N

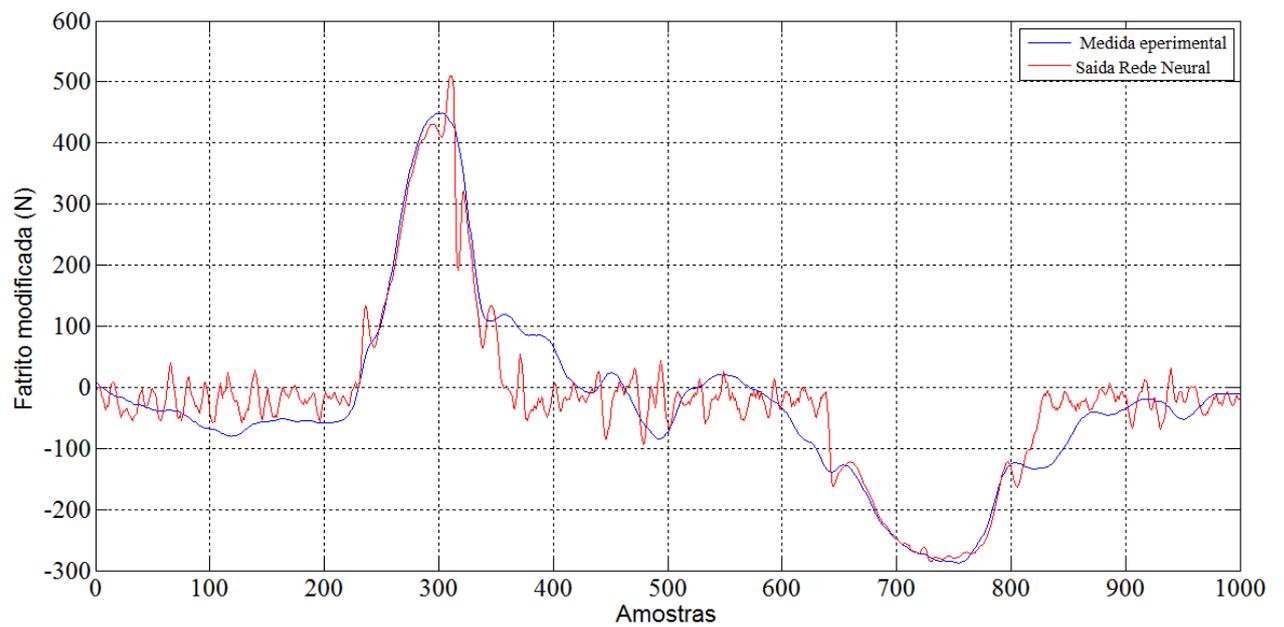


Figura 2.22 - Comparação entre a Força de Atrito modificada obtida experimentalmente e a saída da RN.

Tabela 2.10 - Resumo do treinamento RN atrito modificado

Erro de treinamento normalizado	$3,2 \cdot 10^{-3}$
Pares de treinamento	2400
Pares de teste	1000
Erro de teste normalizado	$1,73 \cdot 10^{-3}$
Constante de treinamento	$1,0 \cdot 10^{-4}$
Número de épocas	300

2.6. Comparação dos resultados de simulação do modelo analítico com os do modelo neural.

Nesta seção é feita uma comparação entre os resultados de simulação obtidos com o uso do modelo matemático analítico apresentado na Tabela 2.4 e o modelo neural descrito por meio das equações da Tabela 2.5.

A comparação é feita a partir dos resultados de simulações realizadas com o uso do software Simulink dos modelos programados em malha aberta. Nas simulações, como entrada u da válvula são utilizadas as medidas experimentais de u com o servoposicionador operando em malha fechada, com o controlador da Figura 2.19 com ganho proporcional $K = 300$.

Na Figura 2.23 é apresentada a resposta da pressão P_A e na Figura 2.24 é apresentada a resposta da pressão P_B . Observa-se, pela inspeção dessas figuras, que a resposta das pressões obtida por meio do modelo neural possui maior semelhança com a resposta das curvas experimentais.

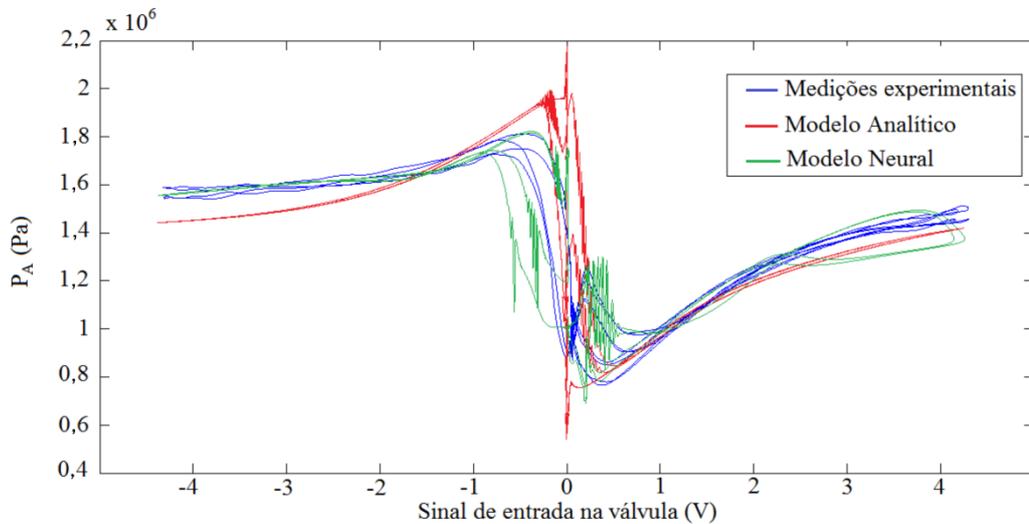


Figura 2.23 - Comparação entre as pressões P_A das simulações dos modelos analítico e neural e da curva experimental.

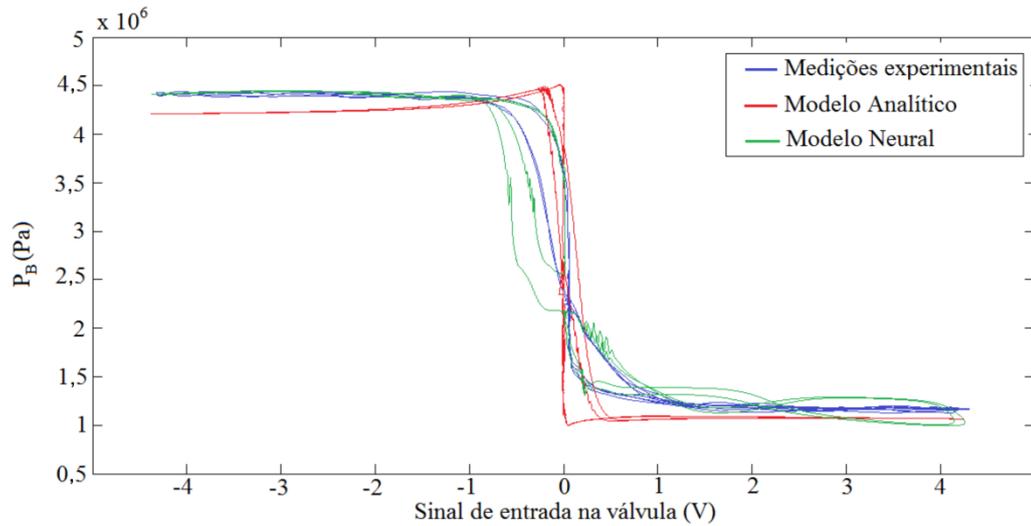


Figura 2.24 - Comparação entre as pressões P_B das simulações dos modelos analítico e neural da curva experimental.

Os resultados para a posição do pistão em malha aberta estão apresentados na Figura 2.25. Os resultados de desvio de posição mostram, por inspeção, que a resposta do modelo com funções neurais é semelhante à resposta do modelo analítico, confirmando também a semelhança de ambos os modelos com a resposta experimental. Destaca-se o fato do modelo neural poder ser obtido com menor esforço experimental.

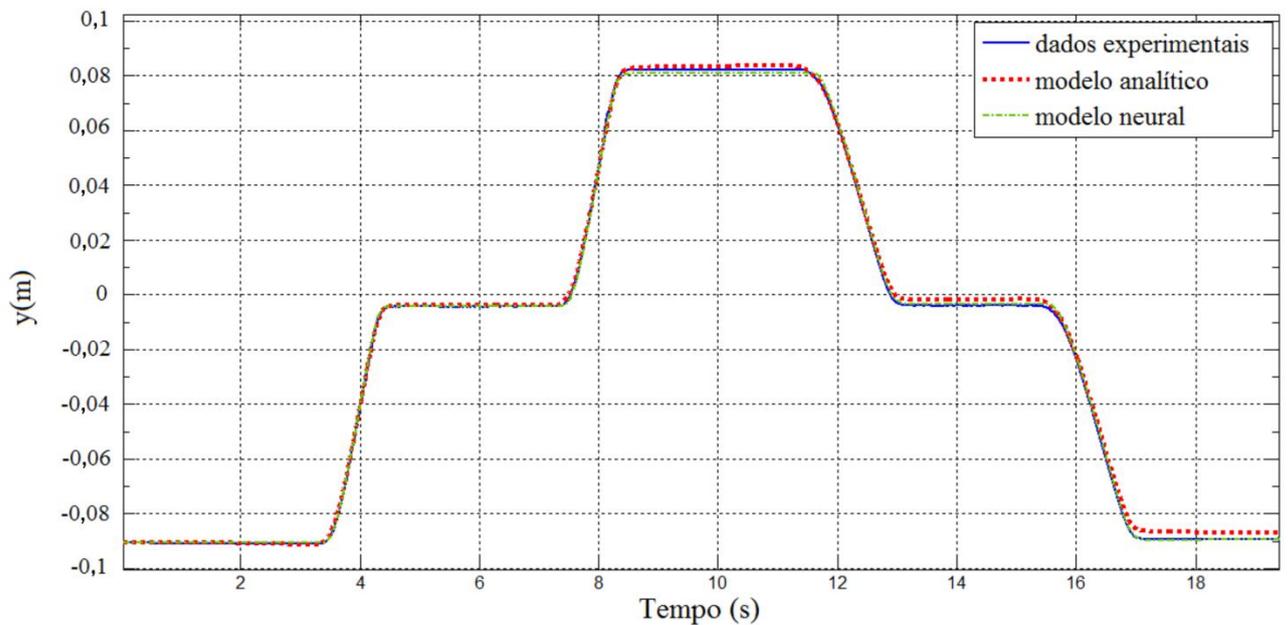


Figura 2.25 - Resposta em malha aberta da posição do pistão - simulações e resultado experimental

2.7. Discussões do Capítulo 2.

Mediante discussões sobre resultados encontrados na bibliografia e dos próprios resultados obtidos e simulações efetuadas, pode-se afirmar que o modelo analítico desenvolvido no presente trabalho aproxima o comportamento do servoposicionador hidráulico, mesmo considerando as simplificações adotadas. A aplicação desse modelo simplificado requer significativo trabalho experimental e a pesquisa de parâmetros em catálogos. Como contribuição no âmbito do presente trabalho, destaca-se a metodologia de obtenção das perdas de carga, com a proposição de uso de constantes aglutinadoras dos efeitos das perdas, cujos ajustes foram realizados interativamente via simulação, procurando aproximar as curvas de pressão medidas e posição do pistão com as respectivas curvas experimentais. Os coeficientes de perda de carga obtidos por esse método foram considerados satisfatórios. Em contrapartida, o modelo neural obtido para o servoposicionador hidráulico não exige um trabalho experimental muito extenso, sendo utilizadas somente algumas medidas experimentais. O experimento realizado é simples e tem por objetivo a obtenção dos pares de treinamento e validação da RN. A resposta da simulação dos modelos, programados em malha aberta, em relação a uma entrada u , mostrou que a resposta do modelo neural é semelhante a resposta obtida com o modelo analítico para a entrada u testada.

3. CONTROLE DO SISTEMA DINÂMICO

Com base em Cunha, 1997, Pereira, 2006, Cunha, 2001, Perondi, 2002, pode-se afirmar que o controle realimentado tem sido utilizado no controle de posicionamento de sistemas fluídicos com três objetivos distintos:

- a) Controlar o atuador de modo que o mesmo parta de um valor A para um valor B de posição, chamado de controle ponto a ponto de posição ou controle de posição (pode, também, ser tratado como um problema de regulação);
- b) Controlar o atuador de modo que o mesmo siga o mais próximo possível uma trajetória de posição pré-definida, chamado de controle de trajetória de posição ou controle de trajetória;
- c) Controlar o atuador de modo que o mesmo aplique uma força pré-estabelecida em relação ao meio ou a um objeto, chamado de controle de força.

Neste capítulo, objetiva-se apresentar e discutir as principais técnicas de controle para servoposicionadores hidráulicos. Inicialmente, serão apresentadas as técnicas mais importantes de controle linear e as suas limitações. Posteriormente, as técnicas de controle não lineares serão também abordadas.

3.1. Controladores lineares.

Apresenta-se, nesta seção, as estratégias de controle linear normalmente utilizadas no controle de trajetória de posição de atuadores hidráulicos, de acordo com Cunha, 1997, Pereira, 2006, Machado, 2010 e Watton, 2012.

3.1.1. Obtenção do modelo Analítico linear

O modelo analítico linear, conforme discutido na Seção 2.2, depende do ponto de linearização escolhido. Assim, para definir esse ponto, optou-se, no presente trabalho, por utilizar uma trajetória padrão, no caso, um polinômio de sétima ordem, como em Cunha, 2001. Esta trajetória está ilustrada na Figura 3.1 e é descrita por meio da Equação (3.1).

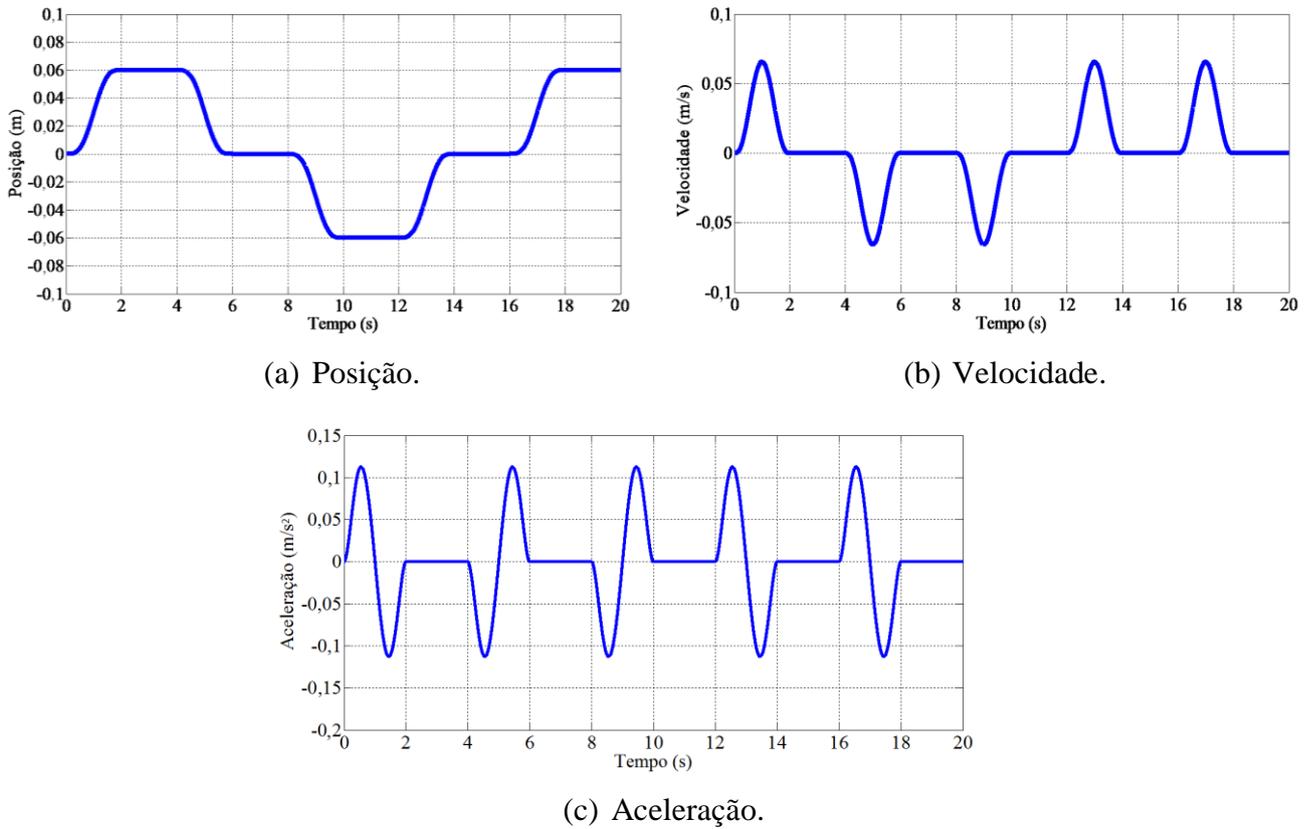


Figura 3.1 – Trajetória desejada.

$$y(t) = 0,6(-2t^7 + 7t^6 - 8,4t^5 + 3,5t^4)$$

$$y_d = \begin{cases} y(t/2) & t < 2 \\ 0,06 & 2 \leq t < 4 \\ -y(t/2 - 2) + 0,06 & 4 \leq t < 6 \\ 0 & 6 \leq t < 8 \\ -y(t/2 - 4) & 8 \leq t < 10 \\ -0,06 & 10 \leq t < 12 \\ y(t/2 - 6) - 0,06 & 12 \leq t < 14 \\ 0 & 14 \leq t < 16 \end{cases} \quad (\text{m}). \quad (3.1)$$

Tomando-se o modelo analítico da bancada experimental, descrito por meio das equações da Tabela 2.4, e os valores obtidos na Seção 2.3 para o mesmo, valores esses listados na Tabela 2.3, é possível determinar os ganhos de vazão e vazão-pressão através das equações (2.52) a (2.55). Foi primeiramente realizada uma simulação com um controlador

proporcional, utilizado para o controle de seguimento da trajetória desejada, ilustrada na Figura 3.1. Dessa simulação, tem-se que os valores de 1,05 V (sentido positivo) e -2,738 V (sentido negativo) correspondem ao sinal de entrada da válvula na respectiva velocidade de maior vazão para o pistão em ambos os sentidos. Aplicando esses valores como entradas do tipo degrau, em uma nova simulação do mesmo modelo em malha aberta, obtêm-se os valores de interesse para a linearização do modelo, ou seja, P_A (que é utilizado em P_1), P_B (que é utilizado em P_2), ΔP_1 , ΔP_2 , ΔP_3 , ΔP_4 aplicados nas equações (2.52) e (2.53) no ponto de linearização. A Tabela 3.1 apresenta os valores referentes aos ganhos do modelo linearizado, sendo B_{eq} calculado por meio da Equação (2.63), considerando $B = Z$ (Equação (2.79)). Aplicando-se esses valores, juntamente com os demais valores da Tabela 2.3, e, considerando $V_0 = 7,438 \cdot 10^{-5} \text{ m}^3$ para a Equação (2.41), obtêm-se a Equação (3.2) para o sentido positivo e a Equação (3.3) para o sentido negativo:

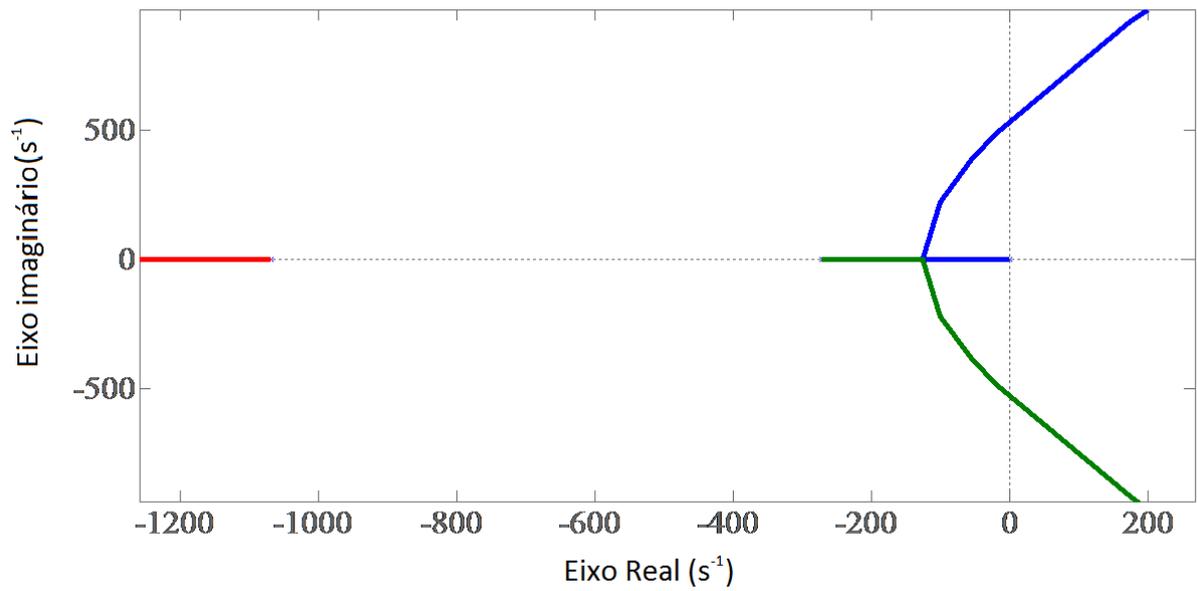
$$G_p(s) = \frac{17,90 \cdot 10^3}{s^3 + 1340s^2 + 2,913 \cdot 10^5 s}, \quad (3.2)$$

$$G_n(s) = \frac{7,2369 \cdot 10^3}{s^3 + 1016s^2 + 2,8014 \cdot 10^5 s}. \quad (3.3)$$

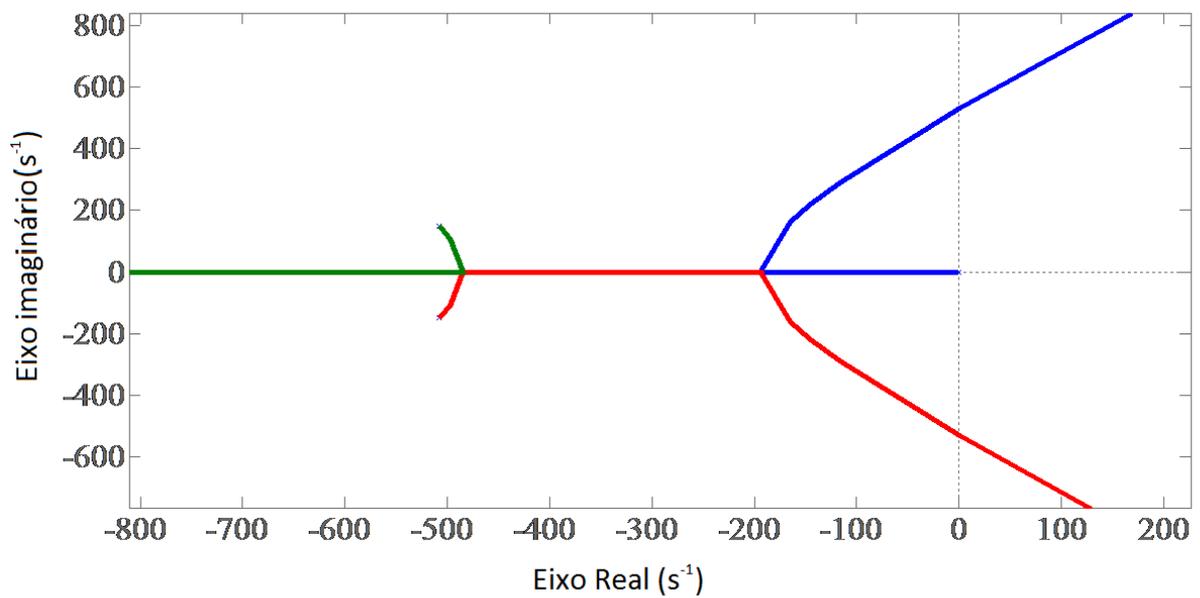
Tabela 3.1 – Valores dos parâmetros utilizados no modelo linear

K_{q1}	$3,1780 \cdot 10^{-5} \text{ (m}^3/\text{s)/V}$	$u \geq 0$
K_{q2}	$1,5340 \cdot 10^{-5} \text{ (m}^3/\text{s)/V}$	
K_{cp}	$9,0077 \cdot 10^{-13} \text{ (m}^3/\text{s)/Pa}$	
B_{eq}	19317 Ns/m	
K_{q1}	$1,2928 \cdot 10^{-5} \text{ (m}^3/\text{s)/V}$	$u < 0$
K_{q2}	$6,2402 \cdot 10^{-6} \text{ (m}^3/\text{s)/V}$	
K_{cp}	$3,6643 \cdot 10^{-13} \text{ (m}^3/\text{s)/Pa}$	
B_{eq}	14705 Ns/m	

A Figura 3.2 apresenta o Lugar Geométrico das Raízes (LGR) de (3.2) e (3.3), respectivamente, do servoposicionador com um controlador proporcional.



a) Deslocamento positivo



b) Deslocamento negativo

Figura 3.2 - Lugar Geométrico das Raízes do modelo linear .

Como se pode perceber analisando-se a Figura 3.2, conforme se aumenta o ganho proporcional, dois polos complexos conjugados se aproximam do semiplano direito do plano complexo, fazendo aparecer oscilações pouco amortecidas na resposta do erro e podendo

levá-lo à região instável. Uma particularidade importante do presente trabalho são os polos em malha aberta. Devido ao elevado amortecimento provocado pelas perdas de carga na bancada de testes, os mesmos estão sobre o eixo real na Equação (3.20) e próximos do mesmo na Equação (3.3).

3.1.2. Controlador PID

O controlador Proporcional-Integral-Derivativo (PID) pode ser descrito pela equação [Dorf e Bishop, 2008]:

$$u(t) = K_P e(t) + K_I \int_0^t e(t) dt + K_D \frac{de(t)}{dt}, \quad (3.4)$$

onde K_P é o ganho proporcional, K_I é o ganho integral e K_D é o ganho derivativo.

Descrições sobre o comportamento do controlador PID aplicado a um servoposicionador hidráulico podem ser encontradas em vários trabalhos [Paim, 1997; Guenther e De Pieri, 1997; Cunha, 1997; Cunha, 2001; Pereira, 2006; Machado, 2010].

A metodologia de ajuste de ganhos aplicada a atuadores hidráulicos encontrada com maior frequência nas referências bibliográficas é o método de Ziegler-Nichols, utilizado, por exemplo, nos trabalhos de Ghazali et al., 2011b, Seo et al., 2007, Pedro e Dahunsi, 2011, e Mintsá et al., 2012. Esse método caracteriza-se por não necessitar do conhecimento preciso da dinâmica da planta.

No presente trabalho, a planta é considerada conhecida (equações (3.2) e (3.3)). Nesse contexto, optou-se em obter o ganho proporcional por meio de um aumento gradativo do ganho, mediante o controle de seguimento da trajetória de posição descrita por meio da Figura 3.1, até que oscilações estacionárias comecem a aparecer na trajetória de posição do pistão. Esse comportamento foi identificado a partir de um ganho proporcional $K_P = 600$, para uma temperatura de 30 °C do fluido hidráulico.

Ao serem incluídas as parcelas integral e derivativa, utilizou-se a metodologia de posicionamento dos polos desejados em malha fechada pelo método do Lugar Geométrico das Raízes [Ogata, 1990; Dorf e Bishop, 2008].

Por fim, realizou-se um refinamento na sintonia dos ganhos por meio de interações heurísticas.

Assim, o processo de sintonia dos ganhos do controlador PID para o seguimento da trajetória da Figura 3.1 pode ser descrito por meio dos seguintes passos:

- 1) Utiliza-se a ação de controle puramente proporcional com ganho K_P crescente para o seguimento da trajetória de posição desejada na bancada experimental até o limite do aparecimento de oscilações estacionárias na trajetória do pistão, obtendo-se, dessa forma, o valor do ganho proporcional K_P limite igual a 650 ($T = 30^\circ\text{C}$).
- 2) A partir do ganho obtido, utilizou-se a ferramenta *sisotool* do *software* Matlab, incluindo as parcelas integral e derivativa do controlador. Essa é uma ferramenta gráfica, na qual é possível alterar os ganhos do controlador diretamente a partir do posicionamento dos polos e zeros no lugar geométrico das raízes e verificar seu efeito na resposta ao degrau do sistema. Utilizou-se a Equação (3.2) como função de transferência, que é mais restrita para a sintonia dos ganhos do que a equação (3.3). Dessa forma, posicionou-se interativamente os polos em malha fechada, de modo a obter-se a resposta considerada adequada (menor sobre sinal com menor tempo de acomodação [Ogata, 1990]) a uma entrada do tipo degrau.
- 3) Utilizando-se o controlador PID obtido nos passos 1 e 2, observou-se a resposta de erro de seguimento de trajetória de posição na bancada experimental para realizar ajustes nos ganhos, com o objetivo de obter respostas consideradas adequadas.

Os Ganhos ajustados para o controlador estão apresentados na Tabela 3.2.

Tabela 3.2 - Ganhos do controlador PID sintonizados ($T = 30^\circ\text{C}$).

Ganho	K_P	K_I	K_D
Valor	420	2018	0,9

3.1.3. Controlador por realimentação de estados PVA (Posição, Velocidade e Aceleração).

O Controlador por realimentação de estados é um controlador linear baseado na estratégia de alocação de polos [Ogata, 1990; Dorf e Bishop, 2008], sendo utilizado para a imposição de uma dinâmica desejada em malha fechada ao sistema.

Considera-se um sistema de controle genérico descrito pela Equação (3.5):

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u} \\ \mathbf{y} = \mathbf{C}\mathbf{x} \end{cases}, \quad (3.5)$$

onde, $\mathbf{u} \in \mathcal{R}^m$ e $\mathbf{y} \in \mathcal{R}^r$ são os vetores de entrada e de saída, $\mathbf{x} \in \mathcal{R}^n$ é o vetor de estados, $\mathbf{A} \in \mathcal{R}^{n \times n}$, $\mathbf{B} \in \mathcal{R}^{n \times m}$ e $\mathbf{C} \in \mathcal{R}^{r \times n}$ são matrizes conhecidas.

Se os estados do sistema são mensuráveis e o sistema é controlável, é possível estabelecer a seguinte lei de controle:

$$\mathbf{u} = -\mathbf{K}\mathbf{x}, \quad (3.6)$$

onde $\mathbf{K} \in \mathcal{R}^{m \times n}$ é a matriz de ganho de realimentação de estado.

Substituindo-se (3.6) em (3.5), tem-se:

$$\dot{\mathbf{x}}(t) = (\mathbf{A} - \mathbf{B}\mathbf{K})\mathbf{x}(t), \quad (3.7)$$

sendo a solução dessa equação dada por:

$$\mathbf{x}(t) = e^{(\mathbf{A} - \mathbf{B}\mathbf{K})t} \mathbf{x}(0). \quad (3.8)$$

Pode-se, portanto, projetar a matriz \mathbf{K} de modo que os autovalores de $(\mathbf{A} - \mathbf{B}\mathbf{K})$ sejam todos negativos, fazendo com que a resposta tenda de forma assintótica a zero. Pode-se escrever \mathbf{K} como:

$$\mathbf{K} = \begin{bmatrix} k_{11} & k_{12} & \dots & k_{1n} \\ \cdot & \cdot & \cdot & \cdot \\ k_{m1} & k_{m2} & \dots & k_{mn} \end{bmatrix}, \quad (3.9)$$

e encontrar os valores de \mathbf{K} através de:

$$\det(s\mathbf{I} - \mathbf{A} + \mathbf{BK}) = (s - \mu_1)(s - \mu_2) \dots (s - \mu_n), \quad (3.10)$$

onde $\mu_1, \mu_2, \dots, \mu_n$ são os polos desejados para o polinômio característico do sistema.

Virvalo, 2002, destaca que os resultados obtidos para o controlador por realimentação de estados PVA aplicado a um atuador hidráulico são melhores que aqueles obtidos para o PID devido ao fato do primeiro ser capaz de melhorar o amortecimento do sistema. Para que a dinâmica da válvula não influencie na alocação dos polos, esse autor utiliza uma válvula que é cerca de 5 vezes mais rápida que a frequência natural não amortecida do conjunto cilindro-carga utilizado pelo mesmo.

Em Pereira, 2006, propõe-se uma discussão sobre o desempenho do controlador PVA mediante a influência da dinâmica da Válvula. O autor utiliza uma válvula proporcional de cerca de 20 Hz de largura de banda, mais lenta que a frequência natural não amortecida do conjunto cilindro-carga utilizado pelo mesmo, de cerca de 65 Hz. O autor conclui que nessa condição o desempenho do controlador PVA é semelhante ao de um controlador proporcional.

Cunha, 2001, destaca que as incertezas paramétricas, as não linearidades e a dificuldade na obtenção do sinal de aceleração, dificultam a obtenção de resultados com a utilização de um controlador PVA em um atuador hidráulico.

Segundo Pereira, 2006, a estimação das parcelas de realimentação de velocidade e aceleração, normalmente realizada por derivação numérica, inserem ruído no sinal de controle, o qual é amplificado pelos ganhos das mesmas.

Apesar do controlador PVA apresentar desempenho, do ponto de vista teórico, superior ao PID, o alto amortecimento do sistema, no caso do atuador em análise nesta tese, descrito por meio das equações (3.2) e (3.3) favorece o controlador PID, diminuindo a vantagem do controlador PVA em relação ao acréscimo de amortecimento. O controlador PVA também apresenta limitação em relação à livre imposição de polos, imposta pela proximidade da frequência natural de 85 Hz da válvula (Apêndice A) em relação à frequência natural não amortecida do conjunto cilindro-carga, que, segundo a metodologia de cálculo apresentada em Furst, 2001, é de 75 Hz. Por esses motivos, o controlador PVA não é utilizado no presente trabalho.

3.1.4. Controlador PID + *feedforward*.

Em aplicações envolvendo atuadores hidráulicos, onde se requer melhores resultados em relação ao erro de posição do que aqueles oferecidos por meio da aplicação de controladores PID, costuma-se utilizar, com base em Nachtwey, 2006 e Kim, et al. 2012, o controlador PID acrescido de uma parcela *feedforward*. Essa estratégia de controle pode ser descrita por meio das equações:

$$u(t) = K_p e(t) + K_I \int_0^t e(t) dt + K_D \frac{de(t)}{dt} + \dot{y}_d F_f, \quad (3.11)$$

$$F_f = \begin{cases} K_{fp}, & \dot{y}_d \geq 0 \\ K_{fn}, & \dot{y}_d < 0 \end{cases}, \quad (3.12)$$

onde F_f é uma ganho aplicado, em malha aberta, à velocidade desejada \dot{y}_d somado diretamente com o sinal em malha fechada do controlador PID.

A parcela referente ao controlador PID é responsável pela estabilidade do sistema em malha fechada. O desempenho do sistema em regime permanente (regulação) será o mesmo do controlador PID [Pereira, 2006].

Se a dinâmica desejada para a velocidade do pistão é conhecida, o ajuste dos ganhos para o controlador PID+*feedforward* pode ser realizado de forma simples. De acordo com Nachtwey, 2006, e Pereira, 2006, o procedimento de ajuste segue os seguintes passos:

- 1) Ajusta-se os ganhos do controlador PID considerando $F_f=0$;
- 2) Ajusta-se, de forma experimental, com aumentos gradativos, o ganho F_f até um valor que proporcione resultado adequado para o erro de posição.

Os resultados de erro de posição do controlador PID+*feedforward* apresentados por Pereira, 2006, indicam uma grande melhora em relação aos resultados apresentados pelo controlador PID e equiparam-se aos resultados do controlador em cascata utilizado por esse autor. Em Kim et al., 2012, os resultados dos erros de posição ponto a ponto e de seguimento de trajetória do controlador PID+*feedforward* são comparados com um controlador não linear, proposto pelo autor, que utiliza um observador de estados. O esquema de controle é utilizado

em um atuador hidráulico com um pistão de haste dupla. Os resultados mostram que o controlador proposto pelo autor apresenta resultados de erro de posição de cerca de 0,5 mm contra 1mm de erro do controlador PID+*feedforward*, em uma trajetória senoidal de 15 mm de amplitude.

Uma análise de estabilidade desse controlador não foi encontrada na bibliografia pesquisada. O controlador PID aplicado em atuadores hidráulicos é localmente estável.

Os ganhos do controlador PID+*feedforward* foram ajustados segundo o procedimento descrito na presente seção. O resultado desse ajuste são os ganhos apresentados na Tabela 3.3:

Tabela 3.3- Valores dos ganhos calculados do controlador PID+*feedforward* (T = 30°C).

Ganho	K_P	K_I	K_D	K_{fp}	K_{fn}
Valor	420	2018	0.9	14	40

3.2. Estratégias de controle não linear

Nesta seção abordam-se os aspectos teóricos que dizem respeito às principais estratégias de controle não linear aplicadas ao controle de atuadores hidráulicos.

3.2.1. Linearização por realimentação

A linearização por realimentação tem por objetivo o cancelamento das não linearidades e a imposição de uma dinâmica linear desejada ao sistema [Slotine e Li, 1991; Isidori e Benedetto, 1996]. Essa técnica aplica-se a uma classe de sistemas não lineares que encontram-se na chamada forma companheira. Um sistema é dito como estando na forma companheira quando o mesmo pode ser representado na forma:

$$\dot{x}^{(n)} = f(x) + b(x)u. \quad (3.13)$$

onde u é uma entrada de controle escalar, x é uma saída escalar de interesse e $x = [x, \dot{x}, \ddot{x}, \dots, x^{(n-1)}]^T$ é o vetor de estados e $f(x)$ e $b(x)$ são funções limitadas não lineares dos estados. A lei de controle linearizante é descrita pela Equação (3.14).

$$u = \frac{1}{b}(v - f). \quad (3.14)$$

Para que essa lei seja aplicável, a parcela b não pode em momento algum assumir valor zero.

Aplicando-se (3.14) em (3.13), as não linearidades são canceladas e o sistema passa a ser descrito pela simples relação entrada-estado:

$$\dot{x}^{(n)} = v, \quad (3.15)$$

onde v é a dinâmica linear a ser imposta.

Para que a técnica seja bem-sucedida, é necessário que a Equação (3.14) aproxime os valores reais das funções não lineares, o que necessita de um conhecimento preciso do modelo não linear do sistema. Por isso, a linearização por realimentação é normalmente utilizada em conjunto com outras técnicas de controle que visam a lidar com as eventuais diferenças de modelagem e que façam que o sistema tenha um desempenho adequado, ou seja, confirmem robustez ao sistema em malha fechada.

3.2.2. Controle de modos deslizantes (*sliding mode control*)

Seja o sistema descrito pela Equação (3.13) e supondo-se que se objetiva que o mesmo siga uma trajetória de estados desejada $\mathbf{x}_d = [x_d, \dot{x}_d, \ddot{x}_d, \dots, x_d^{(n-1)}]^T$. A técnica dos modos deslizantes consiste em definir uma superfície $S(t)$ no espaço de estados. Dentro dessa superfície, garante-se que os estados do sistema seguirão \mathbf{x}_d . Para tanto, deve-se aplicar uma lei de controle que faça com que $s(\mathbf{x}, t) = 0$.

Uma possibilidade para a escolha da superfície é descrita pela Equação (3.16). Com $n=2$, por exemplo, tem-se que $s = \dot{\tilde{x}} + \lambda \tilde{x}$.

$$s(\mathbf{x}, t) = \left(\frac{d}{dt} + \lambda \right)^{n-1} \tilde{x}, \quad (3.16)$$

onde λ é uma constante estritamente positiva e $\tilde{x} = x - x_d$.

Para provar a estabilidade deve-se garantir que a lei de controle verifique a desigualdade [Slotine e Li, 1991]:

$$\frac{1}{2} \frac{d}{dt} s^2 \leq -\eta, \quad (3.17)$$

sendo η uma constante estritamente positiva. A Equação (3.17) é estabelecida a partir da aplicação do método direto de Lyapunov, o qual permite comprovar que os estados convergem para uma região limitada em malha fechada. Considerando o sistema da Equação (3.13), uma lei de controle que satisfaça (3.17), considerando a superfície da Equação (3.16), pode ser descrita pela Equação (3.18).

$$u = \hat{u} - k \operatorname{sgn}(s), \quad (3.18)$$

onde $\hat{u} = \frac{1}{\hat{b}}(-\hat{f} + \tilde{x}_d - \lambda \dot{\tilde{x}})$, onde \hat{f} e \hat{b} são aproximações das funções da Equação (3.13) contendo incertezas.

A constante k deve ser dimensionada de modo a garantir a condição descrita em (3.17), mantendo a trajetória de estados dentro da superfície descrita em (3.16), ou seja, fazendo $s = 0$.

O controle de modos deslizantes reduz o problema de controle à estabilização de um sistema de ordem $n - 1$ em s [Slotine e Li, 1991]. O método não necessita de um conhecimento preciso do modelo do sistema, porém o dimensionamento de k deve ser tal que não provoque uma atividade intensa de controle, causando um efeito oscilatório chamado *chattering*.

3.2.3. Controle baseado no *Backstepping*

O controle baseado no *Backstepping* consiste em uma metodologia passo a passo, baseada no método direto de Lyapunov, usada para obter uma lei de controle em malha fechada que garanta que o sistema seja globalmente assintoticamente estável. O sistema deve estar na forma adequada para aplicação da estratégia do *Backstepping* [Khalil, 2002; Krstic et al., 1995], ou seja, o sistema deve poder ser descrito como:

$$\dot{\eta} = f(\eta) + g(\eta)\xi, \quad (3.19)$$

$$\dot{\xi} = u, \quad (3.20)$$

onde $[\eta^T \ \xi^T]^T \in \mathfrak{R}^{n+1}$ é o vetor de estados, $u \in \mathfrak{R}$ é a entrada de controle e as funções $f: D \rightarrow \mathfrak{R}^n$ e $g: D \rightarrow \mathfrak{R}^n$ são suaves em um domínio $D \subset \mathfrak{R}^n$. Segundo Khalil, 2002, estando o sistema no formato das equações (3.19) e (3.20), o primeiro passo da metodologia é obter uma realimentação de estados que torne (3.19) assintoticamente convergente dada por:

$$\xi = \phi(\eta), \quad (3.21)$$

onde $\phi(0) = 0$.

Ainda, segundo Khalil, 2002, o segundo passo é obter uma função de Lyapunov $V(\eta)$ que satisfaça a Equação (3.22), onde $-W(\eta)$ é positiva definida.

$$\frac{\partial V}{\partial \eta} [f(\eta) + g(\eta)\phi(\eta)] \leq -W(\eta). \quad (3.22)$$

Com os resultados de (3.21) e (3.22), é mostrado em Khalil, 2002, considerando $V(\eta) + \frac{1}{2}[\xi - \phi(\eta)]^2$ como função candidata de Lyapunov, que se as condições iniciais são iguais a zero, a seguinte lei de controle garante que o sistema seja globalmente assintoticamente estável:

$$u = \frac{\partial \phi}{\partial \eta} [f(\eta) + g(\eta)\phi(\eta)] - \frac{\partial V}{\partial \eta} g(\eta) - k[\xi - \phi(\eta)], \quad (3.23)$$

onde k é uma constante estritamente positiva e $f(\eta)$ e $g(\eta)$ são funções conhecidas.

Supondo que o sistema encontre-se na forma:

$$\dot{\eta} = f(\eta) + g(\eta)\xi, \quad (3.24)$$

$$\dot{\xi} = f_a(\eta, \xi) + g_a(\eta, \xi)u, \quad (3.25)$$

onde f_a e g_a são funções conhecidas, pode-se aplicar a estratégia da linearização por realimentação através da lei de controle descrita pela Equação (3.26), ficando o sistema resultante no formato das equações (3.19) e (3.20), sendo possível a aplicação do

Backstepping, resultando em uma lei de controle global descrita pela Equação (3.27) que garante que o sistema seja globalmente assintoticamente estável mediante condições iniciais iguais a zero.

$$u = \frac{1}{g_a(\eta, \xi)}(u_a - f_a(\eta, \xi)), \quad (3.26)$$

$$u = \frac{1}{g_a(\eta, \xi)} \left(\frac{\partial \phi}{\partial \eta} [f(\eta) + g(\eta)\phi(\eta)] - \frac{\partial V}{\partial \eta} g(\eta) - k[\xi - \phi(\eta)] - f_a(\eta, \xi) \right). \quad (3.27)$$

Pode-se afirmar que a metodologia do *Backstepping* é, na verdade, uma estratégia em cascata, podendo-se dividir o problema de controle em vários subsistemas e aplicar uma lei de controle para um subsistema de forma que coloque o mesmo no formato das equações (3.19) e (3.20), de modo a aplicar o *Backstepping* no subsistema subsequente. Em Cunha, 2001, a estratégia em cascata que é descrita na Seção 4.1 é comparada com a metodologia do *Backstepping* para o controle de um atuador hidráulico, concluindo-se que as metodologias são semelhantes.

Todas as considerações até então foram feitas levando-se em conta que as funções que descrevem os modelos são conhecidas. Supondo-se que o sistema seja descrito pelas equações (3.28) e (3.29), onde $\delta_\eta(\eta, \xi)$ e $\delta_\xi(\eta, \xi)$ sejam incertezas paramétricas do modelo, em Khalil, 2002, é demonstrado que, desde que as incertezas sejam limitadas e k tenha um valor suficientemente elevado, a lei de controle da Equação (3.27) garante que o sistema seja globalmente assintoticamente estável mediante condições iniciais iguais a zero.

$$\dot{\eta} = f(\eta) + g(\eta)\xi + \delta_\eta(\eta, \xi), \quad (3.28)$$

$$\dot{\xi} = f_a(\eta, \xi) + g_a(\eta, \xi)u + \delta_\xi(\eta, \xi). \quad (3.29)$$

3.2.4. Controle Adaptativo por Modelo de Referência.

O controle adaptativo por modelo de referência (CAMR) é uma técnica de controle que se aplica a sistemas tanto lineares quanto não lineares. Para que a mesma seja utilizada, é

necessário um conhecimento da estrutura da planta, não necessitando, no entanto, o conhecimento preciso dos valores dos parâmetros da mesma. Baseado nesse conhecimento, é elaborado o modelo de referência, contendo a saída ideal ou desejada para a planta, que, no caso linear, é um polinômio de Hurwitz e, no caso não linear, um modelo linearizado da planta, com parâmetros estimados [Slotine e Li, 1991; Ioannou e Sun, 1996; Cunha, 2001]. Segundo a metodologia apresentada em Slotine e Li, 1991, e Cunha, 2001, aplica-se à planta uma lei de controle com um determinado número de parâmetros ajustáveis, que convergem para valores que levam a planta a uma resposta semelhante à do modelo de referência. O ajuste dos parâmetros é feito por uma lei de adaptação que deve garantir que a resposta do sistema seja estável e que os erros de trajetória tendam para zero, sem a necessidade dos parâmetros adaptados convergirem para os valores verdadeiros.

A Figura 3.3 ilustra a estratégia CAMR aplicada a uma planta a ser controlada.

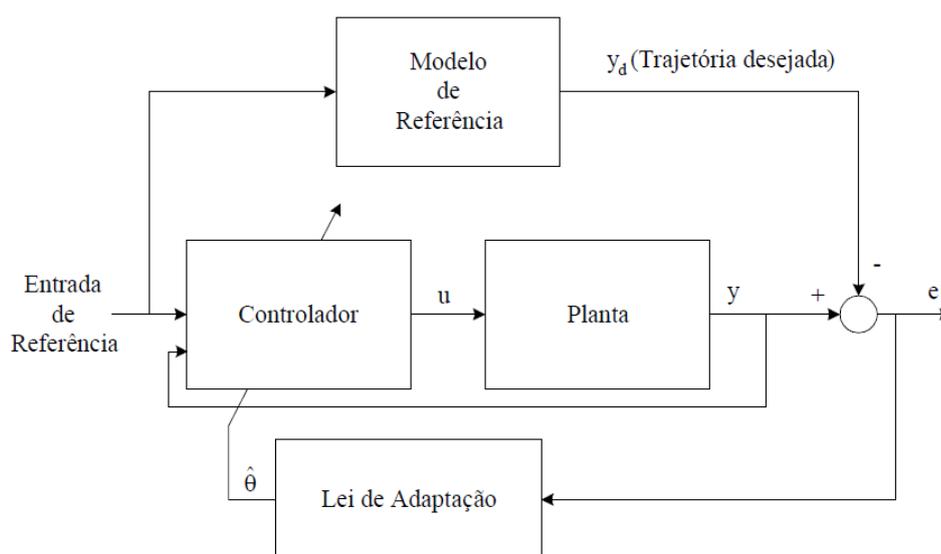


Figura 3.3- Controle Adaptativo por Modelo de Referência [Ioannou e Sun, 1996]

O projeto de um CAMR envolve normalmente três etapas [Slotine e Li, 1991]:

- Escolher uma lei de controle contendo parâmetros ajustáveis;
- Escolher uma lei de adaptação para ajustar esses parâmetros; e
- Analisar as propriedades de convergência do sistema de controle resultante.

Uma abordagem elaborada por Slotine e Li, 1991, e adotada em trabalhos como Cunha, 1997, Cunha, 2005, Cunha e Guenther, 2005 é a seguinte:

Considere dois sinais e e ϕ relacionados pela equação (3.30):

$$e(t) = H(p)[k\phi(t)^T \mathbf{v}(t)], \quad (3.30)$$

onde $e(t)$ é um sinal escalar de saída, $H(p)$ é uma função de transferência real estritamente positiva, k é uma constante desconhecida, mas com sinal conhecido, $\phi(t)$ é um vetor em função do tempo e $\mathbf{v}(t)$ é um vetor mensurável. Se o vetor ϕ varia de acordo com a equação (3.31) :

$$\dot{\phi}(t) = -\text{sgn}(k) \gamma e \mathbf{v}(t), \quad (3.31)$$

onde γ é uma constante positiva, então $\phi(t)$ e $e(t)$ são globalmente limitados. Se $\mathbf{v}(t)$ é limitado, então $e(t)$ tende a zero quando t tende ao infinito. A prova é mostrada em Slotine e Li, 1991. Essa idéia é utilizada no controlador adaptativo de Slotine e Li aplicado a Robôs manipuladores [Slotine e Li, 1988] que serve como base aos trabalhos citados.

O CAMR tem a vantagem de fornecer um erro menor do que a aplicação das técnicas de controle anteriores utilizando modelos com incertezas paramétricas, porém é importante ressaltar que a adaptação não acompanha variações bruscas na planta.

Uma desvantagem dessa metodologia, segundo Slotine e Li, 1991, é a necessidade de um sinal de excitação persistente na planta. Segundo o mesmo autor, a robustez do método está associada a prevenção de perturbações temporárias, que levem o gradiente à atribuir valores distantes da realidade aos parâmetros estimados. Por essa razão, normalmente utilizam-se funções de projeção que limitam os valores dos parâmetros estimados.

3.2.5. Controle utilizando Lógica *Fuzzy*.

Segundo Mendel, 1995, um sistema utilizando Lógica *Fuzzy* representa, em geral, um mapeamento não linear de um vetor de dados de entrada em uma saída escalar (podendo haver múltiplos mapeamentos de entrada/saída escalar independentes), constituindo-se, portanto, em uma ferramenta poderosa para a representação de funções não lineares. A Figura 3.4 ilustra um sistema de lógica *fuzzy* que é bastante utilizado [Mendel, 1995].

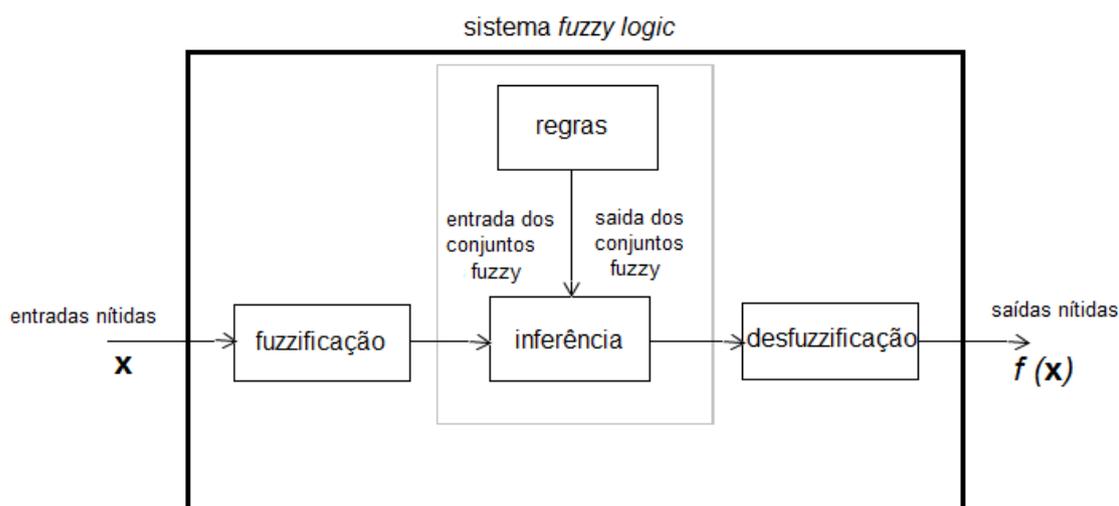


Figura 3.4 – Sistema de lógica *fuzzy* (adaptado de Mendel, 1995).

Um sistema *fuzzy* mapeia entradas nítidas (que respeitam a lógica tradicional de verdadeiro ou falso) em saídas nítidas e contém quatro componentes: regras, inferência, fuzziificação e desfuzziificação. As regras são uma coleção de instruções do tipo *IF-THEN*, podendo ser extraídas do conhecimento de especialistas ou de dados numéricos. A fuzziificação traduz em conjuntos *fuzzy* as entradas nítidas. Os conjuntos *fuzzy* são criados de acordo com as variáveis linguísticas contidas nas regras. A inferência produz diferentes conjuntos fuzzy, que são o resultado das relações pré-estabelecidas entre os conjuntos *fuzzy* resultantes da fuzziificação. Por fim, a desfuzziificação traduz em saídas nítidas os conjuntos *fuzzy* resultantes da inferência.

Em sistemas de controle, os sistemas de lógica *fuzzy* podem ser utilizados nas mais variadas estratégias de controle, como sintonizar controladores PID clássicos [Ghosh et al., 2015], representar funções não lineares, como a zona morta de um sistema hidráulico [Bessa et. al., 2010] ou aproximar as funções b e f da Equação (3.14), na estratégia de controle de linearização por realimentação [Cerman e Hušek, 2012]. Como base em Mendel, 1995, os mapeamentos *fuzzy* constituem saídas limitadas, sendo que os mesmos podem ser utilizados em estratégias de controle com leis de adaptação estáveis, baseadas no método direto de Lyapunov, como em Cerman e Hušek, 2012.

3.2.6. Controle utilizando Redes Neurais.

As redes neurais vêm sendo utilizadas frequentemente em sistemas de controle desde os anos de 1980 [Werbos, 1989]. A principal aplicação é no controle de plantas desconhecidas ou não lineares [Naredra, 1996]. Em Kutz, 2015, encontra-se uma descrição atualizada do funcionamento das principais aplicações de redes neurais em sistemas de controle.

Uma solução muito utilizada é o controlador adaptativo neural por modelo de referência [Naredra e Parthasarathy, 1990], cujo funcionamento é ilustrado por meio da Figura 3.5. OBS: Nessa figura mantêm-se a representação original do autor, que considera a linha de atrasos na realimentação da saída para a entrada da RN de controle intrínstica ao bloco que a representa.

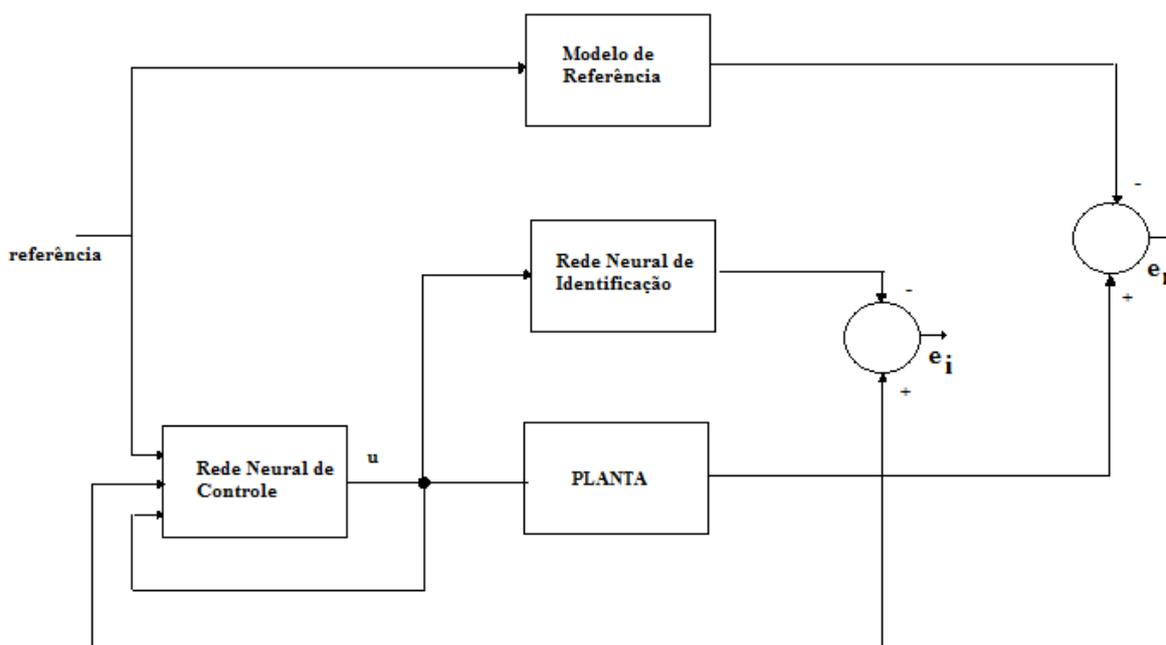


Figura 3.5 - Controle adaptativo por modelo de referência utilizando redes neurais (adaptado de Naredra e Parthasarathy, 1990).

A estratégia pode ser descrita da seguinte forma: um modelo de referência estável é utilizado, como no CAMR da Seção 3.2.4. Segundo Naredra, 1996, é necessário que o projetista tenha certa familiaridade com a planta para a elaboração de um modelo de referência adequado. Esse modelo é comparado com a saída da planta e um erro e_r é gerado, o qual é retropropagado pela rede neural de identificação do sistema, o que possibilita o cálculo

dos jacobianos do controlador em relação ao erro e_r em uma estratégia de controle adaptativo indireto. Os jacobianos são, então, utilizados pelo algoritmo de treinamento para redes recorrentes [Haykin, 2001] para atualização dos pesos do controlador neural. Em relação à rede neural de identificação, a mesma é previamente treinada *off-line*. Quando em operação em conjunto com a rede neural de controle, ela passa a ser treinada *on-line*, utilizando para atualização o erro de identificação e_i , obtido comparando a saída da planta com a saída da rede. Os jacobianos dessa rede são calculados em relação ao erro e_i e são utilizados pelo algoritmo de treinamento para atualização dos pesos da rede neural de identificação. Sendo $r(k)$ o setup de referência para o controlador, a lei de controle para o controlador neural é descrita na Equação (3.32):

$$u(k) = N_c(y(k), y(k-1), \dots, y(k-n+1), r(k), u(k-1), \dots, u(k-n+1)), \quad (3.32)$$

onde N_c é a RN que representa o controlador, $u(k)$ a entrada de controle no instante k , r a referência, $y(\cdot)$ as saídas medidas nos instantes k e $u(\cdot)$ as entradas medidas nos instantes k .

Utiliza-se o modelo NARMAX [Naredra, 1996] para as Redes Neurais de identificação e de controle. Não é necessário, portanto, que os estados estejam disponíveis para medição, bastando ter acesso à entrada e à saída da planta. A ordem do sistema também não necessita ser exatamente conhecida, sendo a mesma aproximada com um número finito de atrasos nas saídas. A planta necessita ser inversível para que o controlador neural possa convergir. Nesse sentido, alguns trabalhos como Sontag, 1979, Aeyels, 1981 e Levin e Naredra, 1996 mostram que a maioria dos sistemas com $2n+1$ amostras passadas, sendo n a ordem do sistema, é localmente observável e inversível.

Com base em Naredra, 1996, recomenda-se o uso dessa estratégia principalmente em plantas desconhecidas e com alguns estados indisponíveis para a medição. Ainda, segundo Hagan e Demuth, 1999, não é possível garantir a estabilidade do sistema em malha fechada utilizando esse controlador.

Uma variação dessa estratégia, que também é muito utilizada, é o controlador neural adaptativo baseado na linearização por realimentação [Breemen e Veelenturf, 1996]. Seja um sistema do tipo descrito por meio da Equação (3.11), seguindo a metodologia de identificação proposta por Naredra e Parthasarathy, 1990, é possível construir duas redes neurais, de modo

a utilizar as mesmas em uma lei de controle de linearização por realimentação, descrita por meio de:

$$u = \frac{1}{N_b} (v - N_f), \quad (3.33)$$

onde N_b e N_f são redes neurais que representam respectivamente as funções b e f da Equação (3.14) e v é a lei de controle aplicada ao sistema em malha fechada linearizado.

As redes neurais N_b e N_f são atualizadas *on-line*, de forma adaptativa, por um algoritmo de treinamento. Segundo Hagan e Demuth, 1999, existem várias versões desse controlador. Devido a maior simplicidade, ilustra-se, por meio da Figura 3.6, a versão apresentada em Hagan e Demuth, 1999.

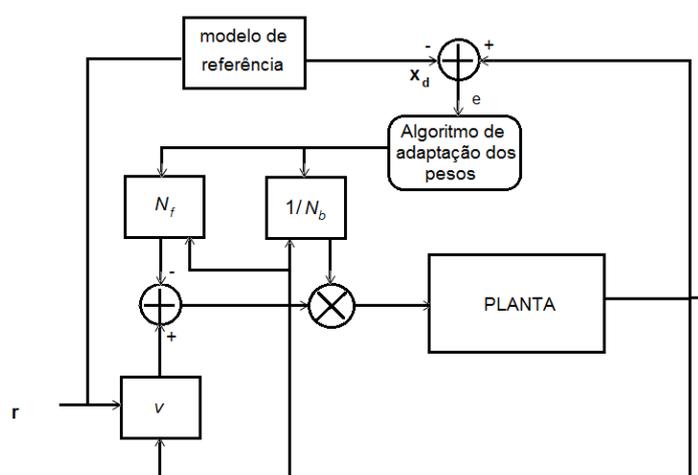


Figura 3.6 - Controlador neural adaptativo baseado na linearização por realimentação (adaptado de Hagan e Demuth, 1999).

Na versão desse controlador proposta por Naredra e Parthasarathy, 1990, encontrada em Fregene, 1999 e Pedro e Dahunsi, 2011, por exemplo, onde se utiliza a entrada e saída discretas da planta com linhas de atraso e não os estados do sistema, tem-se que os algoritmos de treinamento não são baseados no método direto de Lyapunov, não sendo possível, portanto, garantir a estabilidade em malha fechada.

A utilização de neurocontroladores com leis de controle e adaptação elaborados com base no método direto de Lyapunov, segundo Kutz, 2015, tem por base os trabalhos de Cybenko, 1989 e Park e Sandberg, 1991, que provam matematicamente que, em um conjunto

compacto do espaço de soluções, qualquer função contínua pode ser aproximada com um erro limitado por uma rede neural de apenas três camadas utilizando determinadas funções de ativação não lineares na camada oculta. Esse resultado é formalizado, ainda, por Hornik, 1991, através do teorema da aproximação universal para redes neurais. Em Kurková, 1992, prova-se matematicamente esse mesmo resultado para redes neurais de perceptrons de múltiplas camadas com duas camadas ocultas.

Em Sadegh, 1993, propõe-se um método direto de adaptação de uma rede neural de perceptrons cuja última camada é linear. O autor mostra que a parcela não linear da rede pode ser usada como uma base fixa, adaptando *on-line* somente os pesos da última camada. Uma estratégia semelhante é mostrada em Polycarpou e Iannou, 1992, Chen e Liu, 1994, Liang e Elmaraghy, 1994 e Hayakawa et. al., 2008, onde uma lei de controle semelhante aquela utilizada no CAMR é obtida com base no método direto de Lyapunov para adaptação dos pesos da camada linear de saída da rede neural. Visando a aumentar a precisão da aproximação *on-line*, de modo a evitar a necessidade de pré-ajustes *off-line* dos pesos, metodologias de adaptação direta para todos os pesos da rede neural de perceptrons, com base no método direto de Lyapunov, são utilizadas em Lewis et al., 1996, Naira et al., 2002 e Daachi et al., 2014.

As redes neurais RBF também são largamente utilizadas em estratégias de controle estáveis utilizando redes neurais. Apesar de apresentarem mapeamentos locais [Haykin, 2001], essas redes não necessitam de treinamento supervisionado para a parcela não linear da rede. Encontram-se vários trabalhos utilizando redes neurais adaptativas do tipo RBF, com leis de adaptação muito semelhantes às aquelas utilizadas no CAMR, tais como Sanner e Slotine, 1992, Polycarpou e Iannou, 1992, Martins, et al., 2008 e Yang, et al. 2013.

No presente trabalho, assim como em Sadati, et al., 2007 e Yang, et al., 2013, explora-se as potencialidades das redes neurais, como regressores não lineares de erro limitado, em conjunto com uma estratégia de controle baseada em modelo.

3.3. Discussões do Capítulo 3.

Neste capítulo apresentou-se, em linhas gerais, os aspectos teóricos referentes às principais estratégias de controle utilizadas em atuadores hidráulicos segundo a revisão bibliográfica apresentada no Capítulo 1.

Baseando-se nos resultados obtidos no processo de projeto e sintonia dos ganhos dos controladores descritos na Seção 3.1, aplicados à bancada experimental, constata-se que, conforme descrito em Cunha, 1997, e como constatado em trabalhos mais recentes como Yao e Ma, 2014, Ghazali et al., 2011a, Ghazali et al., 2011b e Guo et al., 2015 que os controladores lineares têm um desempenho limitado em relação ao erro de seguimento de trajetória quando aplicados a atuadores hidráulicos.

Com base nas estratégias apresentadas no presente capítulo e no desempenho limitado dos controladores clássicos, esta tese propõe, conforme discutido no Capítulo 1, modificações teóricas em relação ao estado da arte dos algoritmos apresentados. Tais modificações proporcionam resultados experimentais quanto ao erro de seguimento de trajetória em atuadores hidráulicos que superam aqueles apresentados por meio dos controladores clássicos e constituem alternativas interessantes em relação as estratégias existentes, conforme pode ser constatado no Capítulo 5.

4. ESTRATÉGIA EM CASCATA UTILIZANDO REDES NEURAIIS.

Conforme apresentado no Capítulo 1, a estratégia em cascata baseada no trabalho de Guenther e De Pieri., 1997, tem sido aplicada em vários trabalhos sobre o controle de atuadores hidráulicos. A abordagem da interpretação do atuador hidráulico como dois subsistemas conectados permite que esforços sejam feitos em separado visando à melhoria da resposta de cada subsistema e, conseqüentemente, da resposta do sistema realimentado como um todo. Nesse sentido, explora-se neste capítulo a proposta de uma representação por redes neurais do mapa inverso da função que usualmente é utilizada na linearização por realimentação do controlador do subsistema hidráulico. No Capítulo 2, foram apresentados os modelos que utilizam tanto uma função analítica para a vazão de controle da válvula, quanto uma função neural e também discutiram-se as diferenças entre elas. Neste capítulo é apresentado o estudo de uma função neural que substitui as expressões analíticas usadas no mapa inverso, que, essencialmente, constitui a inversa da função de vazão da válvula com relação às pressões nas câmaras e ao sinal de controle da servoválvula. Em relação ao subsistema mecânico, já foi discutida a utilização de redes neurais para a representação do atrito, apresentada, por exemplo, no trabalho de Machado, 2003. Esses resultados são aplicados na proposta de um controlador que reuna ambos benefícios advindos da aplicação das redes neurais estáticas nos controles dos dois subsistemas (hidráulico e mecânico). Assim, obtendo-se por meio do treinamento das redes neurais uma base estática robusta, propõe-se leis de adaptação estáveis, baseadas no método direto de Lyapunov, para que as redes neurais sejam capazes de acompanhar variações paramétricas que ocorram na planta do atuador hidráulico.

A título de organização, o presente capítulo é dividido da seguinte maneira: inicialmente, é feita uma revisão da estratégia em cascata e de seus fundamentos. Em seguida, são propostas modificações no controlador em cascata por meio da substituição da função analítica usualmente utilizada para a representação do mapa inverso e da função analítica de compensação do atrito por redes neurais do tipo perceptrons de múltiplas camadas alimentadas adiante (*feedforward*). Uma metodologia completa de projeto dessas redes, focada em atuadores hidráulicos, é apresentada. Posteriormente, é proposta uma estratégia de adaptação *on-line* dessas redes neurais, com base no método direto de Lyapunov. Apresenta-

se a prova de estabilidade do controlador em cascata neural fixo e adaptativo propostos. Por fim, apresenta-se as discussões finais do capítulo.

4.1. A Estratégia em Cascata

O termo “estratégia em cascata” é bastante genérico. Qualquer estratégia de controle que divida o equacionamento associado ao controle em subsistemas pode ser denominada como uma estratégia em cascata. Por exemplo, o controle baseado na linearização por realimentação da Seção 3.2 pode ser abordado como uma estratégia em cascata, pois é composto por uma lei de controle que lineariza o sistema e por outra que garante convergência assintótica do sistema linearizado. Como já comentado na Seção 3.2.3, o controle baseado no *Backstepping* também pode ser abordado como uma estratégia em cascata. É usual encontrar na literatura, em trabalhos como Heintze, 1997, Prabel e Aschemann, 2014, e Guo et al., 2015, a nomenclatura de “laço interno” e “laço externo” para designar uma estratégia em cascata (*inner loop/outer loop*). Esses termos referem-se ao subsistema mecânico como um laço externo (*outer loop*) (que recebe uma referência externa) e ao subsistema hidráulico como um laço interno (*inner loop*).

A estratégia em Cascata a qual se refere a presente seção foi proposta por Guenther e De Pieri, 1997, para o controle de atuadores hidráulicos, e, segundo Cunha, 1997, baseia-se na redução de ordem proposta por Utkin, 1987. O sistema completo pode ser interpretado como dois subsistemas interconectados: um subsistema hidráulico e um subsistema mecânico, conforme mostrado na Figura 4.1.

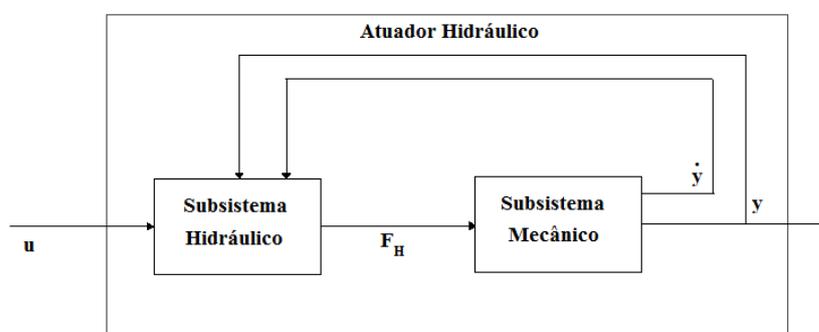


Figura 4.1 - Interpretação da estratégia em cascata

O objetivo de controle é realizar o seguimento de uma trajetória de posição desejada y_d utilizando uma lei de controle elaborada para o subsistema mecânico, de modo a minimizar o erro de seguimento de trajetória de posição. Essa lei de controle fornece o valor da força desejada F_{Hd} , que é seguida aplicando-se uma lei de controle sintetizada para o subsistema hidráulico, que minimize o erro de força e forneça o valor do sinal de controle u a ser diretamente aplicado na entrada da servoválvula.

A grande vantagem dessa estratégia é a possibilidade da elaboração de leis de controle adequadas às características de cada subsistema. A seguir são apresentadas as leis de controle propostas por Cunha, 1997, para ambos os subsistemas, baseadas em trabalhos anteriores de Guenther, 1993, e Guenther e De Pieri., 1997, considerando o modelo analítico obtido na Seção 2.1. As leis de controle estão no formato modificado por Pereira, 2006, que considera a força hidráulica e não a diferença de pressão como variável de estado.

4.1.1. Subsistema mecânico

A lei de controle escolhida para o subsistema mecânico descrito pela Equação (2.41) é a lei de Slotine e Li para manipuladores robóticos [Slotine e Li, 1991]. Para o sistema em estudo esta lei pode ser escrita como:

$$F_{Hd} = M_0 \ddot{y}_r - K_d z + F_A, \quad (4.1)$$

onde K_d é uma constante positiva, \ddot{y}_r é uma aceleração de referência (m/s^2), F_{Hd} é a força hidráulica desejada (N), F_A é a compensação da força de atrito (N) e z é uma medida de erro de velocidade no seguimento de trajetória (m/s). Esse último valor depende da velocidade de referência \dot{y}_r descrita em (4.2):

$$\dot{y}_r = \dot{y}_d - \lambda \tilde{y}, \quad \tilde{y} = y - y_d, \quad z = \dot{y} - \dot{y}_r = \dot{\tilde{y}} + \lambda \tilde{y}, \quad (4.2)$$

onde λ é uma constante positiva e \tilde{y} é o erro de posição (m).

Substituindo (4.1) em (2.41), considerando $F_L = 0$ e os parâmetros nominais iguais aos reais tem-se:

$$M\dot{z} + K_d z = \tilde{F}_H. \quad (4.3)$$

Aplicando-se a transformada de Laplace para condições iniciais diferentes de zero em z , tem-se:

$$M[sZ(s) - Z(0) + \frac{K_d}{M} Z(s)] = \tilde{F}_H(s). \quad (4.4)$$

Separando-se os termos:

$$M[Z(s)(s + \frac{K_d}{M}) - Z(0)] = \tilde{F}_H(s), \quad (4.5)$$

$$M[Z(s)(s + \frac{K_d}{M})] = \tilde{F}_H(s) + MZ(0). \quad (4.6)$$

Substituindo-se $Z(s)$ por $\tilde{Y}(s)(s + \lambda)$ obtém-se:

$$M[\tilde{Y}(s)(s + \lambda)(s + \frac{K_d}{M})] = \tilde{F}_H(s) + MZ(0), \quad (4.7)$$

então:

$$\tilde{Y}(s) = \frac{\tilde{F}_H(s)}{M(s + \lambda)(s + \frac{K_d}{M})} + \frac{Z(0)}{(s + \lambda)(s + \frac{K_d}{M})}. \quad (4.8)$$

4.1.2. Subsistema Hidráulico

Para o subsistema hidráulico, utiliza-se a lei de controle baseada na estratégia de linearização por realimentação descrita na Seção 3.2. Utilizando o subsistema hidráulico conforme descrito pela Equação (2.38), a lei de controle pode ser expressa por:

$$u = \frac{1}{b}(v - f), \quad (4.9)$$

onde: $f = -(A_1^2 f_1 + A_2^2 f_2)\dot{y}$ e $b = (A_1 f_1 K_{VA} g_1 + A_2 f_2 K_{VB} g_2)$.

Assim, a dinâmica linear a ser imposta é $v = \dot{F}_{Hd} - K_p \tilde{F}_H$, resultando, portanto:

$$u = \left[\dot{F}_{Hd} - K_p \tilde{F}_H + (A_1^2 f_1 + A_2^2 f_2) \dot{y} \right] \frac{1}{(A_1 f_1 K_{VA} g_1 + A_2 f_2 K_{VB} g_2)}, \quad (4.10)$$

onde \dot{F}_{Hd} é a derivada da força hidráulica desejada (N/s), K_p é uma constante positiva e \tilde{F}_H , o erro de força (N), K_{VA} e K_{VB} são as constantes da válvula por via utilizadas na lei de controle ($\text{m}^3/(\text{sV}\sqrt{\text{Pa}})$).

Substituindo-se (4.10) em (2.38) e considerando todos os parâmetros conhecidos tem-se:

$$\tilde{F}_H = F_H - F_{Hd}, \quad (4.11)$$

então:

$$\dot{F}_H = \dot{F}_{Hd} - K_p \tilde{F}_H, \quad (4.12)$$

e,

$$\dot{\tilde{F}}_H = -K_p \tilde{F}_H. \quad (4.13)$$

Aplicando a transformada de Laplace para uma condição inicial não nula tem-se:

$$s\tilde{F}_H(s) - \tilde{F}_H(0) = -K_p \tilde{F}_H(s), \quad (4.14)$$

então,

$$\tilde{F}_H(s) = \frac{\tilde{F}_H(0)}{s + K_p}. \quad (4.15)$$

Substituindo-se (4.15) em (4.8) e aplicando-se a transformada inversa de Laplace tem-se:

$$\tilde{y}(t) = \tilde{F}_H(0) \left(C_1 e^{-K_p t} + C_2 e^{-\lambda t} + C_3 e^{-\frac{K_d t}{M}} \right) + Z(0) \left(C_4 e^{-\lambda t} + C_5 e^{-\frac{K_d t}{M}} \right), \quad (4.16)$$

onde C_1 a C_5 são expressões oriundas da expansão em frações parciais da equação resultante.

De acordo com a Equação (4.16), quanto maiores os ganhos K_p , λ e K_d , mais rápido o erro de seguimento de trajetória convergirá para zero. Em Cunha, 2001, no entanto, é demonstrado que quando o controlador é projetado sem considerar a dinâmica da válvula e é aplicado a um modelo considerando a dinâmica da válvula, o aumento de K_p é limitado pela dinâmica da válvula. Os polos da válvula tendem a tornar o sistema subamortecido quanto maior o valor de K_p . Um valor elevado desse ganho faz surgir, portanto, oscilações estacionárias no pistão e também pode tornar o sistema instável, além de amplificar os ruídos do sinal de entrada resultante. Para superar tal limitação, Cunha, 2001, propõe um controlador projetado em um modelo que considera a dinâmica da válvula.

4.2. Compensação do atrito utilizando Redes Neurais

Para o controlador em cascata, a compensação de atrito pode ser feita diretamente através de F_A na Equação (4.1) (lei de controle do subsistema mecânico). A compensação originalmente proposta em Guenther e De Pieri, 1997, e, posteriormente, em Cunha, 1997, consiste da utilização de um termo linear, obtido multiplicando-se o coeficiente de atrito viscoso pela velocidade relativa entre o pistão e a camisa do cilindro, conforme descrito por intermédio de (4.17):

$$F_A = B\dot{y} . \quad (4.17)$$

Essa compensação desconsidera os efeitos do atrito de Coulomb, atrito estático e o efeito de Stribeck. Tal simplificação resulta em aumento do erro de seguimento de trajetória em velocidades baixas, conforme demonstrado por Machado, 2003. Em Cunha, 1997, é proposto um controlador adaptativo por modelo de referência, que ajusta o valor de B de modo a proporcionar o menor erro possível no seguimento da trajetória de posição desejada. Nos trabalhos de Perondi, 2002, em servoposicionadores pneumáticos e Valdiero, 2005, em um manipulador robótico hidráulico, é utilizado o modelo Luge [Canudas de Wit et al., 1995] em estratégias em cascata para compensação do atrito. Esse modelo é dinâmico e engloba as propriedades do atrito viscoso, de Coulomb, estático e o efeito Stribeck (Apêndice B). A utilização de redes neurais para a compensação do atrito no controlador em cascata foi aplicada com sucesso em um atuador hidráulico por Machado, 2003. Esse trabalho baseou-se no estudo de compensação de atrito em atuadores elétricos de Gervini e Gomes, 2001, que,

posteriormente, aplicou a mesma técnica em atuadores pneumáticos em Gervini, 2014. No presente trabalho, utilizou-se essa estratégia no controlador em cascata proposto.

Por conveniência, a Equação (2.41) é aqui reproduzida com $F_L=0$:

$$F_H = M\ddot{y} + F_A. \quad (4.18)$$

Assim, visando-se a reprodução das características da força de atrito por redes neurais, se assume as seguintes hipóteses para para a aplicação da Equação (2.41):

- (i) Como entradas da função de atrito podem, como em Gomes e Da Rosa 2003, ser consideradas a força aplicada F_H , e a velocidade de deslocamento, no caso \dot{y} . Como F_H relaciona-se com as pressões através de constantes, utiliza-se o valor das pressões medidas P_1 e P_2 ;
- (ii) A saída, no caso, a força de atrito, pode ser estimada pela Equação (4.19), obtendo-se \ddot{y} através de derivação numérica.

No presente trabalho, propõe-se a utilização de uma função de suavização que representa a força de atrito em velocidades muito baixas. Tal função tem por objetivo suavizar o chaveamento entre o atrito estático positivo e negativo, que ocorre devido à ação de controle quando a trajetória a ser controlada encontra-se em regulação ($\dot{y}_d = 0$), e é expressa por:

$$F_A = \begin{cases} F_H - M\ddot{y} & ; \dot{y} \geq |v_{\text{lim}}| \\ G_p \dot{y} & ; \dot{y} < |v_{\text{lim}}| \geq 0 \\ G_n \dot{y} & ; \dot{y} > -|v_{\text{lim}}| < 0 \\ F_H - M\ddot{y} & ; \dot{y} \leq -|v_{\text{lim}}| \end{cases}, \quad (4.19)$$

onde G_p e G_n são ganhos fixos e v_{lim} é a velocidade onde ocorre o chaveamento da função.

Com as entradas e saídas mensuráveis é possível, então, utilizar uma rede neural para representar a força de atrito, conforme a Equação (4.20).

$$F_A = \Theta(P_1, P_2, \dot{y}), \quad (4.20)$$

onde Θ é a rede neural que representa o atrito.

Assume-se, com base em Haykin, 2001, que a rede neural treinada por meio da Equação (4.19) é capaz de suavizar as descontinuidades decorrentes das transições entre a força de atrito medida e a função de suavização dessa equação. Para facilitar essa tarefa, os ganhos são definidos com base na força de atrito média em $|v_{lim}|$ e $-|v_{lim}|$, como segue:

$$G_p = \frac{F_A(|v_{lim}|)}{|v_{lim}|} \quad ; \quad G_n = \frac{F_A(-|v_{lim}|)}{-|v_{lim}|}. \quad (4.21)$$

No presente trabalho, a rede neural descrita por meio da Equação (4.20) é também modificada com o objetivo de incluir a temperatura do fluido hidráulico, que passa a ser utilizada na expressão representada por meio da Equação (4.22)

$$F_A = \Theta(P_1, P_2, \dot{y}, T), \quad (4.22)$$

onde T é a temperatura medida do fluido hidráulico (°C).

4.3. Mapa inverso da lei de controle do subsistema Hidráulico representado por Redes Neurais

No presente trabalho é proposta uma estrutura baseada em redes neurais para a representação da função de inversão de b (descrita na Equação (4.9)) e aplicada na lei de controle do subsistema hidráulico. A rede neural escolhida é do tipo perceptrons multicamadas alimentada adiante.

Assim, visando à reprodução da função do mapa inverso do subsistema hidráulico por meio de redes neurais estáticas, assumem-se as seguintes hipóteses em relação à Equação (4.10):

- (i) Todas as entradas e saídas da inversa da função b (mapa inverso) são mensuráveis;

(ii) Todos os parâmetros da função f possuem valores conhecidos;

Dessa forma, pode-se estabelecer uma lei de controle descrita por meio da Equação (4.23), sendo a inversa de b representada por uma rede neural $\Omega(y, \dot{y}, P_1, P_2)$:

$$u = \Omega(y, \dot{y}, P_1, P_2)(v - f), \quad (4.23)$$

onde $f = -(A_1^2 f_1 + A_2^2 f_2) \cdot \dot{y}$, $v = \dot{F}_{Hd} - K_p \tilde{F}_H$ e as entradas y , P_1 e P_2 são diretamente mensuráveis, enquanto que a velocidade \dot{y} pode ser obtida por derivação numérica e Ω é a rede neural que representa o mapa inverso (no caso, $1/b$). A saída da rede neural é obtida indiretamente por meio da Equação (4.24):

$$OUT(\Omega) = \frac{u}{\dot{F}_H + (A_1^2 f_1 + A_2^2 f_2) \cdot \dot{y}} \left(\frac{V}{N / s} \right). \quad (4.24)$$

Assim, a função b é uma relação estática não linear, cuja não linearidade se deve às funções de vazão de controle da válvula descritas nas equações (2.90) e (2.91). O comportamento dessas funções já foi discutido na Seção 2.5.2. Além disso, na Seção 2.6 foi mostrado que existem vantagens em utilizar as redes neurais para a representação das mesmas.

No presente trabalho, da mesma forma que a representação do atrito, a rede neural descrita por meio da Equação (4.23) é também modificada com o objetivo de incluir a temperatura do fluido hidráulico, que passa a ser utilizada na expressão representada por meio da Equação (4.25):

$$u = \Omega(y, \dot{y}, P_1, P_2, T)(v - f), \quad (4.25)$$

onde T é a temperatura medida do fluido hidráulico ($^{\circ}\text{C}$).

4.4. Metodologia de projeto das redes neurais.

A presente seção objetiva fornecer um detalhamento em relação à metodologia utilizada para a obtenção de redes neurais adequadas à utilização nos controladores propostos, descritos por meio das equações (4.1), (4.20), (4.22), (4.23) e (4.25).

4.4.1. Rede neural representando o mapa inverso.

O controlador proposto, expresso por meio da Equação (4.23), possui semelhanças com o controlador neural baseado na linearização por realimentação, descrito na Seção 3.2.6. Destaca-se, no entanto, que o controlador proposto no presente trabalho utiliza a função f , presente na Equação (4.23), representada por meio de uma função analítica. Além disso, os estados do sistema são mensuráveis (a estimação da velocidade e da aceleração é assumida como suficiente para os propósitos de controle). Como pode ser visto em trabalhos que utilizam o controlador neural baseado na linearização por realimentação, como Fregene, 1999, e Pedro e Dahunsi, 2011, esse controlador, em geral, considera a planta desconhecida e os estados não mensuráveis. A Figura 4.2 ilustra a metodologia de treinamento *off-line* utilizada no controlador neural baseado na linearização por realimentação utilizado em Fregene, 1999.

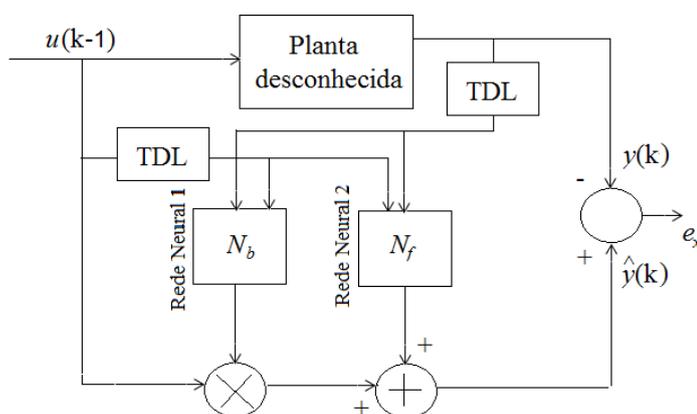


Figura 4.2 – Treinamento *off-line* do controlador neural baseado na linearização por realimentação (adaptado de Fregene, 1999).

Conforme a Figura 4.2, uma entrada $u(k-1)$ é aplicada na planta desconhecida. A saída e as entradas da planta são armazenadas com uma linha de atrasos temporais, de modo a formar o conjunto de treinamento:

$$C(k) = (y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)), \quad (4.26)$$

com $k = 1, \dots, n$, que é utilizado para a identificação das funções N_b (mapa inverso) e N_f , que são posteriormente utilizadas na lei de controle descrita por meio da Equação (3.33). As limitações desse controlador já foram discutidas no Capítulo 3.

Com base no treinamento *off-line* do controlador neural baseado na linearização por realimentação, propõe-se uma metodologia de treinamento *off-line* para o controlador proposto no presente trabalho, ilustrada por meio da Figura 4.3.

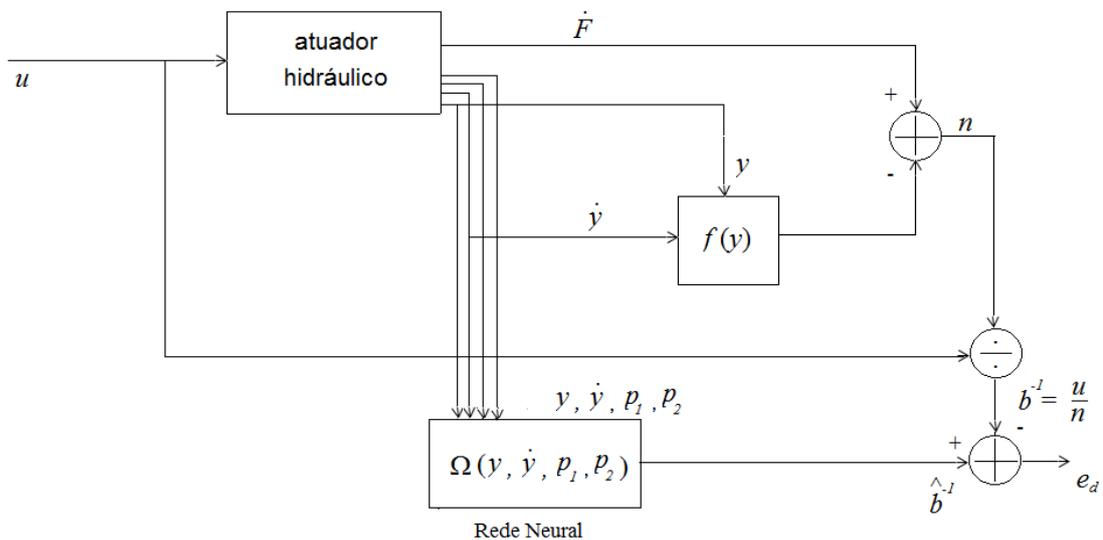


Figura 4.3 – Treinamento *off-line* da rede neural utilizada no mapa inverso.

Conforme a Figura 4.3, um conjunto de treinamento :

$$C(k) = (b^{-1}(k), P_A(k), P_B(k), y(k), \dot{y}(k)), \quad (4.27)$$

com $k = 1, \dots, n$, é utilizado para a obtenção dos pesos da rede neural utilizada na Equação (4.23), onde as pressões P_1 e P_2 são substituídas pelas pressões P_A e P_B , medidas na planta experimental. Este conjunto de treinamento incluirá também a temperatura do fluido hidráulico $T(k)$ quando a rede neural utilizada for aquela descrita por meio da Equação (4.25).

4.4.2. Rede neural representando o atrito.

A metodologia de treinamento *off-line* utilizada para a rede neural do atrito que, no caso do presente trabalho, é uma força de atrito modificada, é semelhante à metodologia proposta em Machado, 2003, e Gervini, 2014, sendo ilustrada por meio da Figura 4.4:

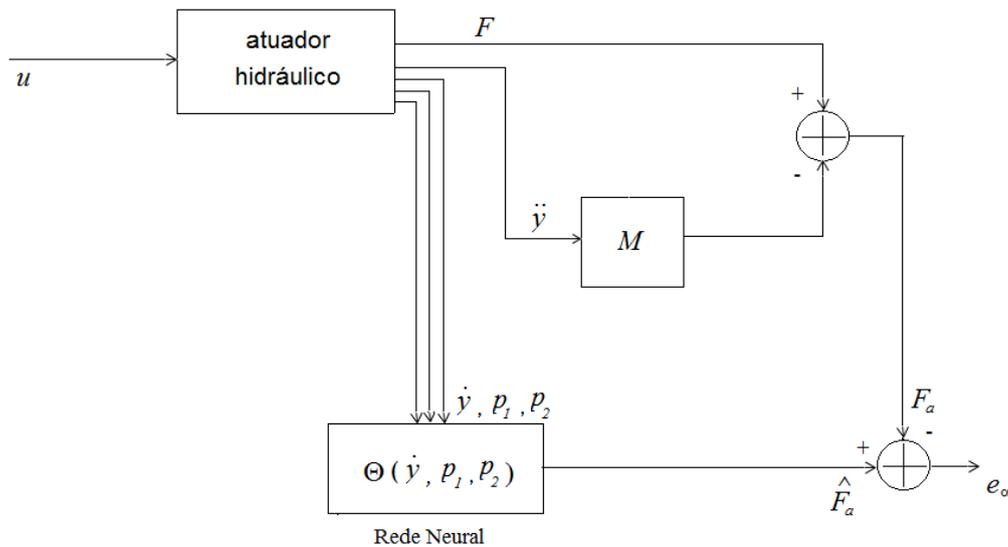


Figura 4.4 – Treinamento *off-line* da rede neural utilizada na obtenção da força de atrito modificada.

Conforme a Figura 4.4, um conjunto de treinamento :

$$C(k) = (F_a(k), P_A(k), P_B(k), \dot{y}(k)), \quad (4.28)$$

com $k = 1, \dots, n$, é utilizado para a obtenção dos pesos da rede neural utilizada na Equação (4.20), onde as pressões P_1 e P_2 são substituídas pelas pressões P_A e P_B , medidas na planta experimental, sendo obtida, portanto, uma força de atrito modificada, conforme discutido no Capítulo 2. Este conjunto de treinamento incluirá também a temperatura do fluido hidráulico $T(k)$ quando a rede neural utilizada for aquela descrita por meio da Equação (4.22).

4.4.3. Metodologia de projeto da entrada u utilizada no treinamento *off-line*.

Baseando-se nos trabalhos clássicos de Psaltis, et al., 1988 e Kawato, et al., 1988, pode-se afirmar que uma rede neural não adaptativa aplicada em um sistema de controle é

capaz de responder *on-line* segundo as informações *off-line* que lhes foram fornecidas. Segundo Kawato, et al. 1988 e Haykin, 2001, as redes neurais possuem grande capacidade de generalização. Um treinamento *off-line* suficientemente abrangente fornece, portanto, um desempenho robusto para a rede neural. Autores como Polycarpou e Ioannou, 1992 e Lewis, et al.,1996, porém, destacam a dificuldade da realização do treinamento *off-line* de redes neurais aplicadas a sistemas de controle devido às metodologias *ad hoc* normalmente utilizadas. Segundo Smithson, et al. 2016, até o presente momento, as metodologias de treinamento *off-line* aplicadas a redes neurais permanecem, em grande parte, baseadas na experiência do projetista. São encontrados vários trabalhos em sistemas de controle utilizando redes RBF, que não necessitam de um treinamento supervisionado para a sua base não linear (vide Apêndice D e Capítulo 3), ou metodologias que inicializam os pesos com zero e ajustam os mesmos *on-line* [Lewis, et al.,1996, Daachi, et al., 2014]. O treinamento *off-line* em sistemas de controle, em geral, conforme trabalhos como Fregene, 1999, Pedro e Dahunsi, 2011, Rong, et al., 2014, utiliza uma entrada u bastante simples, cuja metodologia de obtenção tem como objetivo apenas fornecer um conjunto de pesos que possa ser utilizado em redes neurais que serão ajustadas *on-line* de modo que os mesmos não instabilizem o sistema em malha fechada no início do processo de adaptação.

No presente trabalho, propõe-se uma metodologia de projeto para a entrada u utilizada no treinamento *off-line*. Esta metodologia tem como foco entradas suaves e continuamente diferenciáveis, adequadas à utilização do controlador em cascata. O objetivo é obter um conjunto de treinamento suficientemente abrangente, de modo que uma base robusta seja construída para as redes neurais utilizadas.

Uma forma simples de determinação de entradas u adequadas pode ser obtida com base na metodologia de projeto de controladores lineares para o seguimento de posição de atuadores hidráulicos descrita em Furst, 2001. De acordo com essa metodologia, define-se uma tarefa base, que norteia o projeto, onde o controlador linear é projetado com base em uma função de transferência linearizada do sistema no ponto de maior vazão (onde ocorre a maior abertura da válvula) nessa tarefa.

No presente trabalho, o ponto de maior abertura da válvula ocorre no ponto de maior velocidade do pistão. Tendo como base essa informação:

- Define-se uma trajetória padrão (média) de execução;
- Define-se o ponto de maior velocidade nessa trajetória;
- Define-se uma amplitude de excursão do pistão que abranja todos os pontos de posição desejados do mesmo;
- Definem-se alguns pontos de velocidade máxima arbitrados nas cercanias do ponto de velocidade máxima da tarefa padrão;
- Definem-se funções de trajetória de posição senoidais construídas de acordo com as informações anteriores, de modo a atingirem as amplitudes e velocidades máximas desejadas;
- Aplica-se essas funções em um controlador proporcional na planta em malha fechada, que irá fazer com que o pistão siga as mesmas e gere as entradas u do treinamento;
- Geram-se essas entradas nas temperaturas de 20 °C, 25 °C, 30 °C, 35 °C, 40 °C e 45 °C, para o treinamento da rede neural ao longo da variação da temperatura do fluido hidráulico.

A Tabela 4.1 resume as informações da geração dos conjuntos de treinamento *off-line* das redes neurais. Os ensaios são realizados com um tempo de amostragem de 1 ms. Depois de gerado o conjunto, o mesmo é reduzido para um número de amostras menor, com o objetivo de facilitar o treinamento. O ganho proporcional utilizado foi de $K_P = 250$.

Tabela 4.1- Conjuntos de treinamento das redes neurais.

ensaio	trajetória de posição (m)	tempo (s)	tempo total (s)	amostras	temperaturas (°C)
1	$0,08sen(t)$	6,28	65,358	2000	20
	$0,08sen(0,875t)$	7,17			
	$0,08sen(0,625t)$	10,048			
	$0,08sen(0,375t)$	16,74			
	$0,08sen(0,25t)$	25,12			
2	$0,08sen(t)$	6,28	65,358	2000	25
	$0,08sen(0,875t)$	7,17			
	$0,08sen(0,625t)$	10,048			
	$0,08sen(0,375t)$	16,74			
	$0,08sen(0,25t)$	25,12			
3	$0,08sen(t)$	6,28	65,358	2000	30
	$0,08sen(0,875t)$	7,17			
	$0,08sen(0,625t)$	10,048			
	$0,08sen(0,375t)$	16,74			
	$0,08sen(0,25t)$	25,12			
4	$0,08sen(t)$	6,28	65,358	2000	35
	$0,08sen(0,875t)$	7,17			
	$0,08sen(0,625t)$	10,048			
	$0,08sen(0,375t)$	16,74			
	$0,08sen(0,25t)$	25,12			
5	$0,08sen(t)$	6,28	65,358	2000	40
	$0,08sen(0,875t)$	7,17			
	$0,08sen(0,625t)$	10,048			
	$0,08sen(0,375t)$	16,74			
	$0,08sen(0,25t)$	25,12			
6	$0,08sen(t)$	6,28	65,358	2000	45
	$0,08sen(0,875t)$	7,17			
	$0,08sen(0,625t)$	10,048			
	$0,08sen(0,375t)$	16,74			
	$0,08sen(0,25t)$	25,12			

4.4.4. Definição das arquiteturas e treinamento das redes neurais.

A maioria dos trabalhos em sistemas de controle, como Polycarpou e Ioannou 1992, Daachi et al., 2001, Daachi et al., 2014, não detalha a metodologia de escolha da arquitetura da rede neural utilizada. De acordo com os trabalhos pesquisados, procura-se utilizar em aplicações de controle redes neurais de três camadas, com poucos neurônios na camada escondida e com a camada de saída linear. Segundo Hornik, 1991, esse tipo reduzido de rede

neural é teoricamente capaz de aproximar, com erro arbitrário, qualquer função contínua em um espaço compacto das soluções da mesma. O trabalho de Tamura e Tateishi, 1997, porém, prova matematicamente que redes de quatro camadas possuem uma maior capacidade de aprendizado que redes de três camadas.

O presente trabalho propõe arbitram-se três arquiteturas básicas de rede, duas arquiteturas de três camadas e uma de quatro camadas. A escolha parte de uma rede típica de três camadas com 10 camadas escondidas, utilizada, por exemplo, em Lewis, et al., 1996, e propõe-se outras duas arquiteturas para experimentação. O critério de escolha da arquitetura da rede neural é o de melhor resultado observado em relação ao conjunto de validação.

O algoritmo de treinamento utilizado no presente trabalho é o algoritmo *Quickprop*, um algoritmo do tipo Quase-Newton que é mais rápido que o *Backpropagation* [Borges, 1999]. Esse algoritmo é descrito em detalhes no apêndice D, juntamente como os procedimentos heurísticos utilizados no treinamento.

A metodologia de validação e teste utilizada no presente trabalho é a metodologia de validação cruzada, que pode ser encontrada em detalhes em Haykin, 2001, segundo a qual:

- São estabelecidos três conjuntos descorrelacionados entre si: os conjuntos de treinamento, validação e teste;
- Observa-se a evolução do erro de treinamento do conjunto de treinamento e, concomitantemente, o resultado de erro obtido com os pesos fornecidos por esse treinamento aplicados à mesma rede neural tendo como entrada o conjunto de validação. O número máximo de interações (épocas) do treinamento é determinado quando o erro do conjunto de validação não mais evolui ou quando esse chega a um erro mínimo, o que previne o sobre-treinamento;
- A rede é treinada com esse número de interações máximo e submetida ao conjunto de teste, para validação final do treinamento.

Para o conjunto de teste utiliza-se a trajetória padrão, descrita por meio da Equação (3.1), retirando-se, porém, os instantes de tempo onde o pistão permanece completamente

parado (regulação). O conjunto de validação utiliza funções senoidais. A Tabela 4.2 resume o conjunto de validação e a Tabela 4.3 os conjuntos de teste.

Tabela 4.2- Conjuntos de validação das redes neurais.

trajetória de posição (m)	tempo (s)	tempo total (s)	amostras	temperatura (°C)
$0,08\text{sen}(0,93t)$	6,75	14,5	1200	30
$0,08\text{sen}(0,81t)$	7,75			

Tabela 4.3- Conjuntos de teste das redes neurais.

ensaio	trajetória de posição	tempo (s)	amostras	temperaturas (°C)
1	Equação (3.1)	8	1200	20
2	Equação (3.1)	8	1200	30
3	Equação (3.1)	8	1200	40

Para a definição da arquitetura das redes neurais, utiliza-se somente o processo de validação aplicado aos conjuntos obtidos com o fluido a uma temperatura $T = 30$ °C. A informação da temperatura não é utilizada no treinamento e validação, nesse caso.

Devido às características dinâmicas do atuador hidráulico, discutidas no Capítulo 2, propõe-se, no presente trabalho, dividir a rede neural descrita por meio das equações (4.23) e (4.25) em duas redes neurais, uma atribuída à velocidade positiva do pistão e outra atribuída à velocidade negativa. A cada uma dessas redes neurais é verificada a arquitetura que fornece melhor resultado de aproximação do mapa inverso.

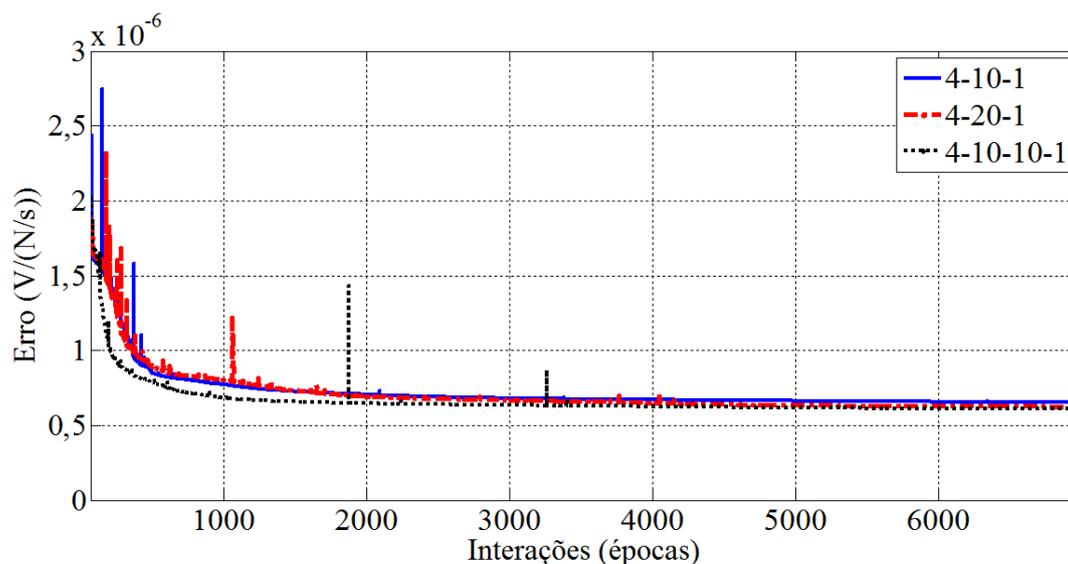
O critério de avaliação de erro utilizado no presente trabalho é o da raiz do erro quadrático médio, descrito por meio da Equação (4.29).

$$RMSE = \sqrt{\frac{1}{P} \sum_{n=1}^P (y_p - y_t)^2}, \quad (4.29)$$

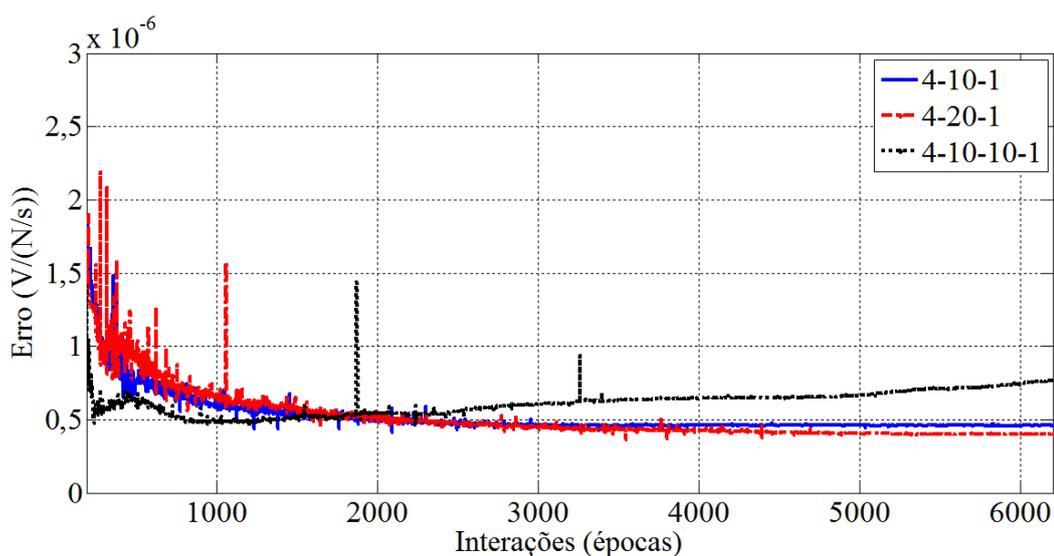
onde P é o número total de elementos do conjunto, y_t é a saída objetivo e y_p é a saída do conjunto de representação.

A Figura 4.5 (b) ilustra que os resultados do conjunto de validação determinam uma melhor aproximação para uma arquitetura 4-20-1, com a raiz do erro quadrático médio de $4,5 \cdot 10^{-7}$ V/(N/s), quando se considera o conjunto completo do mapa inverso. Ao considerar-se uma divisão desse conjunto, obtém-se um erro quadrático médio de $1,4 \cdot 10^{-7}$ V/(N/s), com uma

arquitetura 4-10-10-1, para velocidades positivas e $4,46 \cdot 10^{-7} \text{ V}/(\text{N/s})$, com uma arquitetura 4-10-1, para velocidades negativas, com os resultados sendo ilustrados por meio da Figura 4.7(b) e por meio da Figura 4.6(b). Observa-se por meio das figuras 4.5, 4.6 e 4.7 que os resultados de validação nem sempre acompanham os resultados de treinamento, evidenciando a necessidade dos conjuntos de validação, que determinam a melhor arquitetura e a quantidade ideal de interações necessárias durante o treinamento [Haykin, 2001].

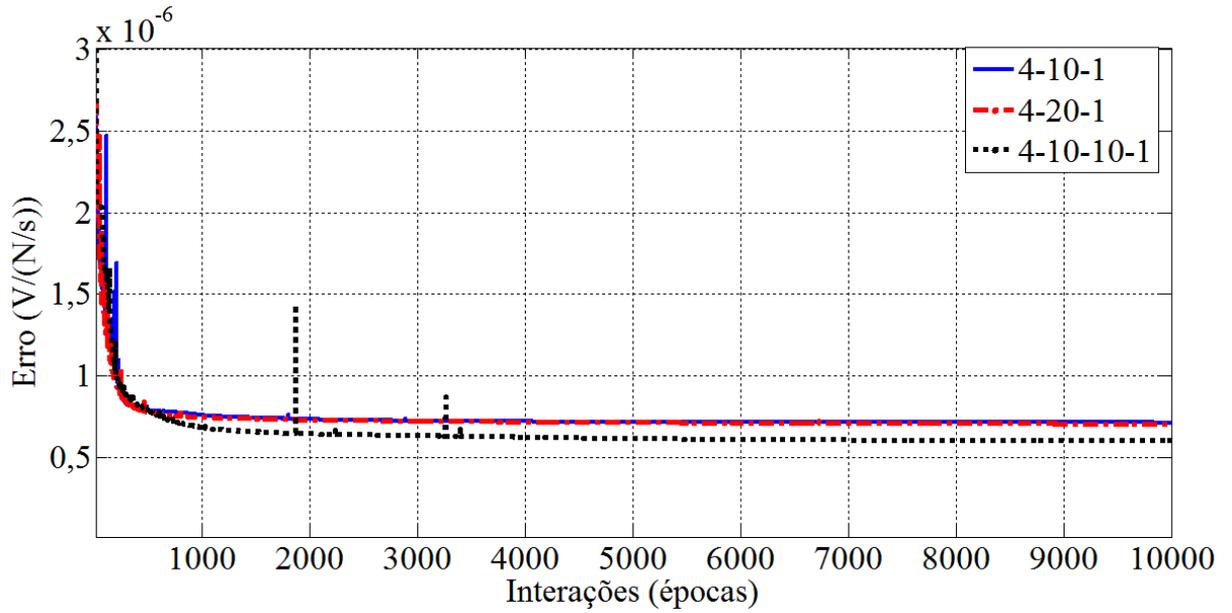


(a) Erro de treinamento.

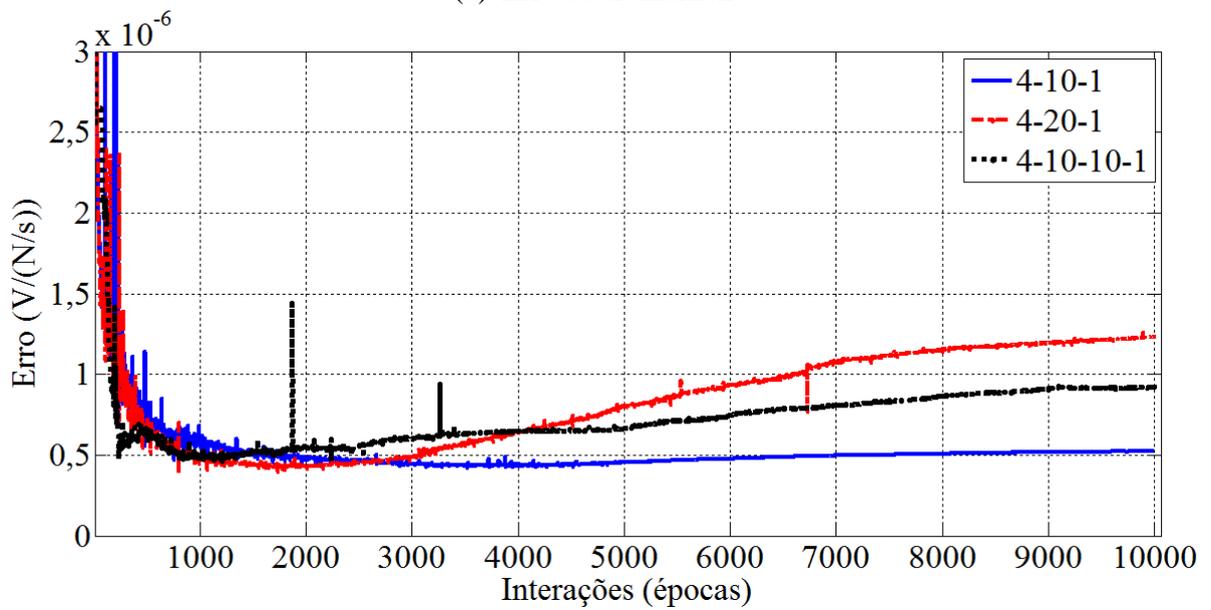


(b) Erro de validação.

Figura 4.5 – Conjunto total do mapa inverso – treinamento e validação.

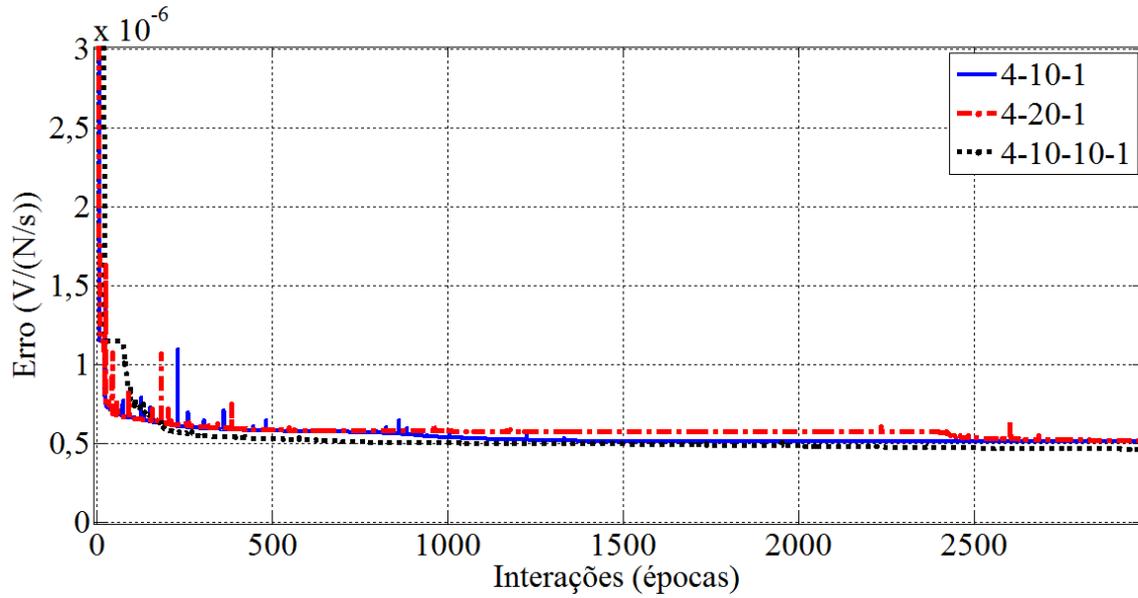


(a) Erro de treinamento.

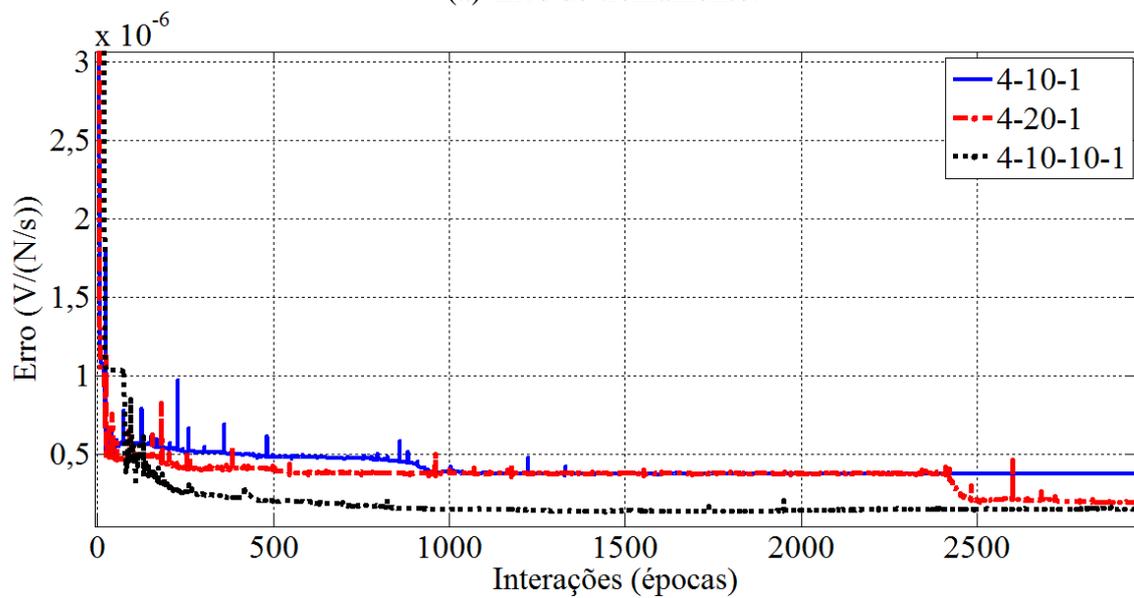


(b) Erro de validação.

Figura 4.6 – Conjunto negativo do mapa inverso – treinamento e validação.



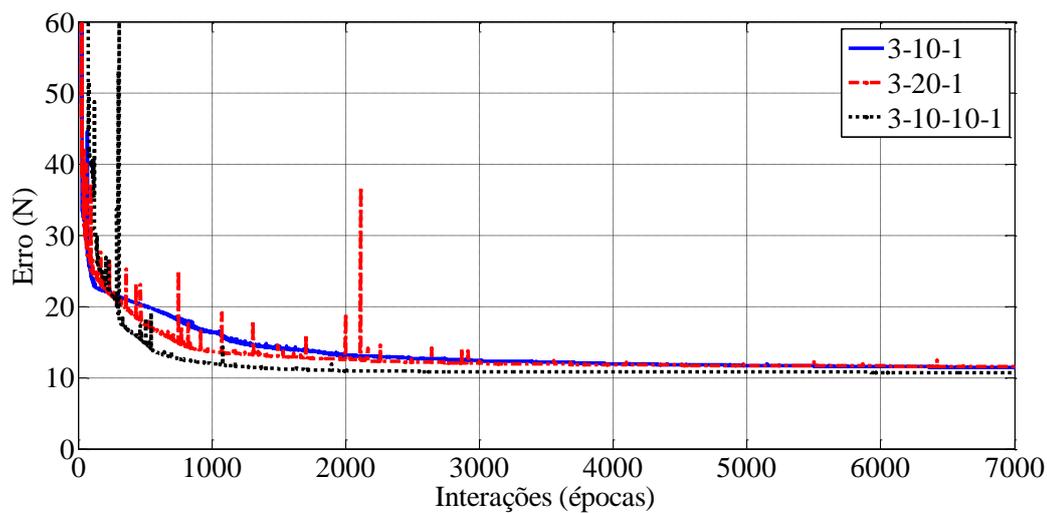
(a) Erro de treinamento.



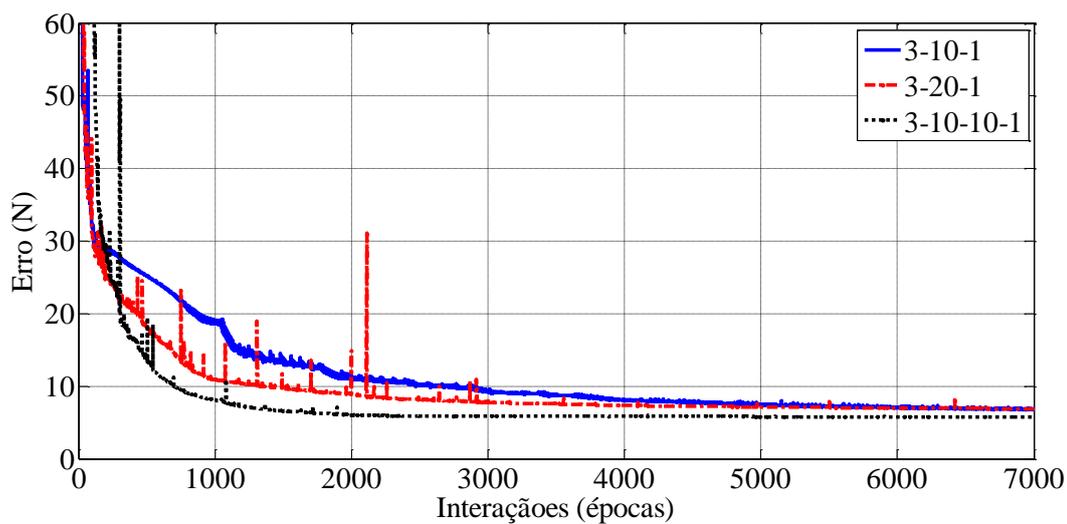
(b) Erro de validação.

Figura 4.7 – Conjunto positivo do mapa inverso – treinamento e validação.

A Figura 4.8 ilustra o processo de treinamento e validação em relação à força de atrito modificada. Por meio destes resultados, determina-se uma arquitetura 3-10-10-1 para a rede neural a ser utilizada para a representação da força de atrito modificada.



(a) Erro de treinamento.



(b) Erro de validação.

Figura 4.8 – Conjunto atrito modificado – treinamento e validação.

A rede multicamadas alimentada adiante utilizada para a representação do mapa inverso é descrita matematicamente por meio da Equação (4.30).

$$\Omega(y, \dot{y}, P_A, P_B) = \begin{cases} \Psi_{3P} \left(\mathbf{W}_{3P}^T \left[\left(\Psi_{2P} \left(\mathbf{W}_{2P}^T \left[\left(\Psi_{1P} \left(\mathbf{W}_{1P}^T \mathbf{h}_0 \right) \right]^T \right) \right) \right]^T \right) \right]^T \right) & \dot{y} \geq 0 \\ \Psi_{2N} \left(\mathbf{W}_{2N}^T \left[\left(\Psi_{1N} \left(\mathbf{W}_{1N}^T \mathbf{h}_0 \right) \right)^T \right]^T \right) & \dot{y} < 0 \end{cases}, \quad (4.30)$$

onde $\mathbf{W}_{3P} \in \mathfrak{R}^{1 \times 1}$ e $\mathbf{W}_{2N} \in \mathfrak{R}^{1 \times 1}$ são os vetores dos pesos de saída da rede, $\mathbf{W}_{1P} \in \mathfrak{R}^{5 \times 10}$, $\mathbf{W}_{1N} \in \mathfrak{R}^{5 \times 10}$ são matrizes dos pesos de entrada. A rede neural positiva, como possui 2 camadas ocultas, tem uma matriz de pesos $\mathbf{W}_{2P} \in \mathfrak{R}^{11 \times 10}$. O vetor das entradas da rede, que é acrescido de uma entrada unitária para operação dos bias, que, nesse caso, estão incorporados aos pesos da rede, é $\mathbf{h}_0 = [y \quad \dot{y} \quad P_A \quad P_B \quad 1]^T$. Assim como na entrada, o vetor resultante de cada camada da rede deve ser acrescido de uma entrada unitária, para operar o *bias* da camada seguinte (vide Apêndice D). Por simplificação, essas informações são omitidas nas representações seguintes, marcando as funções modificadas com um asterisco. As funções não lineares Ψ representam a função logística sigmoideal. A Tabela 4.4 resume o treinamento e validação dessa rede.

Tabela 4.4- Treinamento e validação para as arquiteturas escolhidas (T=30°C).

rede neural	condição	arquitetura	épocas	erro (RMSE)	
				treinamento	validação
$\Omega(y, \dot{y}, P_A, P_B)$	$\dot{y} \geq 0$	4-10-10-1	2000	$4,85 \cdot 10^{-7}$ V/(N/s)	$1,4 \cdot 10^{-7}$ V/(N/s)
	$\dot{y} < 0$	4-10-1	3500	$7,2 \cdot 10^{-7}$ V/(N/s)	$4,46 \cdot 10^{-7}$ V/(N/s)
$\Theta(P_A, P_B, \dot{y})$	-	3-10-10-1	3000	10,84 N	5,84 N

A rede multicamadas alimentada adiante utilizada para a representação do mapa inverso, quando considerada a temperatura do fluido hidráulico, é descrita matematicamente por meio da Equação (4.31):

$$\Omega(y, \dot{y}, P_A, P_B, T) = \begin{cases} \Psi_{3P_T} \left(\mathbf{W}_{3P}^T \Psi_{2P_T}^* \left(\mathbf{W}_{2P_T}^T \Psi_{1P_T}^* \left(\mathbf{W}_{1P_T}^T \mathbf{h}_{0_T}^* \right) \right) \right) & \dot{y} \geq 0 \\ \Psi_{2N_T} \left(\mathbf{W}_{2N_T}^T \Psi_{1N_T}^* \left(\mathbf{W}_{1N_T}^T \mathbf{h}_{0_T}^* \right) \right) & \dot{y} < 0 \end{cases}, \quad (4.31)$$

onde $\mathbf{W}_{3P_T} \in \mathfrak{R}^{11 \times 1}$ e $\mathbf{W}_{2N_T} \in \mathfrak{R}^{11 \times 1}$ são os vetores dos pesos de saída da rede, $\mathbf{W}_{1P_T} \in \mathfrak{R}^{6 \times 11}$, $\mathbf{W}_{1N_T} \in \mathfrak{R}^{6 \times 11}$ são matrizes dos pesos de entrada. A rede neural positiva, como possui 2 camadas ocultas, tem uma matriz de pesos $\mathbf{W}_{2P_T} \in \mathfrak{R}^{11 \times 10}$. O vetor das entradas da rede é $\mathbf{h}_0^* = [y \ \dot{y} \ P_A \ P_B \ T]^T$. As funções não lineares Ψ representam a função logística sigmoidal. A Tabela 4.5 resume o treinamento da rede neural (utilizando a mesma arquitetura de (4.30) e todos os ensaios da Tabela 4.1).

Tabela 4.5- Treinamento para as arquiteturas escolhidas considerando a temperatura do fluido hidráulico.

				erro (RMSE)
rede neural	condição	arquitetura	épocas	treinamento
$\Omega(y, \dot{y}, P_A, P_B, T)$	$\dot{y} \geq 0$	5-10-10-1	2000	$7,55 \cdot 10^{-7}$ V/(N/s)
	$\dot{y} < 0$	5-10-1	3500	$12,2 \cdot 10^{-7}$ V/(N/s)
$\Theta(P_A, P_B, \dot{y}, T)$	-	4-10-10-1	3000	15,6 N

Conforme descrito no Apêndice D, os limites utilizados na normalização das entradas e na reconstrução da saída das redes neurais que representam o mapa inverso são descritos por meio da Tabela 4.6.

Tabela 4.6 - Parâmetros de normalização para as entradas e saída das redes neurais que representam o mapa inverso.

<i>Parâmetro</i>	<i>Valor máximo</i>	<i>Valor mínimo</i>
y	0,1 m	-0,1 m
\dot{y}	0,15 m/s	-0,1 m/s
P_A	2,5 MPa	0,01 MPa
P_B	5,0 MPa	0,01 MPa
T	70 °C	10 °C
$Out(V/(N/s))$	$4,0 \cdot 10^{-5}$	0

A rede multicamadas alimentada adiante utilizada para a representação da força de atrito modificada é descrita matematicamente por meio da Equação (4.32):

$$\Theta(\dot{y}, P_A, P_B) = \mathbf{W}_3^T \Psi_2^* (\mathbf{W}_2^T \Psi_1^* (\mathbf{W}_1^T \mathbf{x}_0^*)), \quad (4.32)$$

onde $\mathbf{W}_3 \in \mathfrak{R}^{1 \times 1}$ é o vetor fixo dos pesos de saída da rede. Neste caso, utiliza-se uma camada de saída linear. A matriz $\mathbf{W}_1 \in \mathfrak{R}^{4 \times 10}$ é utilizada para os pesos de entrada. A rede neural possui 2 camadas ocultas e tem uma matriz de pesos $\mathbf{W}_2 \in \mathfrak{R}^{11 \times 10}$. O vetor das entradas da rede é $\mathbf{x}_0^* = [\dot{y} \ P_A \ P_B]^T$. As funções não lineares Ψ representam a função logística sigmoidal. A Tabela 4.4 resume o treinamento e validação dessa rede.

A rede multicamadas alimentada adiante utilizada para a representação da força de atrito modificada, quando considerada a temperatura do fluido hidráulico, é descrita matematicamente por meio da Equação (4.33):

$$\Theta(\dot{y}, P_A, P_B, T) = \mathbf{W}_{3_r}^T \Psi_{2_r}^* (\mathbf{W}_{2_r}^T \Psi_{1_r}^* (\mathbf{W}_{1_r}^T \mathbf{x}_{0_r}^*)), \quad (4.33)$$

onde $\mathbf{W}_{3_r} \in \mathfrak{R}^{1 \times 1}$ é o vetor fixo dos pesos da saída da rede, que é linear. A matriz $\mathbf{W}_{1_r} \in \mathfrak{R}^{5 \times 10}$ é utilizada para os pesos de entrada. A rede neural possui 2 camadas ocultas e tem uma matriz de pesos $\mathbf{W}_{2_r} \in \mathfrak{R}^{11 \times 10}$. O vetor das entradas da rede é $\mathbf{x}_{0_r}^* = [\dot{y} \ P_A \ P_B \ T]^T$. As funções não lineares Ψ representam a função logística sigmoidal. A Tabela 4.5 resume o treinamento dessa rede.

Conforme descrito no Apêndice D, os limites utilizados na normalização das entradas das redes neurais que representam o atrito modificado são descritos por meio da Tabela 4.7.

Tabela 4.7 - Parâmetros de normalização para as entradas e saída das redes neurais que representam o atrito modificado.

<i>Parâmetro</i>	<i>Valor máximo</i>	<i>Valor mínimo</i>
\dot{y}	0,2 m/s	-0,2 m/s
P_A	2,5 MPa	0,01 MPa
P_B	5,0 MPa	0,01 MPa
T	70 °C	10 °C

As figuras 4.9, 4.10 e 4.11 ilustram os resultados de teste das redes neurais descritas por meio das equações (4.30) e (4.31), que são resumidos por meio da Tabela 4.8. Esses resultados mostram um desempenho superior de ambas as redes neurais em relação à representação do conjunto de teste quando comparado com o resultado da representação deste mesmo conjunto fornecido pela função analítica do mapa inverso, descrita por meio da Equação (4.10). A melhor representação de ambas as redes neurais é obtida quando considerada a temperatura do fluido hidráulico, por meio da rede neural da Equação (4.31), com exceção dos ensaios realizados com $T = 30\text{ °C}$, mesma temperatura do ensaio utilizado para treinamento da rede neural da Equação (4.30).

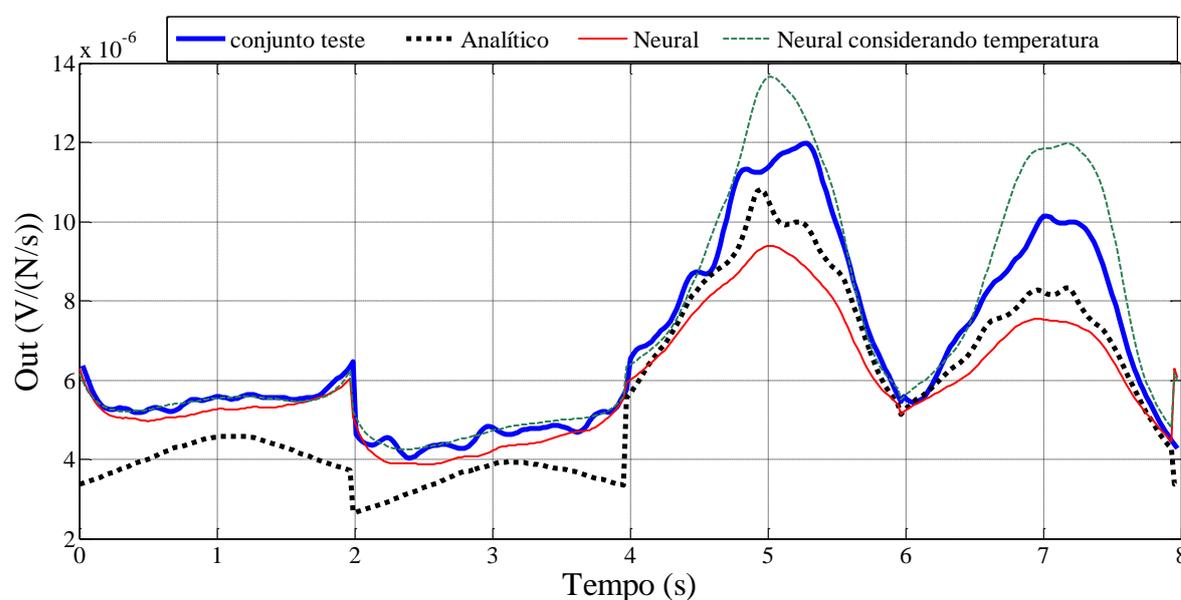


Figura 4.9 – Conjunto de teste do mapa inverso ($T=20\text{ °C}$).

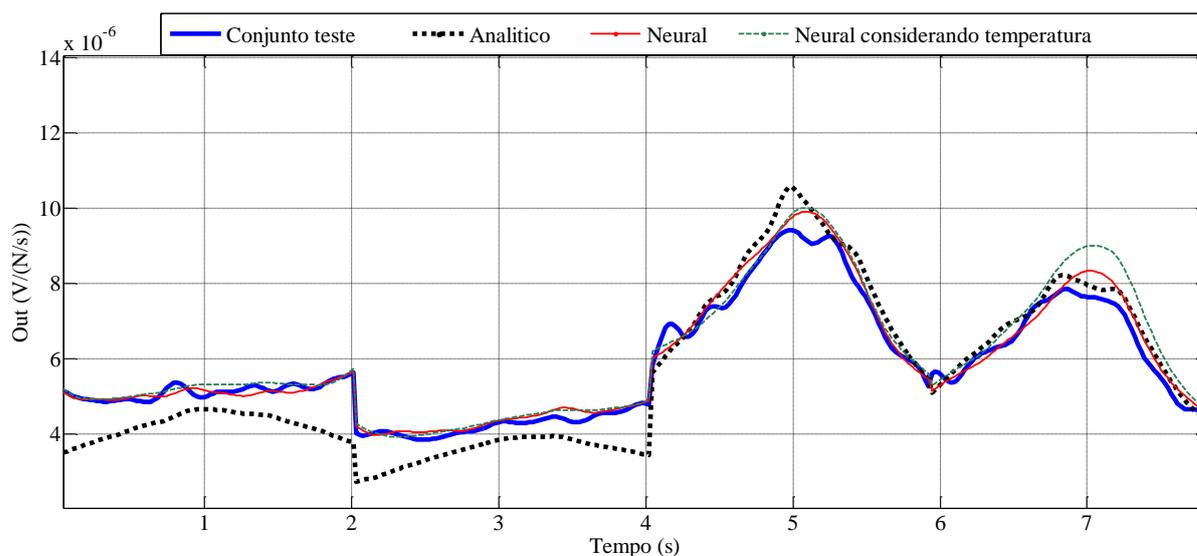


Figura 4.10 – Conjunto de teste do mapa inverso ($T=30^{\circ}\text{C}$).

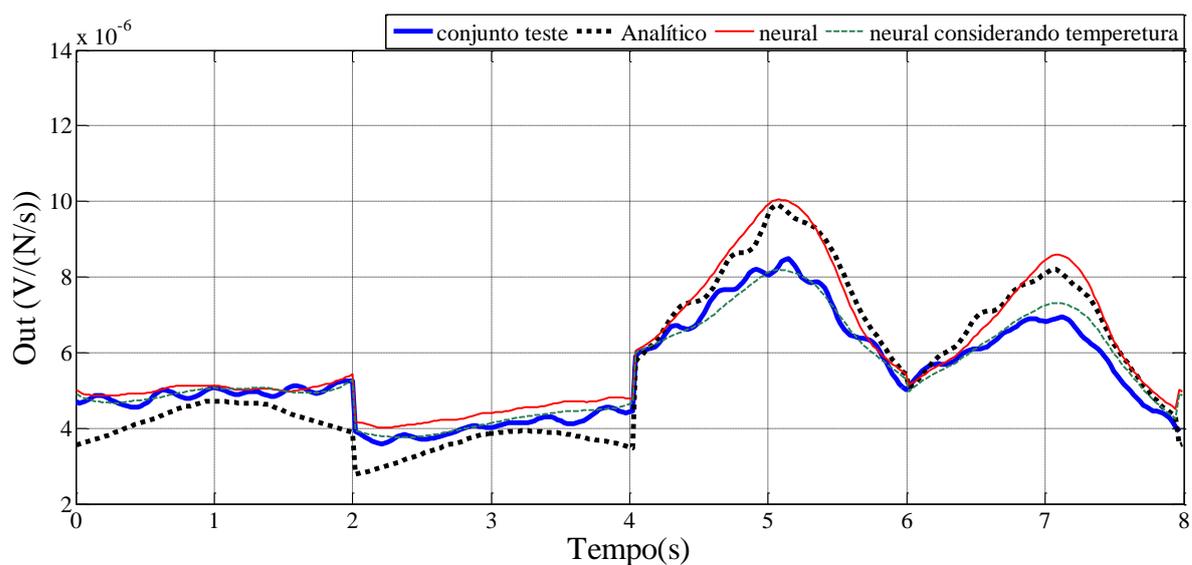


Figura 4.11 – Conjunto de teste do mapa inverso ($T=40^{\circ}\text{C}$).

A Figura 4.12 ilustra os resultados de teste das redes neurais que aproximam a força de atrito modificada, descritas por meio das equações (4.32) e (4.33), que são resumidos por meio da Tabela 4.9. Os resultados de aproximação do conjunto de teste da rede neural que considera a temperatura do fluido apresentam um erro quadrático médio menor.

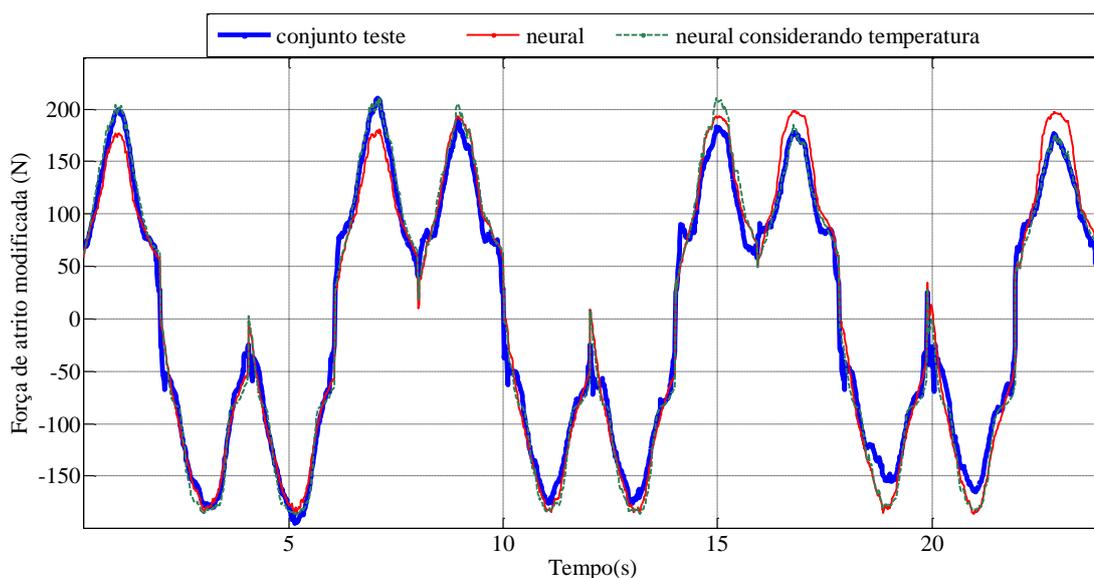


Figura 4.12 – Conjunto de teste do atrito modificado ($T=20^{\circ}\text{C}$; 30°C ; 40°C).

Tabela 4.8- Erros (RMSE) em relação ao conjunto de teste: mapa inverso.

Temperatura ($^{\circ}\text{C}$)	erro $\times 10^{-7}$ (V/(N/s))		
	analítico	Neural (30°C)	Neural considerando a temperatura
20	12,5	12	8
30	7,17	2,7	4,31
40	7,55	7,18	2,19

Tabela 4.9- Erros (RMSE) em relação ao conjunto de teste: atrito modificado (20°C ; 30°C ; 40°C).

	erro (N)
Neural (30°C)	17
Neural considerando a temperatura	15,24

Como validação final das redes neurais, testa-se se a saída das mesmas é limitada em relação a entradas que extrapolem os limites daquelas utilizadas no treinamento. Para a realização do teste, aplica-se 10.000 vetores de entradas, cujos valores de cada componente desse vetor são distribuídos aleatoriamente, em uma distribuição de probabilidade retangular. A Tabela 4.10 resume os limites das distribuições de probabilidade aplicadas. A Tabela 4.11

resume os valores aproximados que limitam a região de treinamento. O teste é realizado utilizando as redes neurais definidas por meio das equações (4.31) e (4.33), que incluem a temperatura do fluido hidráulico.

Tabela 4.10- Limites utilizados nas distribuições de probabilidade que extrapolam a região de treinamento das redes neurais.

	limite superior	limite inferior
y (m)	0,1	-0,1
\dot{y} (m/s)	1	-1
P_A (MPa)	10	0
P_B (MPa)	10	0
T (°C)	100	0

Tabela 4.11- Limites utilizados nas distribuições de probabilidade que delimitam aproximadamente a região de treinamento das redes neurais.

	limite superior	limite inferior
y (m)	0,1	-0,1
\dot{y} (m/s)	0,15	-0,1
P_A (MPa)	2,5	0
P_B (MPa)	5	0
T (°C)	50	20

As figuras 4.13 e 4.14 ilustram o resultado da aplicação das entradas aleatórias na rede neural que representa o mapa inverso e considera a temperatura do fluido hidráulico. Pode-se concluir, por meio da análise das referidas figuras, que a saída permanece limitada, mesmo aplicando-se entradas muito maiores que aquelas utilizadas no processo de treinamento. Esse limite ocorre na vizinhança da região de treinamento. Pode-se perceber também que a saída dessa rede neural é estritamente positiva. Valores elevados nas entradas levam a saída da rede neural a valores próximos a um limite de $3,5 \cdot 10^{-5}$ V/(N/s). Percebe-se por meio da análise das figuras 4.13 e 4.14 que a saída da rede neural é, para a maioria das entradas aplicadas, menor que $10 \cdot 10^{-6}$ V/(N/s).

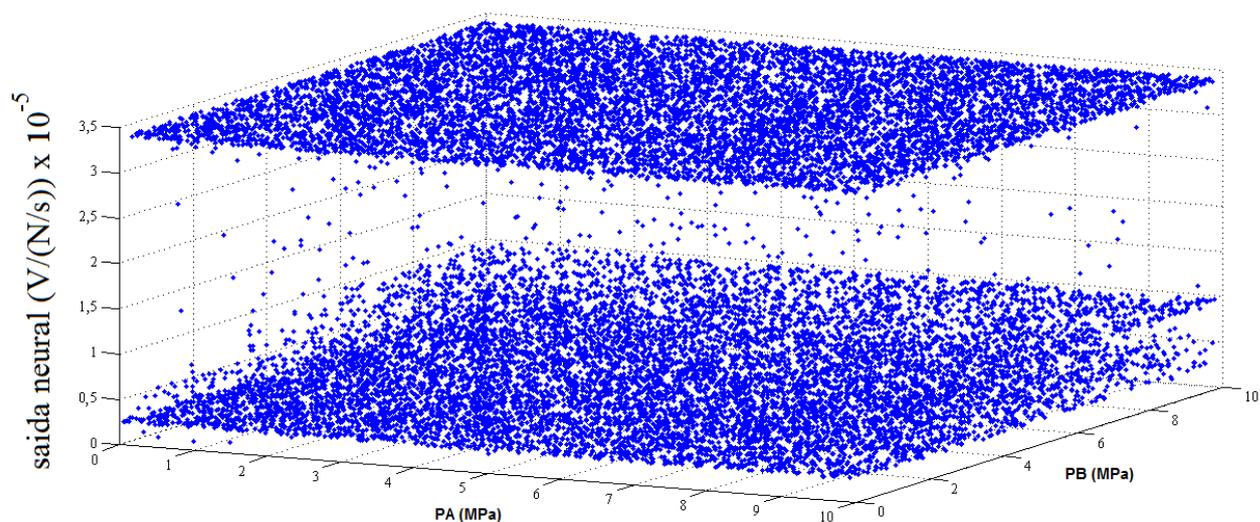


Figura 4.13 – Aplicação de entradas aleatórias na rede neural que representa o mapa inverso com entradas extrapolando a região de treinamento.

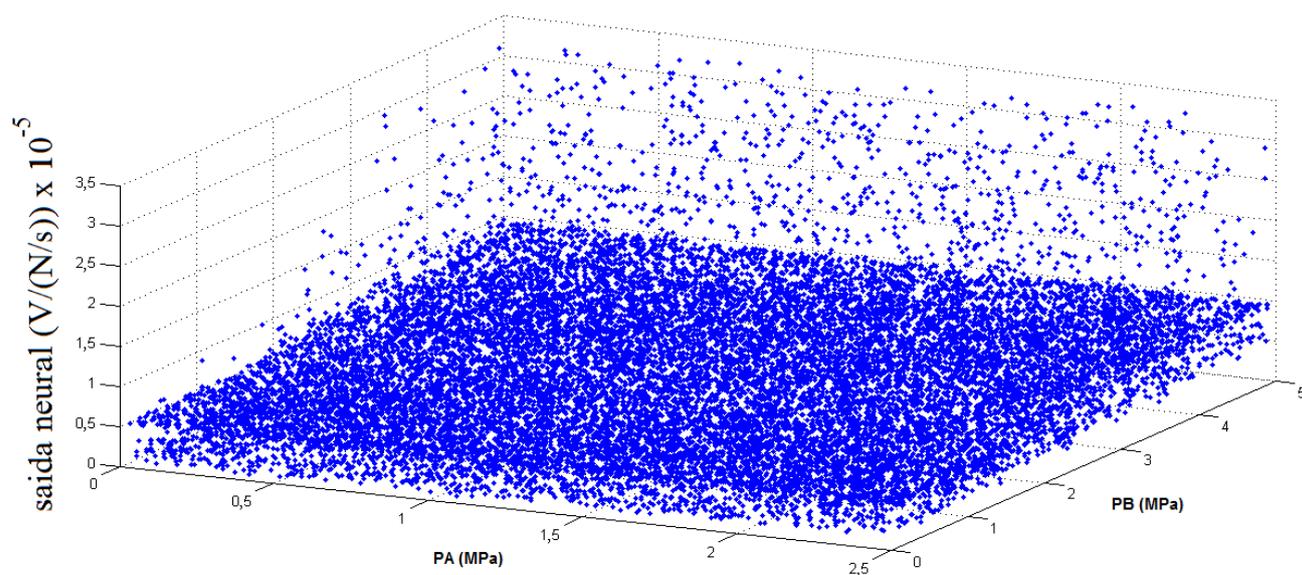


Figura 4.14 – Aplicação de entradas aleatórias na rede neural que representa o mapa inverso: região de treinamento.

As figuras 4.15 e 4.16 ilustram o resultado da aplicação das entradas aleatórias na rede neural que representa a força de atrito modificada e considera a temperatura do fluido hidráulico. Pode-se concluir, a exemplo da rede neural do mapa inverso, que a saída permanece limitada, mesmo aplicando-se entradas muito maiores que aquelas utilizadas no

processo de treinamento. Esse limite também ocorre na vizinhança da região de treinamento para as figuras 4.15 e 4.16. Valores elevados nas entradas levam a saída da rede neural a valores próximos a um limite de 400 N e -300 N. Percebe-se por meio da análise dessas figuras que, para a maioria das entradas, a saída da rede neural tende a valores semelhantes aos da curva experimental apresentada na Figura 2.8.

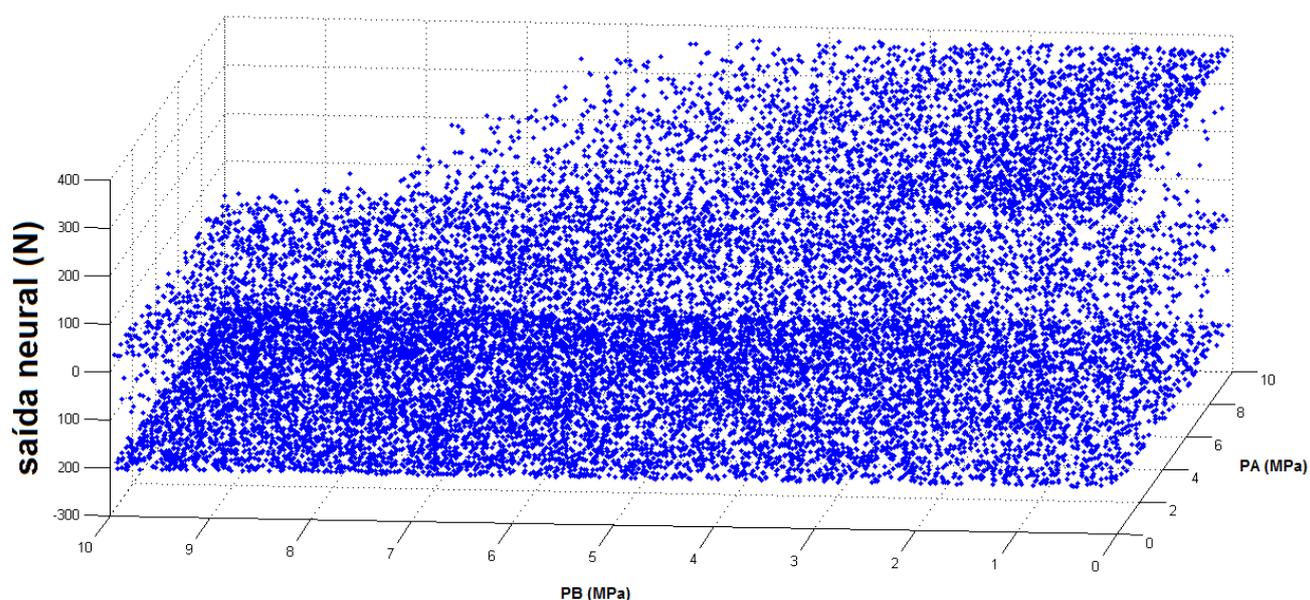


Figura 4.15 – Aplicação de entradas aleatórias na rede neural que representa a força de atrito modificada com entradas extrapolando a região de treinamento.

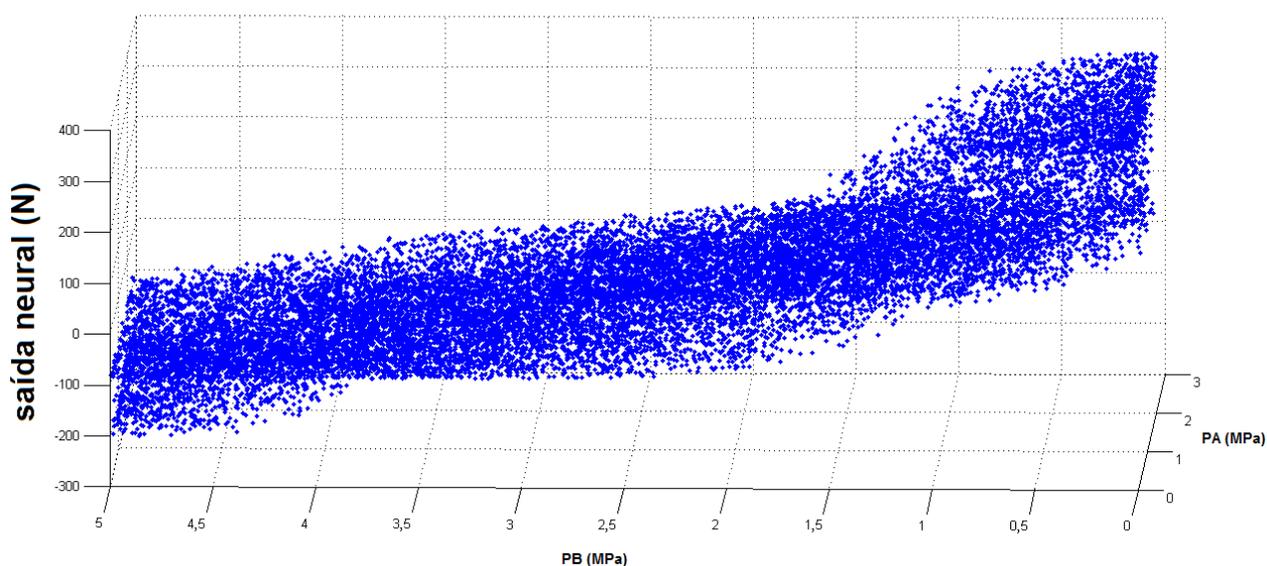


Figura 4.16 – Aplicação de entradas aleatórias na rede neural que representa a força de atrito modificada: região de treinamento.

4.5. Estratégias de adaptação *on-line* para as redes neurais propostas.

De acordo com Liang e ElMaraghy, 1994, as redes neurais multicamadas utilizando perceptrons fornecem boa interpolação local (região de treinamento), mas podem não fornecer uma resposta satisfatória em outras regiões. A utilização de um treinamento suficientemente abrangente, como em Prokhorov, 2008, pode ser a solução. Porém, conforme previamente discutido na Seção 3.2.6, existem várias soluções que propõem a adaptação *on-line* dos pesos da rede, algumas delas formuladas de forma a garantir a estabilidade do sistema em malha fechada. Dentro dessas propostas, a adaptação completa dos pesos da rede, como em Lewis, 1996 e Daachi et al., 2014, tem a vantagem de não necessitar de ajuste *off-line*. Essas estratégias utilizam algoritmos de adaptação baseados em gradiente. Haykin, 2001, por exemplo, destaca que algoritmos baseados no gradiente oferecem convergência a um mínimo local. Assim, quando não se utiliza uma base fixa, pode ocorrer a convergência a uma resposta não adequada, devido a um mínimo local. Além disso, como previamente discutido, esses autores utilizam sempre redes neurais de tamanho reduzido, que podem também não oferecer uma capacidade de aprendizado satisfatória. Por fim, a estratégia de projeto desses trabalhos considera plantas desconhecidas e, por isso, como pode ser constatado em Lewis, et al., 1996, normalmente não são realizadas comparações de desempenho com estratégias baseadas em modelo.

Nesta tese, assim como em Liang e ElMaraghy, 1993 e Sadegh, 1993, aplica-se um conceito de adaptação onde uma base fixa de pesos das redes neurais é utilizada. Assume-se que essa base, bem como a arquitetura das redes neurais utilizadas, é robusta. Desta forma, considera-se que pequenos ajustes em parâmetros lineares utilizados na saída das redes neurais serão suficientes para adaptar a rede a uma variação paramétrica que ocorra na planta a ser controlada. Desta forma, as informações do treinamento *off-line* da rede sempre serão mantidas, evitando que a mesma “esqueça” esse treinamento por meio da convergência dos pesos para um mínimo local insatisfatório. Trata-se de um conceito semelhante ao controle adaptativo por modelo de referência, onde um modelo fixo é utilizado e um parâmetro linear é ajustado de forma a minimizar o erro em relação a um modelo de referência.

A rede neural que representa a força de atrito modificada, descrita por meio da Equação (4.33), pode ser reescrita como:

$$\Theta(\dot{y}, P_A, P_B, T) = \hat{\mathbf{W}}_{3r}^T \phi, \quad (4.34)$$

onde $\phi = \Psi_{2r}^* (\mathbf{W}_{2r}^T \Psi_{1r}^* (\mathbf{W}_{1r}^T \mathbf{x}_{0r}^*))$ é a base fixa da rede e $\hat{\mathbf{W}}_{3r}$ é um vetor de pesos estimados, cujo valor inicial utilizado é aquele obtido por meio do treinamento *off-line*. Assume-se que existe um vetor de pesos ideal \mathbf{W}_{3r} , constante ao longo do tempo, cujo erro da rede neural é zero. Considera-se, portanto, que $\hat{\mathbf{W}}_{3r} = \mathbf{W}_{3r} + \tilde{\mathbf{W}}_{3r}$. Sendo $\tilde{\mathbf{W}}_{3r}$ o erro de estimação em relação aos pesos ideais, então: $\dot{\hat{\mathbf{W}}}_{3r} = \dot{\tilde{\mathbf{W}}}_{3r}$.

A lei de controle do subsistema mecânico pode ser reescrita como:

$$F_{Hd} = M\ddot{y}_r - K_d z + \hat{\mathbf{W}}_{3r}^T \phi. \quad (4.35)$$

Propõe-se então a seguinte lei de adaptação em relação à $\hat{\mathbf{W}}_{3r}$:

$$\dot{\hat{\mathbf{W}}}_{3r} = -\Gamma \phi z, \quad (4.36)$$

onde Γ é uma matriz diagonal de ganhos de adaptação sempre positivos.

Em relação à lei de controle do subsistema hidráulico, propõe-se a seguinte modificação:

$$u = \left(\dot{F}_{Hd} - K_p \tilde{F} + (A_1^2 f_1 + A_2^2 f_2) \cdot \dot{y} \right) \Omega(y, \dot{y}, P_A, P_B, T) \hat{\alpha}, \quad (4.37)$$

onde $\hat{\alpha} = \alpha + \tilde{\alpha}$, sendo $\alpha = 1/\delta$ uma constante fixa desconhecida, sempre positiva, a ser estimada e $\tilde{\alpha}$ o erro de estimação em relação a essa constante. Sendo α constante ao longo do tempo, então $\dot{\hat{\alpha}} = \dot{\tilde{\alpha}}$. Define-se δ como uma constante estritamente positiva que representa o percentual de erro de estimação da rede neural ao longo do tempo somado a um.

Propõe-se então a seguinte lei de adaptação em relação à $\hat{\alpha}$:

$$\dot{\hat{\alpha}} = -l \left(\dot{F}_{Hd} - K_p \tilde{F} + (A_1^2 f_1 + A_2^2 f_2) \dot{y} \right) \tilde{F}, \quad (4.38)$$

onde l é um ganho de adaptação escalar sempre positivo.

A lei de controle expressa por meio da Equação (4.37) é baseada na lei de controle proposta em Cunha, 2005, e Coelho e Cunha, 2011. Nesses trabalhos, os autores utilizam um

controle adaptativo por modelo de referência para adaptar a inversa do parâmetro K_v da válvula, descrito no Capítulo 2, mantendo a parte analítica não linear fixa. Uma ideia semelhante é utilizada na Equação (4.37), mantendo a rede neural fixa. O valor ideal de $\hat{\alpha}$ é igual a um (rede sem erro), e deverá ser adaptado de acordo com o erro da rede neural para um valor que minimize o erro de força \tilde{F} .

Um problema bastante conhecido em controle adaptativo, abordado por autores como Slotine e Li, 1991, Polycarpou e Ioannou 1992 e Lewis, et al., 1993 e mais recentemente em trabalhos como Yang et al., 2013, trata-se do *drift* nos parâmetros estimados, que pode levar os mesmos a valores muito altos, instabilizando o sistema em malha fechada. Esse problema ocorre, segundo Slotine e Li, 1991 e Lewis, et al., 1993, devido a uma estimação pobre dos parâmetros adaptados, ocasionada por ruídos, perturbações, excitação de dinâmicas não modeladas ou um sinal de excitação não persistente. Várias soluções são propostas para tal problema, tais como funções de projeção [Polycarpou e Ioannou 1992], proposição de um termo adicional que evite oscilações dos parâmetros estimados [Lewis, et al., 1996] e a introdução de uma zona morta de adaptação baseada no erro [Chen e Liu, 1994].

No presente trabalho, adota-se uma solução simples, com base na solução proposta por Lewis, et al., 1993, para uma aplicação em controle adaptativo de manipuladores robóticos. Como se conhece aproximadamente os limites das redes neurais propostas, ilustrados por meio das figuras 4.13 a 4.16, e se tem parâmetros iniciais robustos, propõe-se um *reset* nos parâmetros quando a saída das redes neurais ultrapassarem determinados limites pré-fixados. As equações (4.39) e (4.40) descrevem a estratégia.

$$\left\{ \begin{array}{l} \dot{\hat{\mathbf{W}}}_{3_T} = -\Gamma \phi z \quad ; \quad D_{\min} \leq \mathbf{W}_{3_T}^T \phi \leq D_{\max} \\ \hat{\mathbf{W}}_{3_T} = \hat{\mathbf{W}}_{3_T \text{ inicial}} \quad ; \quad D_{\min} > \mathbf{W}_{3_T}^T \phi \quad ; \quad \mathbf{W}_{3_T}^T \phi > D_{\max} \end{array} \right. , \quad (4.39)$$

$$\left\{ \begin{array}{l} \dot{\hat{\alpha}} = -l \left(\dot{F}_{Hd} - K_p \tilde{F} + (A_1^2 f_1 + A_2^2 f_2) \cdot \dot{y} \right) \tilde{F} \quad ; \quad U_{\min} \leq \Omega(y, \dot{y}, P_A, P_B, T) \hat{\alpha} \leq U_{\max} \\ \hat{\alpha} = 1 \quad ; \quad U_{\min} > \Omega(y, \dot{y}, P_A, P_B, T) \hat{\alpha} \quad ; \quad \Omega(y, \dot{y}, P_A, P_B, T) \hat{\alpha} > U_{\max} \end{array} \right. . \quad (4.40)$$

onde D_{\min} e D_{\max} são os limites para a função do mapa inverso (Vs/N) e U_{\min} e U_{\max} são os limites para a função do atrito modificado (N).

As provas de estabilidade dos controladores utilizando as redes neurais estáticas e adaptativas são apresentadas na Seção 4.6 abaixo.

4.6. Prova de estabilidade.

Considera-se a representação matemática do modelo do atuador hidráulico a ser controlado descrita por meio das equações da Tabela 2.4 reescritas por meio da Tabela 4.12, que constituem o modelo de 4° ordem do sistema:

Tabela 4.12- Equações do modelo do atuador hidráulico.

Equação	número
$P_A A_1 - P_B A_2 = M\ddot{y} + F_A' + F_L$	(2.80)
$F_A' = F_A + F_p$	(2.76)
$\dot{P}_A A_1 - \dot{P}_B A_2 = (A_1 f_1 K_{VA} g_A + A_2 f_2 K_{VB} g_B)u - (A_1^2 f_1 + A_2^2 f_2)\dot{y}$	(2.81)
$Q_1 = K_{VA} g_A u$	(2.82)
$Q_2 = K_{VB} g_B u$	(2.83)
$g_A = \begin{cases} u \geq 0 \rightarrow \sqrt{(P_s - P_A - \Delta P_1)} \\ u < 0 \rightarrow \sqrt{P_A - \Delta P_3} \end{cases}$	(2.84)
$g_B = \begin{cases} u \geq 0 \rightarrow \sqrt{P_B - \Delta P_4} \\ u < 0 \rightarrow \sqrt{(P_s - P_B - \Delta P_2)} \end{cases}$	(2.85)
$f_1 = \frac{\beta}{V_{10} + A_1 y}$	(2.39)
$f_2 = \frac{\beta}{V_{20} - A_2 y}$	(2.40)

4.6.1. Prova de estabilidade do controlador em cascata neural fixo.

Considera-se o atuador hidráulico, descrito por meio das equações da Tabela 4.12, sendo comandado pelo Controlador em Cascata Neural Fixo, descrito por meio das equações:

$$F_H = P_A A_1 - P_B A_2, \quad (4.41)$$

$$\tilde{F} = F_H - F_{Hd}, \quad (4.42)$$

$$F_{Hd} = M\ddot{y}_r - K_d z + \Theta(\dot{y}, P_A, P_B, T), \quad (4.43)$$

$$u = \left(\dot{F}_{Hd} - K_p \tilde{F} + (A_1^2 f_1 + A_2^2 f_2) \dot{y} \right) \Omega(y, \dot{y}, P_A, P_B, T), \quad (4.44)$$

onde $\Omega(y, \dot{y}, P_A, P_B, T)$ e $\Theta(\dot{y}, P_A, P_B, T)$ são duas redes neurais descritas por meio das equações (4.31) e (4.33), que são treinadas “*off-line*”, de modo a representarem as seguintes funções:

$$\Omega(y, \dot{y}, P_A, P_B, T) \cong \frac{1}{(A_1 f_1 K_{VA} g_A + A_2 f_2 K_{VB} g_B)}, \quad (4.45)$$

$$\Theta(\dot{y}, P_A, P_B, T) \cong F_A + F_L. \quad (4.46)$$

Suposição 1: As redes neurais não apresentam erros de estimação em relação as funções por elas representadas.

Considerando a relação descrita em (4.41) e substituindo (4.43) e (4.44) em (2.80) e (2.81) tem-se:

$$M\dot{z} = -K_d z + \tilde{F}, \quad (4.47)$$

$$\dot{\tilde{F}} = -K_p \tilde{F}. \quad (4.48)$$

Para a estratégia proposta, é imposta a condição de que a trajetória de posição desejada y_d e suas derivadas sejam limitadas até a quarta ordem (condição de projeto do controlador em cascata com base em Cunha, 2001). Seja o vetor de erros de rastreamento de trajetória $\boldsymbol{\rho} = [\tilde{y} \quad \dot{\tilde{y}} \quad \tilde{F}]$, prova-se a estabilidade exponencial através do seguinte Lema:

Lema 1: Se uma função real $W(t) \geq 0$ satisfaz a desigualdade $\dot{W}(t) + \xi W(t) \leq 0$ onde ξ é um número real, então $W(t) \leq W(0)e^{-\xi t}$ [Slotine e Li, 1991].

O Teorema 1 estabelece as características da malha fechada:

Teorema 1: Considerando válida a Suposição 1 e os demais parâmetros do sistema conhecidos, o sistema formado pelas equações constantes na Tabela 4.12 e por meio das equações (4.41) a (4.44) é exponencialmente estável em relação à origem do vetor de rastreamento $\boldsymbol{\rho}$.

Prova: considera-se a função de Lyapunov descrita por meio da equação:

$$V = \frac{1}{2} (HMz^2 + R\tilde{y}^2 + \tilde{F}^2), \quad (4.49)$$

onde H e R são constantes positivas a serem definidas. Substituindo o valor de z representado por meio da Equação (4.2) e descrevendo V por meio de operações matriciais, tem-se:

$$V = \frac{1}{2} [\tilde{y} \quad \dot{\tilde{y}} \quad \tilde{F}] \begin{bmatrix} MH\lambda^2 + R & \lambda MH & 0 \\ \lambda MH & MH & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \tilde{y} \\ \dot{\tilde{y}} \\ \tilde{F} \end{bmatrix} = \frac{1}{2} \boldsymbol{\rho}^T \mathbf{N}_1 \boldsymbol{\rho}. \quad (4.50)$$

Derivando a função V em relação ao tempo tem-se:

$$\dot{V} = MH(z\dot{z}) + R(\tilde{y}\dot{\tilde{y}}) + \tilde{F}\dot{\tilde{F}}. \quad (4.51)$$

Substituindo-se agora as equações (4.47) e (4.48) em (4.51), obtém-se:

$$\dot{V} = (-K_d H(\dot{\tilde{y}} + \lambda \tilde{y}) + H\tilde{F})(\dot{\tilde{y}} + \lambda \tilde{y}) + R(\tilde{y}\dot{\tilde{y}}) + \tilde{F}(-K_p \tilde{F}). \quad (4.52)$$

Colocando na forma matricial e definindo $R \equiv 2\lambda HK_d$, resulta:

$$\dot{V} = -\begin{bmatrix} \tilde{y} & \dot{\tilde{y}} & \tilde{F} \end{bmatrix} \begin{bmatrix} \lambda^2 HK_d & 0 & -\frac{1}{2} H \lambda \\ 0 & K_d H & -\frac{1}{2} H \\ -\frac{1}{2} H \lambda & -\frac{1}{2} H & K_p \end{bmatrix} \begin{bmatrix} \tilde{y} \\ \dot{\tilde{y}} \\ \tilde{F} \end{bmatrix} = -\mathbf{\rho}^T (\mathbf{N}_2) \mathbf{\rho}. \quad (4.53)$$

Para a análise das propriedades de \mathbf{N}_1 e \mathbf{N}_2 será utilizado o conhecido Critério de Sylvester [Noble e Daniel, 1986].

Critério de Sylvester: sendo a matriz simétrica, uma condição necessária e suficiente para que a mesma seja positiva definida é que os determinantes de seus menores principais sejam positivos.

Aplicando-se o critério de Sylvester a \mathbf{N}_1 , tem-se

$$\begin{aligned} \det[MH\lambda^2 + R] &= MH\lambda^2 + R \\ \det \begin{bmatrix} MH\lambda^2 + R & \lambda MH \\ \lambda MH & MH \end{bmatrix} &= MHR. \\ \det[N_1] &= MHR \end{aligned} \quad (4.54)$$

Como M, H, λ e R são estritamente positivos, a matriz \mathbf{N}_1 é positiva definida, sendo, portanto, a função V definida na Equação (4.53) sempre positiva quando $\rho \neq 0$.

Aplicando-se o critério de Sylvester a \mathbf{N}_2 :

$$\begin{aligned}
\det[\lambda^2 \mathbf{H} \mathbf{K}_d] &= \lambda^2 K_d \\
\det \begin{bmatrix} \lambda^2 \mathbf{H} \mathbf{K}_d & 0 \\ 0 & \mathbf{K}_d \mathbf{H} \end{bmatrix} &= \lambda^2 K_d^2 H^2 \quad . \\
\det[-\mathbf{N}_2] &= \lambda^2 K_d^2 H^2 K_p - \frac{1}{2} \lambda^2 K_d H^3
\end{aligned} \tag{4.55}$$

Como K_d e λ são sempre maiores que zero, uma condição suficiente para que a matriz \mathbf{N}_2 seja positiva definida é que:

$$K_d K_p > \frac{1}{2} H. \tag{4.56}$$

Assim, atendendo à condição (4.56), \mathbf{N}_2 é positiva definida, então a função \dot{V} definida na Equação (4.51), para $\rho \neq 0$, é sempre negativa. Desta forma, prova-se, de acordo com Slotine e Li, 1991, que o sistema formado pelas equações da Tabela 4.12 e pelas equações (4.41)-(4.44) é estável no sentido de Lyapunov.

Para completar a prova do Teorema 1, recorre-se ao Teorema de Rayleigh-Ritz, que estabelece que:

$$\begin{aligned}
\lambda_{\min}(\mathbf{N}_1) \boldsymbol{\rho}^T \boldsymbol{\rho} &\leq \boldsymbol{\rho}^T \mathbf{N}_1 \boldsymbol{\rho} \leq \lambda_{\max}(\mathbf{N}_1) \boldsymbol{\rho}^T \boldsymbol{\rho} \\
\lambda_{\min}(\mathbf{N}_2) \boldsymbol{\rho}^T \boldsymbol{\rho} &\leq \boldsymbol{\rho}^T \mathbf{N}_2 \boldsymbol{\rho} \leq \lambda_{\max}(\mathbf{N}_2) \boldsymbol{\rho}^T \boldsymbol{\rho}
\end{aligned} \tag{4.57}$$

Desta forma,

$$\mathbf{N}_1 \leq \lambda_{\max}(\mathbf{N}_1) \mathbf{I} \quad \text{e} \quad \lambda_{\min}(\mathbf{N}_2) \mathbf{I} \leq \mathbf{N}_2. \tag{4.58}$$

Definindo agora uma constante γ como sendo:

$$\gamma = \frac{\lambda_{\min}(\mathbf{N}_2)}{\lambda_{\max}(\mathbf{N}_1)}, \tag{4.59}$$

utilizando os resultados de (4.57), (4.58) e (4.59), pode-se escrever que:

$$\boldsymbol{\rho}^T \mathbf{N}_2 \boldsymbol{\rho} \geq \gamma \left(\boldsymbol{\rho}^T (\lambda_{\max}(\mathbf{N}_1) \mathbf{I}) \boldsymbol{\rho} \right). \quad (4.60)$$

Então, tem-se que:

$$\boldsymbol{\rho}^T \mathbf{N}_2 \boldsymbol{\rho} \geq \gamma \boldsymbol{\rho}^T \mathbf{N}_1 \boldsymbol{\rho}. \quad (4.61)$$

Substituindo agora (4.50) e (4.53) em (4.61), tem-se que:

$$\gamma V(t) + \dot{V}(t) \leq 0. \quad (4.62)$$

Finalmente, de acordo com o Lema 1, pode-se concluir que:

$$V(t) \leq V(0) e^{-\gamma t}. \quad (4.63)$$

Tendo por base o que foi definido por meio da Equação (4.57), onde $\lambda_{\min}(\mathbf{N}_1) \boldsymbol{\rho}^T \boldsymbol{\rho} \leq \boldsymbol{\rho}^T \mathbf{N}_1 \boldsymbol{\rho}$, pode-se afirmar que a norma do vetor de erros converge exponencialmente para a origem com uma taxa de convergência maior que $\frac{\gamma}{2}$, completando a prova do Teorema 1.

Suposição 2: A rede neural representando a força de atrito modificada, descrita por meio da Equação (4.33), representa exatamente o comportamento descrito por meio da Equação (4.46), sendo tal força limitada em um valor máximo \bar{f}_A e sua derivada limitada por um valor máximo $\bar{\dot{f}}_A$. A rede neural descrita por meio da Equação (4.31) apresenta um erro limitado, que pode ser representado por meio de um valor $\tilde{\delta}$, de acordo com a equação:

$$u = \Omega(y, \dot{y}, P_A, P_B, T) [v + f] + \varepsilon = b^{-1} \left[\dot{F}_{Hd} - K_p \tilde{F} + f \right] (1 + \tilde{\delta}), \quad (4.64)$$

cujos limites encontra-se entre os valores de $-\bar{\delta} \leq \tilde{\delta} \leq \bar{\delta}$. O valor de $\bar{\delta}$ representa um percentual de erro.

Teorema 2: Considerando válida a Suposição 2 e os demais parâmetros do sistema conhecidos, o sistema formado pelas equações constantes na Tabela 4.12 e por meio das equações (4.41) a (4.44), para qualquer trajetória com condição inicial $\boldsymbol{\rho}(0)$, tem a norma do vetor de erros $\|\boldsymbol{\rho}\|$ convergindo para um conjunto residual limitado por uma esfera de raio k , sendo k limitado, quando $t \rightarrow \infty$.

Prova: Considerando a Suposição 2, a Equação (4.48) passa a ser descrita por:

$$\dot{\tilde{F}} = -K_p \tilde{F} + \tilde{\delta} [\dot{F}_{Hd} - K_p \tilde{F} + f]. \quad (4.65)$$

Substituindo (4.47) em (4.51) tem-se:

$$\dot{V} = -K_d H \dot{\tilde{y}}^2 - (2\lambda K_d H - R) \tilde{y} \dot{\tilde{y}} - K_d \lambda^2 H \tilde{y}^2 + H \tilde{F} \dot{\tilde{y}} + \lambda H \tilde{F} \tilde{y} + \tilde{F} \dot{\tilde{F}}, \quad (4.66)$$

Considerando os seguintes termos:

$$\dot{F}_{Hd} = (-K_d - M \lambda) \ddot{\tilde{y}} - K_d \lambda \dot{\tilde{y}} + M \ddot{y}_d + \dot{\bar{f}}_A, \quad (4.67)$$

e também,

$$\ddot{\tilde{y}} = -\lambda \dot{\tilde{y}} - M^{-1} K_d (\dot{\tilde{y}} + \lambda \tilde{y}) + M^{-1} \tilde{F}, \quad (4.68)$$

atribuindo-se $R = 2\lambda K_d H$, pode-se escrever (4.66) como:

$$\dot{V} = - \left(\begin{array}{c} \left[\begin{array}{ccc} \lambda^2 K_d H & 0 & -\frac{1}{2} H \lambda - \frac{\tilde{\delta} \alpha_1}{2} \\ 0 & K_d H & -\frac{1}{2} H - \frac{\tilde{\delta} \alpha_2}{2} \\ -\frac{1}{2} H \lambda - \frac{\tilde{\delta} \alpha_1}{2} & -\frac{1}{2} H - \frac{\tilde{\delta} \alpha_2}{2} & K_p - \tilde{\delta} \alpha_3 \end{array} \right] \begin{bmatrix} \tilde{y} \\ \dot{\tilde{y}} \\ \tilde{F} \end{bmatrix} \dots \\ + \left[\begin{array}{ccc} \tilde{y} & \dot{\tilde{y}} & \tilde{F} \end{array} \right] \begin{bmatrix} 0 \\ 0 \\ -\Psi_d \tilde{\delta} \end{bmatrix} \end{array} \right), \quad (4.69)$$

$$\dot{V} = -(\boldsymbol{\rho}^T (\mathbf{N}_2) \boldsymbol{\rho} + \boldsymbol{\rho}^T \boldsymbol{\Delta})$$

onde $\alpha_1, \alpha_2, \alpha_3, \Psi_d$ são termos auxiliares limitados, definidos por:

$$\alpha_1 = \left((M \lambda + K_d) \frac{\lambda K_d}{M} \right), \quad (4.70)$$

$$\alpha_2 = \left((M \lambda + K_d) \left(\lambda + \frac{K_d}{M} \right) - \lambda K_d + (A_1^2 f_1 + A_2^2 f_2) \right), \quad (4.71)$$

$$\alpha_3 = \left(-K_d \frac{1}{M} - (\lambda + K_p) \right), \quad (4.72)$$

$$\Psi_d = M \ddot{y}_d + (A_1^2 f_1 + A_2^2 f_2) \dot{y}_d + \bar{f}_A, \quad (4.73)$$

sendo f_1 e f_2 funções limitadas.

Considerando o Critério de Sylvester, uma condição suficiente para que a matriz \mathbf{N}_2 seja positiva definida é que:

$$K_p > \frac{1}{(\lambda^2 K_d H)(1 + \tilde{\delta})} \left(\left(\frac{1}{2} H \lambda + \frac{\tilde{\delta} \alpha_1}{2} \right)^2 + \left(\frac{1}{2} H + \frac{\tilde{\delta} \alpha_2}{2} \right)^2 \lambda^2 - \lambda^2 K_d H \tilde{\delta} (K_d + \lambda M) \frac{1}{M} \right), \quad (4.74)$$

sendo tal condição satisfeita escolhendo valores apropriados para os ganhos e para a constante H , mediante um limite $\bar{\delta}$ para o erro da rede neural que representa o mapa inverso. Considerando, por exemplo, $K_p = 200$, $\lambda = 150$, $K_v = 5000$ e escolhendo $H = 9 \cdot 10^5$, tem-se

que a matriz \mathbf{N}_2 é positiva definida para um valor de $\bar{\delta} = 0,17$ ($\pm 17\%$ de erro para a rede neural).

Uma vez que o critério é satisfeito, da inequação de Cauchy-Schwarz [Noble e Daniel, 1986] tem-se que:

$$\begin{aligned} |x^T y| &\leq \|x\| \|y\| \\ \boldsymbol{\rho}^T \Delta &\leq \|\boldsymbol{\rho}\| \|\Delta\| \end{aligned} \quad (4.75)$$

De (4.57) e (4.75) tem-se que:

$$\begin{aligned} -\lambda_{\min}(\mathbf{N}_2) \boldsymbol{\rho}^T \boldsymbol{\rho} + \|\boldsymbol{\rho}\| \|\Delta\| &\geq -\boldsymbol{\rho}^T \mathbf{N}_2 \boldsymbol{\rho} + \|\boldsymbol{\rho}\| \|\Delta\| \\ -\lambda_{\min}(\mathbf{N}_2) \|\boldsymbol{\rho}\|^2 + \|\boldsymbol{\rho}\| \|\Delta\| &\geq \dot{V}(t) \end{aligned} \quad (4.76)$$

Para que a função permaneça negativa, tem-se que:

$$\begin{aligned} (-\lambda_{\min}(\mathbf{N}_2) \|\boldsymbol{\rho}\| + \|\Delta\|) \|\boldsymbol{\rho}\| &< 0 \\ \|\boldsymbol{\rho}\| &> \frac{\|\Delta\|}{\lambda_{\min}(\mathbf{N}_2)} \end{aligned} \quad (4.77)$$

Sendo Δ limitado e $\bar{\Delta}$ um limite para a norma desse vetor, então, uma condição suficiente para que a função permaneça negativa é que:

$$\|\boldsymbol{\rho}\| > \frac{\bar{\Delta}}{\lambda_{\min}(\mathbf{N}_2)} \quad (4.78)$$

Considerando um raio $k = \bar{\Delta} / \lambda_{\min}(\mathbf{N}_2)$, quando a norma $\|\boldsymbol{\rho}\|$ é menor que k , a energia aumenta, fazendo que a condição descrita por meio da Equação (4.78) seja atendida e, portanto, retornando a norma para um valor menor que k , provando, então, o Teorema 2.

4.6.2. Prova de estabilidade do controlador em cascata neural adaptativo.

Considera-se o atuador hidráulico, descrito por meio das equações da Tabela 4.12, sendo comandado pelo Controlador em Cascata Neural Adaptativo, descrito por meio das equações (4.79) e (4.80):

$$u = \left(\dot{F}_{Hd} - K_p \tilde{F} + (A_1^2 f_1 + A_2^2 f_2) \cdot \dot{y} \right) \Omega(y, \dot{y}, P_A, P_B, T) \hat{\alpha}, \quad (4.79)$$

$$F_{Hd} = M\ddot{y}_r - K_d \dot{z} + \Theta(\dot{y}, P_A, P_B, T), \quad (4.80)$$

onde $\Theta(\dot{y}, P_A, P_B, T)$ é uma rede neural definida por meio da Equação (4.34) e $\Omega(y, \dot{y}, P_A, P_B, T)$ é uma rede neural definida por meio da Equação (4.31), ambas treinadas “*off-line*”, de modo a representarem as seguintes funções do modelo:

$$\Omega(y, \dot{y}, P_A, P_B, T) \cong \frac{1}{(A_1 f_1 K_{VA} \cdot g_A + A_2 f_2 K_{VB} \cdot g_B)} + \varepsilon_1, \quad (4.81)$$

$$\Theta(\dot{y}, P_A, P_B, T) \cong F_A + F_L + \varepsilon_2, \quad (4.82)$$

onde ε_1 e ε_2 são erros desconhecidos de estimação.

Suposição 3: As redes neurais descritas por meio das equações (4.31) e (4.34) são adequadamente treinadas, de modo que as funções obtidas são suaves e com erros de estimação reduzidos.

Recorrendo-se ao Teorema da aproximação universal para redes neurais, estabelecido em Hornik, 1991, e, levando em conta a Suposição 3, pode-se estabelecer que:

- Os erros de estimação descritos por meio das equações (4.81) e (4.82) são limitados;

- O limite para a saída das redes neurais descritas por meio das equações (4.31) e (4.34) encontra-se dentro da vizinhança do limite estabelecido para a saída das funções estimadas apresentado às respectivas redes durante o treinamento (conforme ilustrado nas figuras 4.13 e 4.15);
- As derivadas superiores das saídas das redes neurais descritas por meio das equações (4.31) e (4.34) em relação ao tempo são limitadas [Haykin,2001].

Suposição 4: O erro $\tilde{\delta}$, definido na Suposição 2, é constante ao longo do tempo. Desta forma, a Equação (4.81) pode ser reescrita como:

$$\Omega(y, \dot{y}, P_A, P_B, T) = \frac{1}{(A_1 f_1 K_{VA} g_A + A_2 f_2 K_{VB} g_B)} (1 + \tilde{\delta}), \quad (4.83)$$

onde se supõe, então, que existe uma constante estritamente positiva $\delta = (1 + \tilde{\delta})$ que representa o erro de estimação ao longo do tempo. Para um erro de estimação nulo, o valor dessa constante seria, portanto, $\delta = 1$.

Suposição 5: O erro ε_2 apresentado na Equação (4.82) pode ser definido como:

$$\varepsilon_2 = \tilde{\mathbf{W}}_{3r}^T \phi, \quad (4.84)$$

Desta forma a Equação (4.82) pode ser reescrita como:

$$\Theta(\dot{y}, P_A, P_B, T) \cong F_A' + F_L + \tilde{\mathbf{W}}_{3r}^T \phi. \quad (4.85)$$

Reescrevendo as leis de adaptação descritas por meio das equações (4.36) e (4.38):

$$\dot{\tilde{\mathbf{W}}}_{3r} = -\Gamma \phi z, \quad (4.86)$$

$$\dot{\hat{\alpha}} = -l \left(\dot{F}_{Hd} - K_p \tilde{F} + (A_1^2 f_1 + A_2^2 f_2) \cdot \dot{y} \right) \tilde{F}. \quad (4.87)$$

Substituindo (4.79) e (4.80) em (2.81) e (2.80), tem-se:

$$M\dot{z} = \tilde{\mathbf{W}}_{3_r}^T \phi - K_d z + \tilde{F}, \quad (4.88)$$

$$\dot{\tilde{F}} = -K_p \tilde{F} + \delta \tilde{\alpha} \left(\dot{F}_{Hd} - K_p \tilde{F} + (A_1^2 f_1 + A_2^2 f_2) \dot{y} \right). \quad (4.89)$$

Para a estratégia proposta, é imposta a condição de que a trajetória de posição desejada y_d e suas derivadas sejam limitadas até a quarta ordem. Seja o vetor de erro de rastreamento de trajetória $\boldsymbol{\rho} = [\tilde{y} \quad \dot{\tilde{y}} \quad \tilde{F}]$, propõe-se agora o Teorema 3, o qual estabelece as características do sistema em malha fechada:

Teorema 3: Considerando válidas as suposições 3, 4 e 5, o sistema formado pelas equações da Tabela 4.12 e pelas equações (4.79) e (4.80) é globalmente estável e $\rho \rightarrow 0$ quando $t \rightarrow \infty$.

Prova: considera-se a função de Lyapunov descrita por meio da Equação:

$$V = \frac{1}{2} \left(Mz^2 + R\tilde{y}^2 + \tilde{F}^2 + \tilde{\mathbf{W}}_{3_r}^T \Gamma^{-1} \tilde{\mathbf{W}}_{3_r} + \delta l^{-1} \tilde{\alpha}^2 \right) = \frac{1}{2} \boldsymbol{\rho}^T \mathbf{N}_1 \boldsymbol{\rho} + \tilde{\mathbf{W}}_{3_r}^T \Gamma^{-1} \tilde{\mathbf{W}}_{3_r} + \delta l^{-1} \tilde{\alpha}^2. \quad (4.90)$$

Derivando a função V em relação ao tempo tem-se:

$$\dot{V} = M(z\dot{z}) + R(\tilde{y}\dot{\tilde{y}}) + \tilde{F}\dot{\tilde{F}} + \tilde{\mathbf{W}}_{3_r}^T \Gamma^{-1} \dot{\tilde{\mathbf{W}}}_{3_r} + \delta \tilde{\alpha} l^{-1} \dot{\tilde{\alpha}}. \quad (4.91)$$

Substituindo (4.79) e (4.80) em (4.91), obtém-se:

$$\begin{aligned} \dot{V} = & \left(\tilde{\mathbf{W}}_{3_r}^T \phi - K_d z + \tilde{F} \right) z + R(\tilde{y}\dot{\tilde{y}}) + \tilde{F} \left(-K_p \tilde{F} + \delta \tilde{\alpha} \left(\dot{F}_{Hd} - K_p \tilde{F} + (A_1^2 f_1 + A_2^2 f_2) \dot{y} \right) \right) \\ & + \tilde{\mathbf{W}}_{3_r}^T \Gamma^{-1} \dot{\tilde{\mathbf{W}}}_{3_r} + \delta \tilde{\alpha} l^{-1} \dot{\tilde{\alpha}}. \end{aligned} \quad (4.92)$$

Substituindo agora (4.86) e (4.87) em (4.92):

$$\begin{aligned} \dot{V} = & \tilde{\mathbf{W}}_{3_T}^T \phi z - K_d z^2 + \tilde{F} z + R(\tilde{y}\dot{\tilde{y}}) - K_p \tilde{F}^2 + \delta \tilde{\alpha} (\dot{F}_{Hd} - K_p \tilde{F} + (A_1^2 f_1 + A_2^2 f_2)) \tilde{F} \\ & - \tilde{\mathbf{W}}_{3_T}^T \phi z - \delta \tilde{\alpha} (\dot{F}_{Hd} - K_p \tilde{F} + (A_1^2 f_1 + A_2^2 f_2)) \tilde{F}. \end{aligned} \quad (4.93)$$

Tem-se então que:

$$\dot{V} = -K_d z^2 + \tilde{F} z + R(\tilde{y}\dot{\tilde{y}}) - K_p \tilde{F}^2 = -\boldsymbol{\rho}^T (\mathbf{N}_2) \boldsymbol{\rho}. \quad (4.94)$$

Considerando os resultados anteriormente obtidos em relação a \mathbf{N}_1 e \mathbf{N}_2 (para $H=1$ e $\tilde{\delta} = 0$) e sendo os ganhos de adaptação sempre positivos, pode-se afirmar que, para $\rho \neq 0$, V é sempre positiva e \dot{V} é sempre negativa $\forall t$, sendo, portanto, o sistema estável no sentido de Lyapunov.

Para completar a prova, aplica-se o Lema de Barbalat [Slotine e Li, 1991]:

- Se $V(t)$ é limitada, e,
- se $\dot{V}(t)$ é negativa semi-definida, e,
- se $\dot{V}(t)$ é uniformemente contínua (o que ocorre se $\dot{V}(t)$ é limitada), então $\dot{V}(t) \rightarrow 0$ quando $t \rightarrow \infty$ e portanto $\rho \rightarrow 0$ quando $t \rightarrow \infty$.

Derivando (4.94) em relação ao tempo tem-se:

$$\ddot{V} = -2\boldsymbol{\rho}^T (\mathbf{N}_2) \dot{\boldsymbol{\rho}}. \quad (4.95)$$

Sendo \dot{V} negativa semi-definida, as seguintes conclusões podem ser estabelecidas:

- ρ é limitado e $\tilde{\mathbf{W}}_{3_T}$ e $\tilde{\alpha}$ são limitados, e,
- sendo ρ , $\tilde{\mathbf{W}}_{3_T}$ e $\tilde{\alpha}$ limitados então \tilde{y} , $\dot{\tilde{y}}$, \tilde{F} , $\dot{\tilde{F}}$, \dot{y}_r , \dot{y}_r , z , $\tilde{\mathbf{W}}_{3_T}$ e $\hat{\alpha}$ são limitados, então,
- F_{Hd} e F_H são limitados;

Sendo $\dot{\boldsymbol{\rho}} = [\dot{\tilde{y}} \quad \dot{\tilde{y}} \quad \dot{\tilde{F}}]$, as seguintes conclusões podem ser estabelecidas:

- Como $M\dot{z} = \tilde{W}_{3T}^T \phi - K_d z + \tilde{F}$, então \dot{z} é limitado e \ddot{y} e \ddot{y}_r são limitados;
- \dot{y} é limitado (conforme já mostrado), e,
- Como $\dot{F}_{Hd} = M\ddot{y}_r - K_d \dot{z} + \dot{\Theta}(\dot{y}, P_A, P_B, T)$, então:
 - Da Suposição 3, $\dot{\Theta}(\dot{y}, P_A, P_B, T)$ é limitado, sendo, portanto, \dot{F}_{Hd} limitado;
 - Sendo \dot{F}_{Hd} limitado, u e \dot{F}_H são também limitados;
 - \ddot{F} é também limitado.
- N_2 é positiva definida (como mostrado anteriormente).

Prova-se, portanto, que $\ddot{V}(t)$ é limitada e, por conseguinte, $\dot{V}(t) \rightarrow 0$ quando $t \rightarrow \infty$ e $\rho \rightarrow 0$ quando $t \rightarrow \infty$, completando a prova do Teorema 3.

4.7. Discussões do Capítulo 4.

Neste capítulo foi apresentada a estratégia de controle em cascata tradicional utilizada em vários trabalhos encontrados na bibliografia, os quais mostram a efetividade dessa estratégia. As Redes Neurais foram utilizadas com a intenção de propor um controlador que agregue as conhecidas vantagens de projeto e síntese de funções não lineares das mesmas. Por meio de uma metodologia de treinamento *off-line* proposta com base nas características de um sistema hidráulico, obteve-se redes neurais que representam adequadamente as funções de atrito e do mapa inverso do subsistema hidráulico, considerando-se, ainda, a variação de temperatura do fluido hidráulico. Assumindo-se que o treinamento *off-line* constitui uma base robusta para as funções de representação supracitadas, utiliza-se parâmetros lineares na saída dessas funções como parâmetros a serem estimados, de forma a propor um controlador adaptativo que seja capaz de ajustar *on-line* esses parâmetros. A estabilidade destes controladores, com base em suposições simplificadoras, foi provada por meio do método direto de Lyapunov.

5. RESULTADOS EXPERIMENTAIS

Os resultados experimentais apresentados neste capítulo foram obtidos na bancada de testes da Seção 2.3. O objetivo dos experimentos é de ilustrar o desempenho das estratégias de controle propostas no Capítulo 4. Para permitir uma visão comparativa são também apresentados os resultados experimentais dos controladores clássicos e do controlador em cascata analítico. Este capítulo é organizado da seguinte maneira: inicialmente, são apresentadas as trajetórias de posição desejadas. Na sequência, são apresentados os resultados experimentais obtidos com os controladores lineares descritos na Seção 3.1. Logo após, são apresentados os resultados obtidos utilizando o controlador em cascata apresentado na Seção 4.1, e, na sequência, os resultados obtidos utilizando o controlador proposto no presente trabalho com as modificações descritas nas seções 4.2 e 4.3. Por fim, são apresentados os resultados experimentais obtidos por meio da utilização das estratégias de adaptação apresentadas na Seção 4.5. Todos os resultados de experimentos apresentados neste capítulo foram obtidos com um período de amostragem de 0,5 ms. Todos os resultados de erro foram pós-filtrados utilizando um filtro de primeira ordem do tipo Butterworth, com frequência de corte $\omega_c = 45$ rad/s sem atraso de fase de filtragem.

5.1. Trajetórias de posição desejadas.

A exemplo de outros trabalhos na área, foram escolhidas duas trajetórias distintas de posição visando a permitir a análise dos controladores em diferentes situações de aproximação. A primeira delas é uma trajetória polinomial de sétima ordem, semelhante às utilizadas em Perondi, 2002 e Cunha, 2001, adaptada ao curso de 200 mm (0,2 m) do pistão utilizado. Essa trajetória foi descrita no Capítulo 3 por meio da Equação (3.1) e ilustrada por meio da Figura 3.1. Por conveniência, reescreve-se a mesma por meio da Equação (5.1):

$$y(t) = 0,6(-2t^7 + 7t^6 - 8,4t^5 + 3,5t^4)$$

$$y_d = \begin{cases} y(t/2) & t < 2 \\ 0,06 & 2 \leq t < 4 \\ -y(t/2 - 2) + 0,06 & 4 \leq t < 6 \\ 0 & 6 \leq t < 8 \\ -y(t/2 - 4) & 8 \leq t < 10 \\ -0,06 & 10 \leq t < 12 \\ y(t/2 - 6) - 0,06 & 12 \leq t < 14 \\ 0 & 14 \leq t < 16 \end{cases} \quad (\text{m}). \quad (5.1)$$

A segunda trajetória utilizada é uma trajetória do tipo senoidal, descrita por meio da Equação (5.2). O zero da posição também é considerado como o centro do cilindro (0,1 m).

$$y(t) = 0,08 \cdot \text{sen}(0,75t) \quad (\text{m}) \quad (5.2)$$

Nas seções que se seguem estão apresentados os resultados experimentais para aplicação dos controladores lineares e em cascata analítico e cascata com redes neurais utilizando pesos fixos e, posteriormente, utilizando as estratégias de adaptação propostas. Para ilustrar o desempenho dos controladores mediante as variações de temperatura do fluido hidráulico, são apresentados experimentos nas temperaturas do fluido hidráulico de 20 °C, 30 °C e 40 °C, temperatura medida no tanque da unidade hidráulica com o sensor descrito no Apêndice C.

5.2. Controladores Lineares

Os controladores lineares utilizados são aqueles descritos no Capítulo 3, ou seja, o controlador PID e o controlador PID + *feedforward*. Os seus ganhos foram sintonizados com a temperatura do fluido hidráulico em 30 °C, e foram apresentados na Tabela 3.2 para o controlador PID e na Tabela 3.3 para o controlador PID+*feedforward*. Os experimentos utilizando os controladores lineares foram realizados conforme a configuração padrão da bancada descrita na Seção 2.3.1.

As figuras 5.1 e 5.2 ilustram os resultados das trajetórias de posição e do sinal de controle da válvula quando no seguimento da trajetória polinomial em uma temperatura de 40 °C do fluido hidráulico.

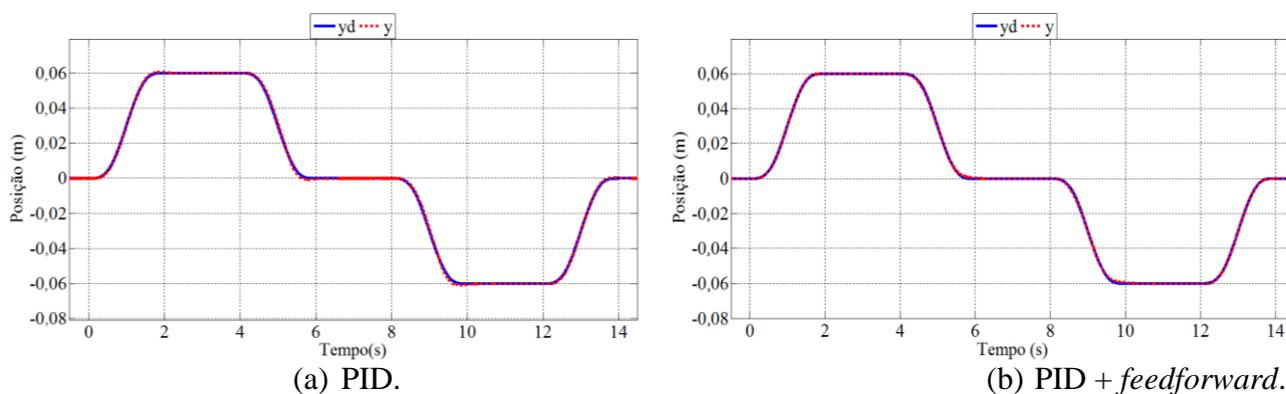


Figura 5.1 - Experimentos a 40 °C PID e PID + f. (trajetória polinomial): posição.

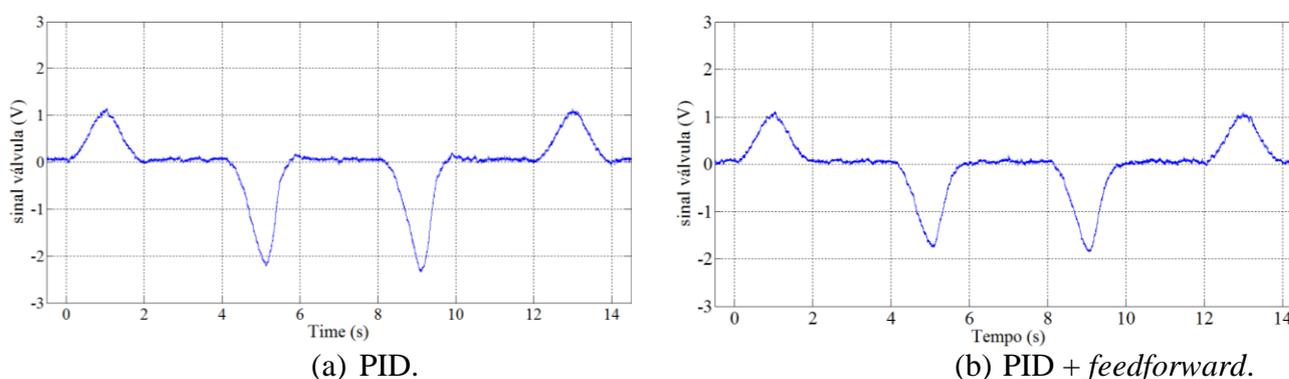


Figura 5.2 - Experimentos a 40 °C PID e PID + f. (trajetória polinomial): sinal de controle.

Observa-se por meio da Figura 5.2 a ausência no sinal de controle de ruídos de alta frequência significativos, que podem estar presentes devido aos ruídos na instrumentação que são amplificados pela ação dos ganhos do controlador. Para temperaturas menores observa-se por meio de experimentos que o ruído percebido é menor, razão pela qual, em relação aos controladores lineares, não são apresentadas as figuras anteriores referentes as informações para temperaturas do fluido hidráulico inferiores a 40 °C.

As figuras 5.3 a 5.5 ilustram os erros de seguimento de posição:

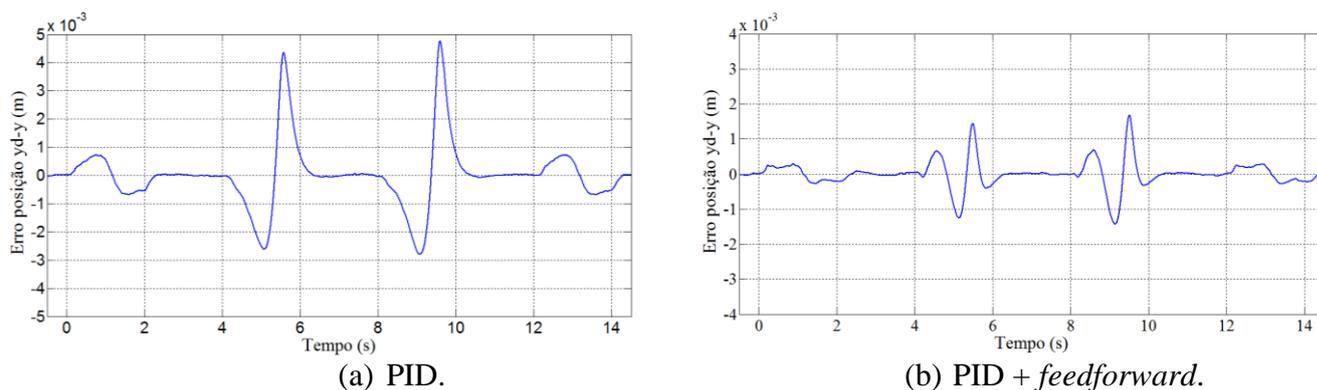


Figura 5.3 - Experimentos a 20 °C : PID e PID + f. (trajetória polinomial): erros de posição.

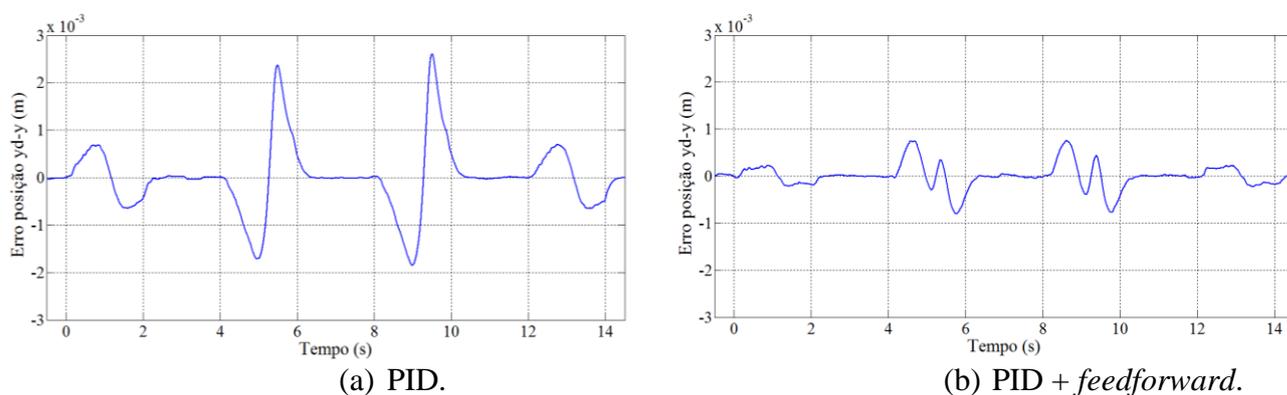


Figura 5.4 - Experimentos a 30 °C PID e PID + f. (trajetória polinomial): erros de posição.

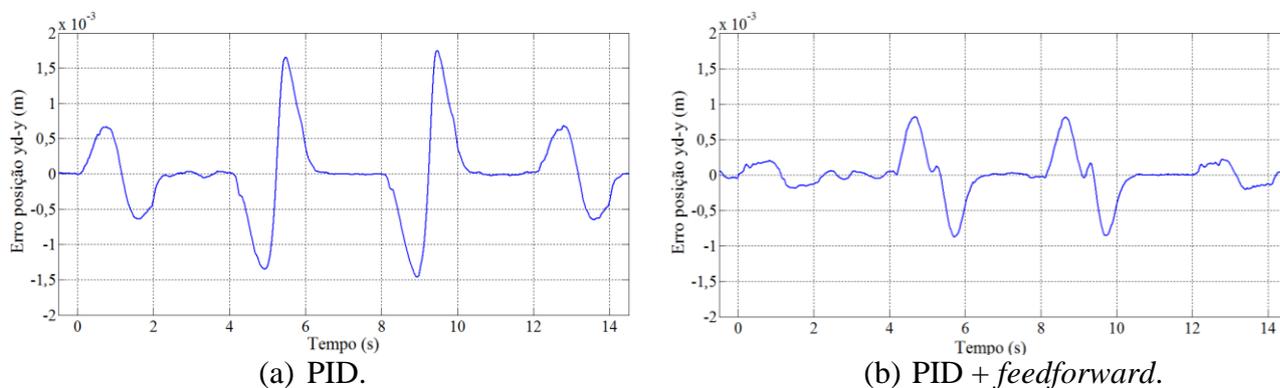


Figura 5.5 - Experimentos a 40 °C PID e PID + f. (trajetória polinomial) : erros de posição.

Por meio da inspeção das figuras anteriores pode-se perceber a diminuição do erro de seguimento de posição do controlador PID conforme a diminuição da temperatura do fluido hidráulico. Uma vez que os ganhos do controlador são mantidos iguais em todos os experimentos, esse comportamento pode ser atribuído a diminuição da viscosidade do fluido hidráulico devido ao aumento da temperatura, o que afeta diretamente vários parâmetros do modelo tais como perdas de carga, coeficiente da válvula e atrito, que, de acordo com Merrit, 1967, e Watton, 2012, são dependentes das condições do fluido hidráulico. Observa-se

também que a introdução da parcela *feedforward* reduz bastante os erros de seguimento de trajetória do controlador PID.

A Figura 5.6 ilustra a influência da variação da temperatura do fluido hidráulico no erro de seguimento de posição apresentado pelo controlador PID na trajetória polinomial.

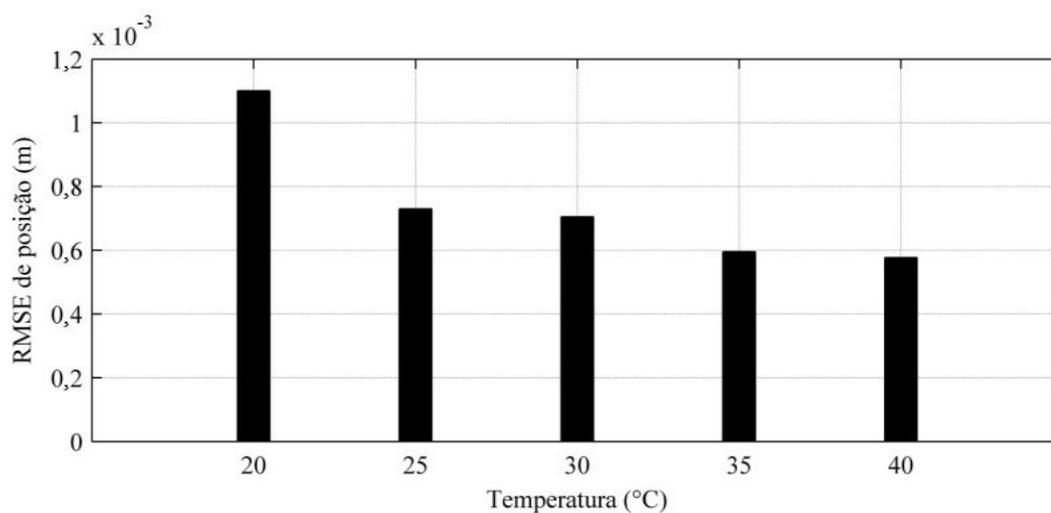


Figura 5.6 – Variação de Erro de posição (RMSE) com a temperatura do fluido hidráulico para o controlador PID aplicado à trajetória polinomial.

As figuras 5.7 e 5.8 ilustram os resultados das trajetórias de posição e do sinal de controle da válvula quando no seguimento da trajetória senoidal em uma temperatura de 40 °C do fluido hidráulico.

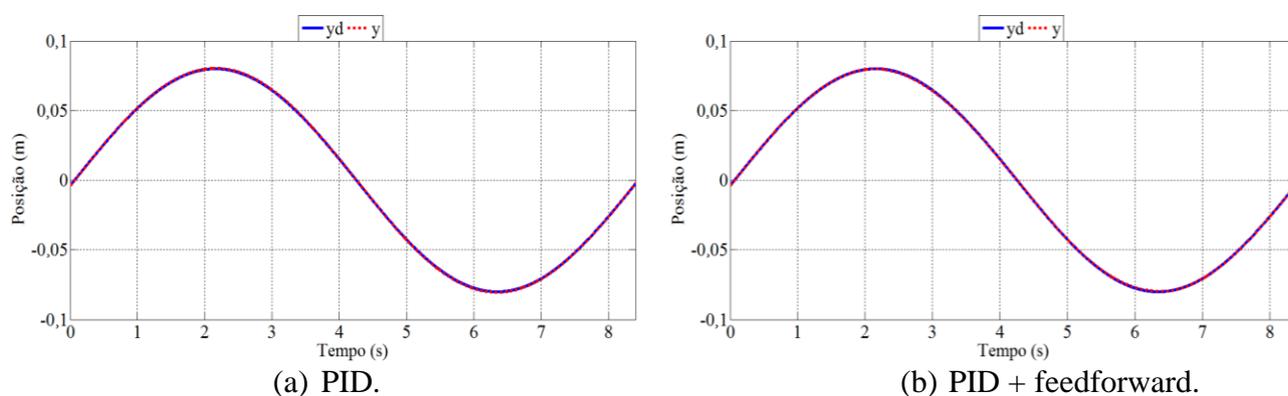
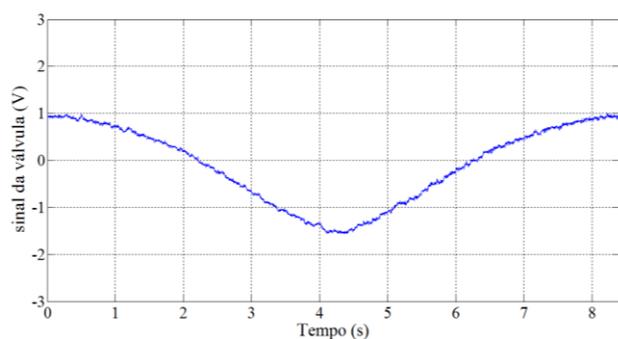
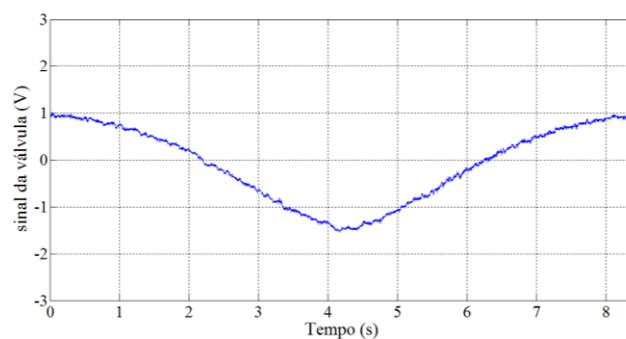


Figura 5.7 - Experimentos a 40 °C PID e PID + f. (trajetória senoidal): posição.



(a) PID: erro de posição.

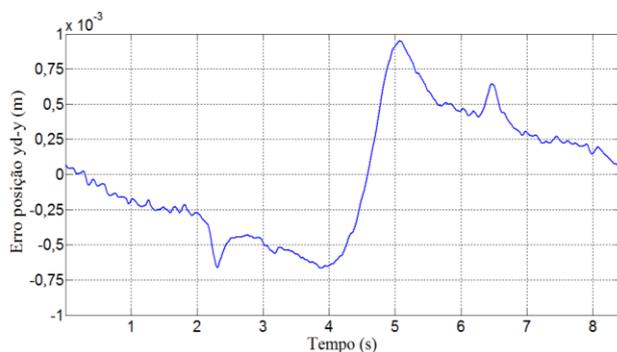


(b) PID + feedforward: erro de posição.

Figura 5.8 - Experimentos a 40 °C PID e PID + f. (trajetória senoidal): sinal de controle.

Observa-se, por meio das figuras, que o sinal de controle da trajetória senoidal possui valores máximos menores que o da trajetória polinomial devido a menor vazão máxima necessária para o seguimento da trajetória de posição senoidal, que possui menor velocidade máxima do pistão. Assim como na trajetória polinomial, observa-se igualmente a ausência de ruídos de alta frequência no sinal de controle.

As figuras 5.9 a 5.11 ilustram os erros de seguimento de posição para a trajetória senoidal.



(a) PID: erro de posição.

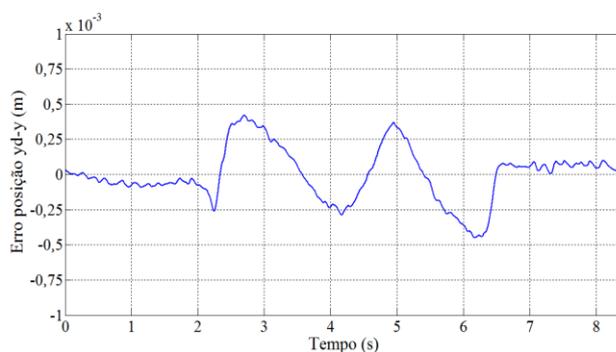
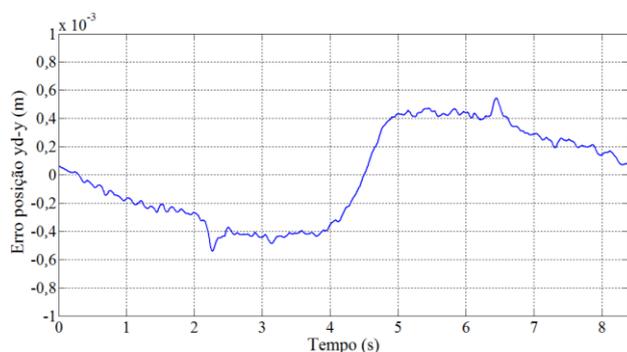
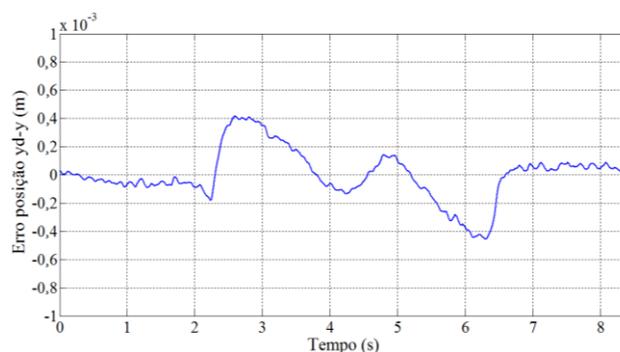
(b) PID + *feedforward*: erro de posição.

Figura 5.9 - Experimentos a 20 °C PID e PID + f. (trajetória senoidal): erros de posição.



(a) PID: erro de posição.



(b) PID + feedforward: erro de posição .

Figura 5.10 - Experimentos a 30 °C PID e PID + f. (trajetória senoidal): erros de posição.

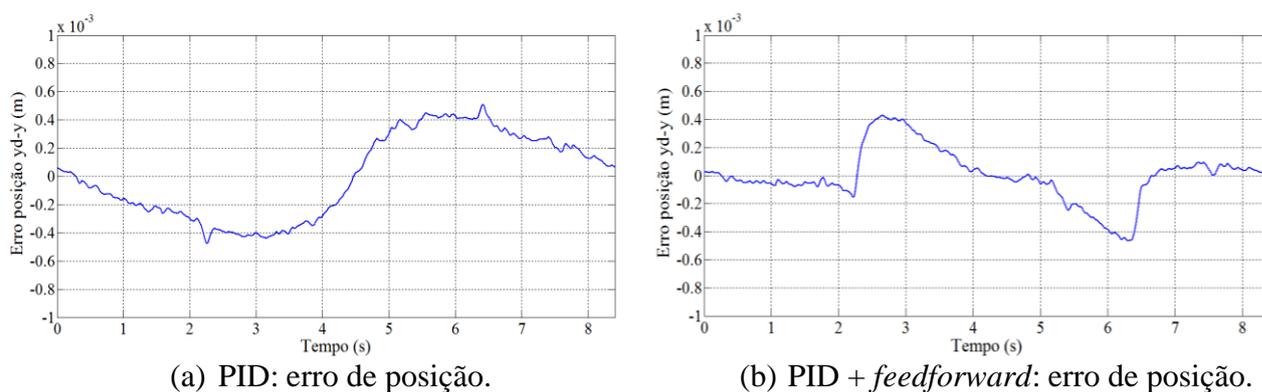


Figura 5.11 - Experimentos a 40 °C PID e PID + f. (trajetória senoidal) : erros de posição.

Confirma-se, por meio das figuras 5.3 a 5.5 e 5.9 a 5.11, que a introdução da parcela *feedforward*, em conjunto com o controlador PID, melhora a resposta do erro de posição. Esse resultado é confirmado, mais adiante, por meio das tabelas 5.2 e 5.3, aplicando a raiz do erro quadrático médio (Equação (4.29)) aos resultados experimentais obtidos. Por meio dessas tabelas, confirma-se também que erro do seguimento de posição para o controlador PID+*feedforward* é menor com o fluido hidráulico a 30 °C, indicando que a sintonia dos ganhos da parcela *feedforward* foi otimizada para essa temperatura, mudando o desempenho à medida que a mesma é alterada.

A Figura 5.12 ilustra a influência da variação da temperatura do fluido hidráulico no erro de seguimento de posição apresentado pelo controlador PID na trajetória senoidal.

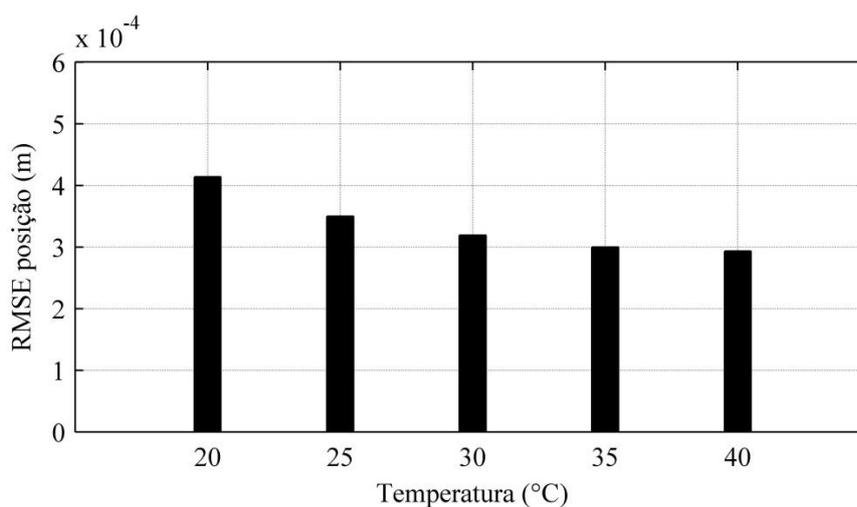


Figura 5.12 – Variação de Erro de posição (RMSE) com a temperatura do fluido hidráulico para o controlador PID aplicado à trajetória senoidal.

5.3. Controladores em Cascata fixo.

Nesta seção, são inicialmente apresentados os resultados do controlador em cascata analítico, descrito por meio das equações (4.1) e (4.10), com a compensação da força de atrito modificada realizada utilizando a Equação (4.17), considerando $B = 3.600$. Posteriormente, são apresentados os resultados dos controladores em cascata utilizando as modificações descritas nas seções 4.2 e 4.3. Os ganhos para os controladores foram sintonizados procurando minimizar o erro de posição sem excitar os modos oscilatórios do sistema, que podem provocar vibrações indesejadas no pistão. Procurou-se obter respostas não vibratórias até a temperatura de 45 °C para o fluido hidráulico. Os valores utilizados para os ganhos estão apresentados na Tabela 5.1. A metodologia de sintonia dos ganhos seguiu as diretrizes descritas em Cunha, 2001.

Tabela 5.1 - Ganhos dos controladores em cascata.

K_p	λ	K_d
200	150	5.000

A Figura 5.13 apresenta a resposta de posição, pressão de suprimento, pressões P_A e P_B medidas por meio dos sensores conectados as portas 1 e 2 do cilindro hidráulico e o erro de seguimento de força referentes ao seguimento da trajetória polinomial, informações consideradas suficientes para observar o comportamento das pressões e da força hidráulica do sistema em malha fechada. Esses resultados são apresentados somente para a maior temperatura do fluido hidráulico medida nos experimentos, no caso, 40 °C. Nas demais temperaturas do fluido hidráulico, o erro de força é semelhante, acompanhando as variações do erro de posição. São observados comportamentos semelhantes àqueles visualizados na Figura 5.13 para as demais curvas quando em outras temperaturas do fluido hidráulico.

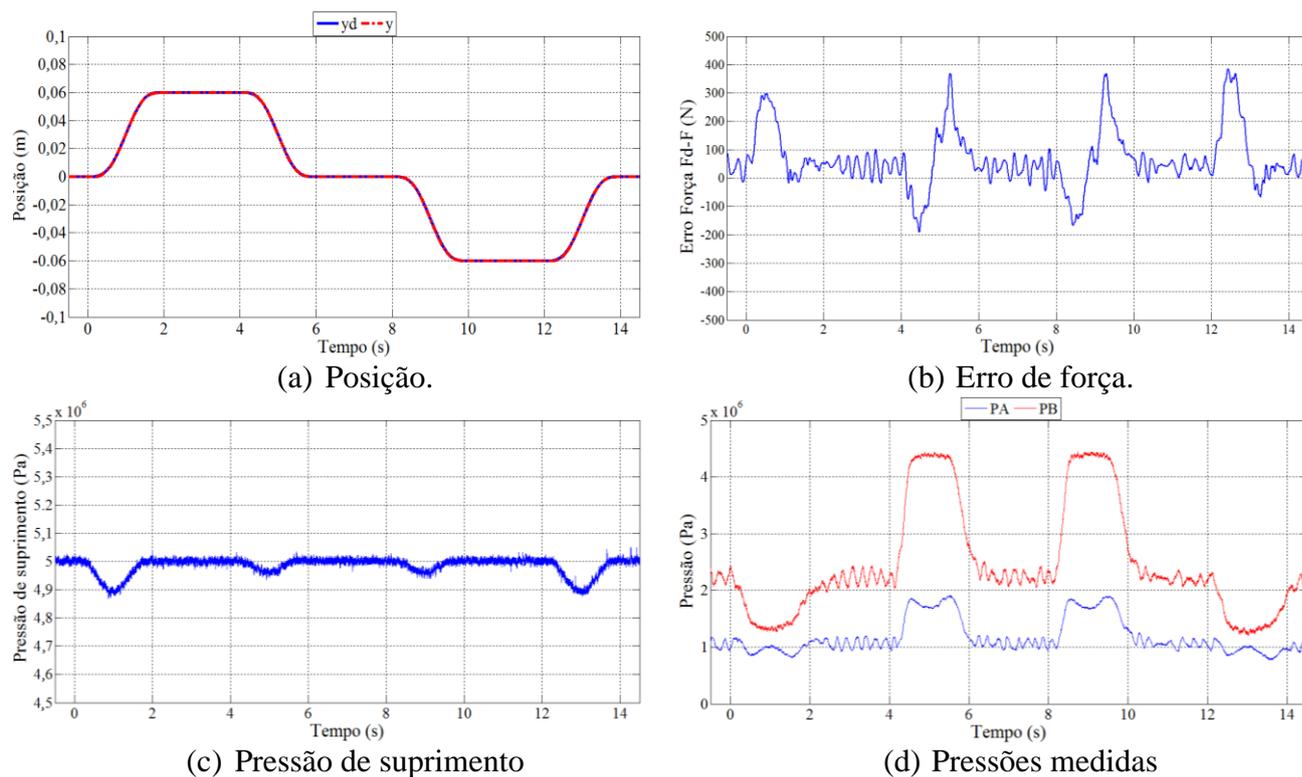
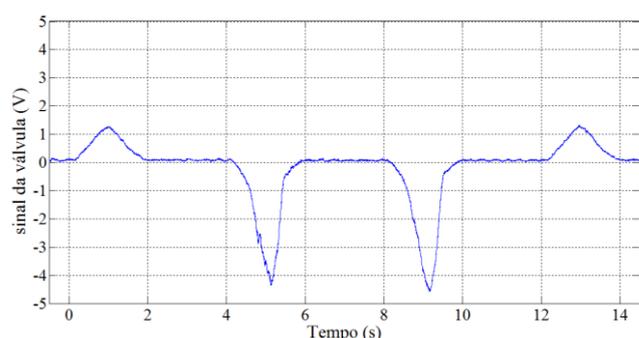


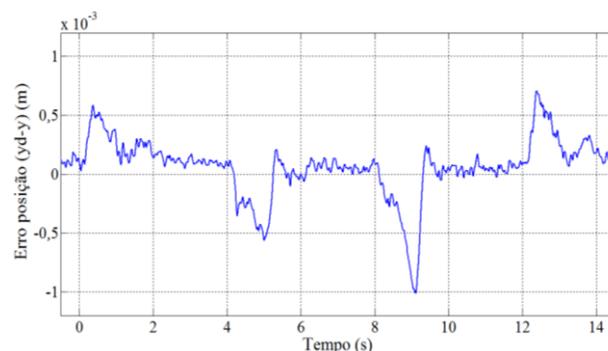
Figura 5.13 - Experimentos a 40 °C para o cascata analítico na trajetória polinomial.

Observa-se variação de 0,1 MPa na pressão de suprimento no sentido positivo do deslocamento e 0,025 Mpa no sentido negativo. Pequenas oscilações no erro de força também são visualizadas na Figura 5.13b quando o pistão encontra-se em regulação. Essas oscilações não proporcionam a percepção de vibrações no pistão em repouso.

As figuras 5.14 a 5.16 apresentam o erro de seguimento de posição e o respectivo sinal de controle para o seguimento de posição na trajetória polinomial, informações consideradas suficientes para a avaliação da resposta do erro de posição e do ruído e saturação do sinal de controle.

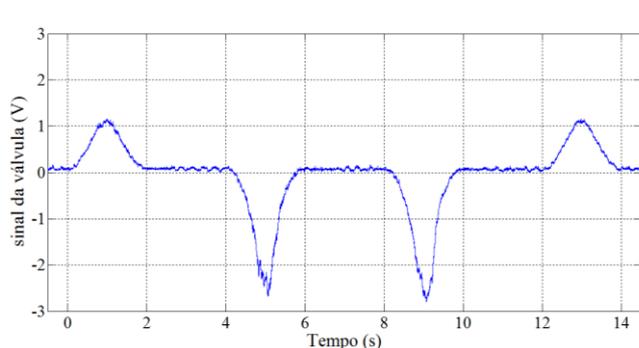


(a) Sinal de controle.

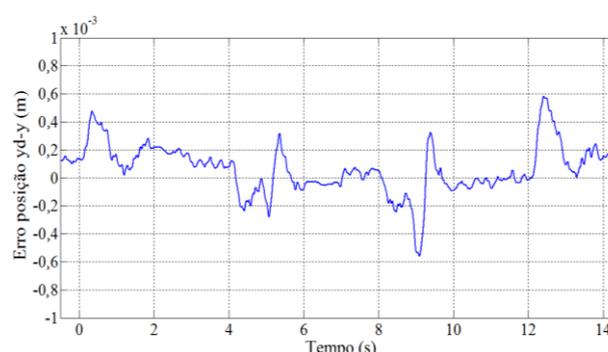


(b) Erro de posição.

Figura 5.14 - Experimentos a 20 °C para o cascata analítico na trajetória polinomial: sinal de controle e erro de seguimento de posição.

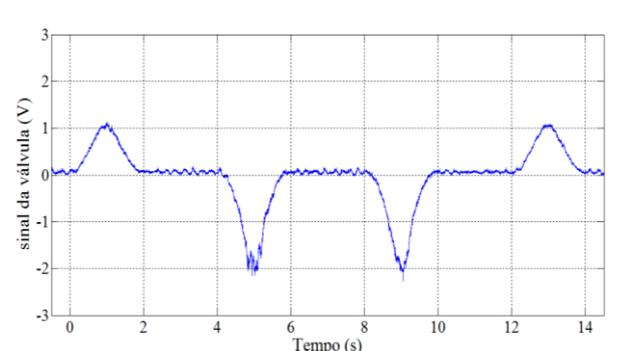


(a) Sinal de controle.

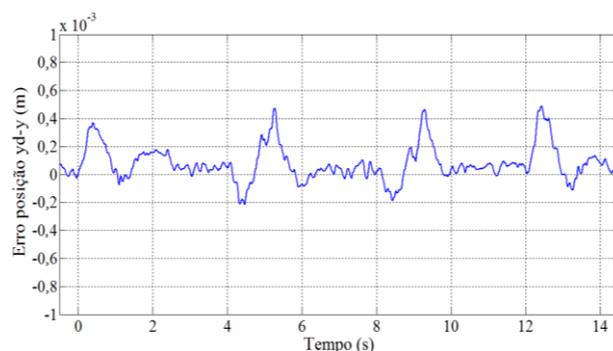


(b) Erro de posição.

Figura 5.15 - Experimentos a 30 °C para o cascata analítico na trajetória polinomial: sinal de controle e erro de seguimento de posição.



(a) Sinal da controle.



(b) Erro de posição.

Figura 5.16 - Experimentos a 40 °C para o cascata analítico na trajetória polinomial: sinal de controle e erro de seguimento de posição.

Observa-se por meio das figuras que o sinal de controle necessário para o seguimento da trajetória diminui, principalmente no sentido negativo, com o aumento da temperatura do fluido hidráulico. Observou-se o mesmo comportamento para os controladores lineares. Atribui-se esse comportamento às variações paramétricas da planta inerentes a variação de

viscosidade do fluido hidráulico com a temperatura. O erro de seguimento de posição também diminui com o aumento da temperatura do fluido hidráulico, porém, nesse caso, também ocorre influência do modelo utilizado no controlador em cascata.

A Figura 5.17 apresenta a resposta de posição, pressão de suprimento, pressões P_A e P_B medidas por meio dos sensores conectados as portas 1 e 2 do cilindro hidráulico e o erro de seguimento de força referentes ao seguimento da trajetória senoidal na temperatura de 40 °C medida para o fluido hidráulico.

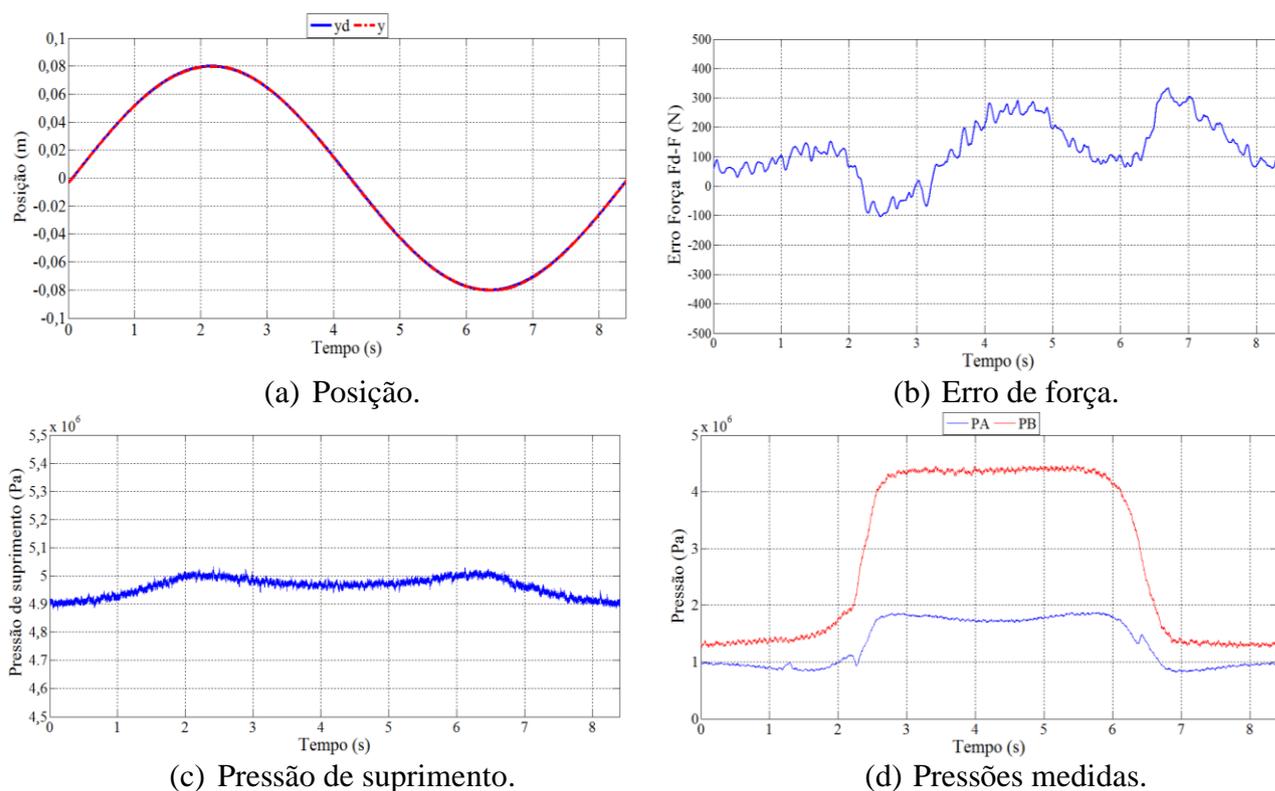
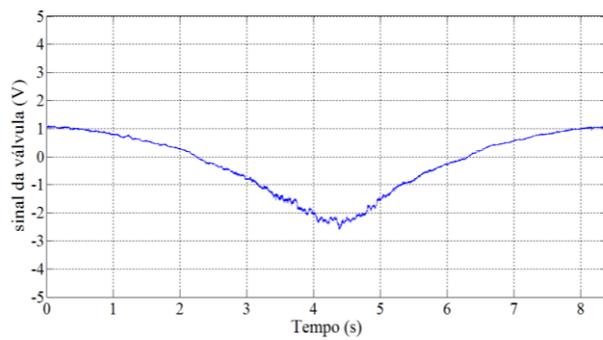


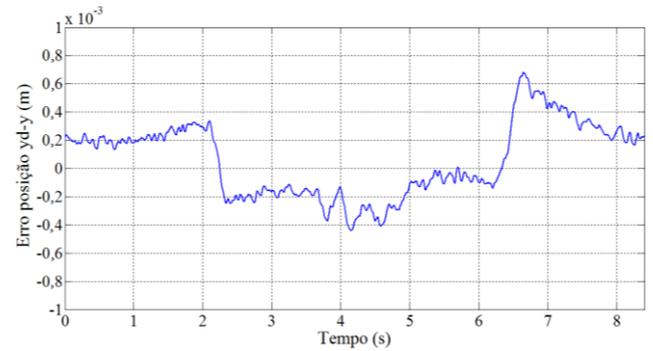
Figura 5.17 - Experimentos a 40 °C para o cascata analítico na trajetória senoidal.

Observa-se por meio das figuras que os limites das variações na pressão de suprimento na trajetória senoidal são semelhantes àqueles observados na trajetória polinomial.

As figuras 5.18 a 5.20 apresentam o erro de seguimento de posição e o respectivo sinal de controle para o seguimento de posição da trajetória senoidal.

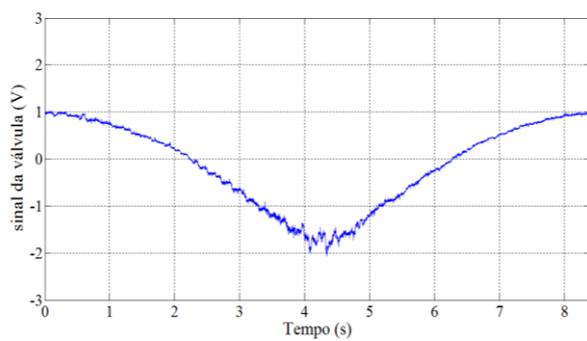


(a) Sinal de controle

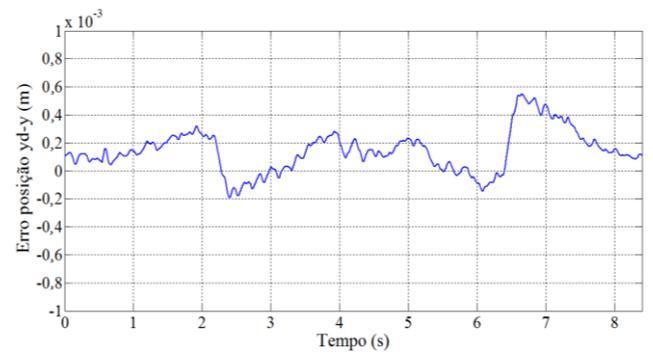


(b) Erro de posição

Figura 5.18 - Experimentos a 20 °C para o cascata analítico na trajetória senoidal: sinal de controle e erro de seguimento de posição.

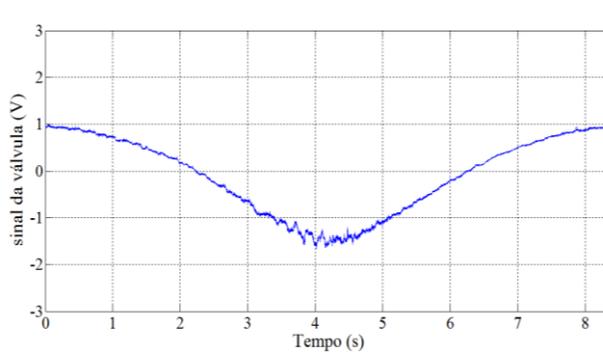


(a) Sinal de controle.

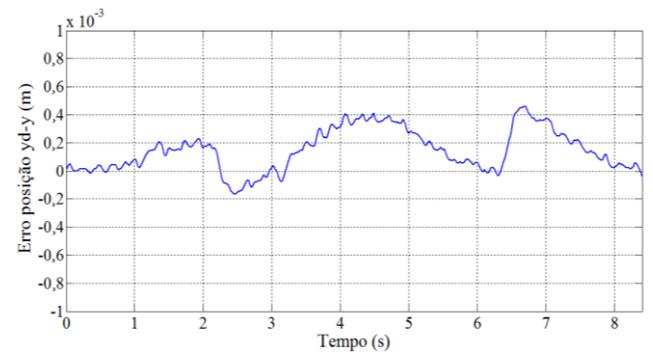


(b) Erro de posição.

Figura 5.19 - Experimentos a 30 °C para o cascata analítico na trajetória polinomial: sinal de controle e erro de seguimento de posição.



(a) Sinal de controle.



(b) Erro de posição.

Figura 5.20 - Experimentos a 40 °C para o cascata analítico na trajetória polinomial: sinal de controle e erro de seguimento de posição.

A Tabela 5.2 apresenta a aplicação do RMSE (Equação (4.29)) nas curvas apresentadas nas figuras 5.3 a 5.5 e 5.14b a 5.16b, e também o valor máximo absoluto do erro para cada uma dessas curvas.

Tabela 5.2 – Comparação de erro entre os controladores lineares e o controlador em cascata analítico para a trajetória polinomial.

temperatura (°C)	PID		PID+FF		Cascata analítico	
	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)
20	11,0	47,6	3,61	16,7	2,47	9,8
30	7,05	25,6	2,53	7,8	1,45	5,7
40	5,77	17,4	2,81	8,6	1,30	4,8

A Tabela 5.3 apresenta a aplicação do RMSE (Equação (4.29)) nas curvas apresentadas nas figuras 5.9 a 5.11 e 5.18b a 5.20b, e também o valor máximo absoluto do erro para cada uma dessas curvas.

Tabela 5.3 – Comparação de erro entre os controladores lineares e o controlador em cascata analítico para a trajetória senoidal.

temperatura (°C)	PID		PID+FF		Cascata analítico	
	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)
20	4,20	9,4	1,83	4,2	2,67	6,8
30	3,12	5,4	1,76	4,5	1,63	5,4
40	2,88	5,1	1,83	4,5	1,80	4,5

Pode-se observar, por meio das figuras apresentadas e pelos resultados apresentados nas tabelas 5.2 e 5.3, que o controlador em cascata analítico melhora o desempenho do erro de posição em relação ao controlador PID, confirmando os resultados de trabalhos como Cunha, 2001, e Pereira, 2006. Embora o controlador em cascata analítico apresente melhores

resultados, o controlador *PID+feedforward*, em algumas situações, como na trajetória senoidal, mostra um desempenho semelhante ao do controlador em cascata, o que já havia sido mostrado nos resultados de Pereira, 2006, e que justifica a utilização desse controlador em aplicações de alta precisão [Johnson, 2011].

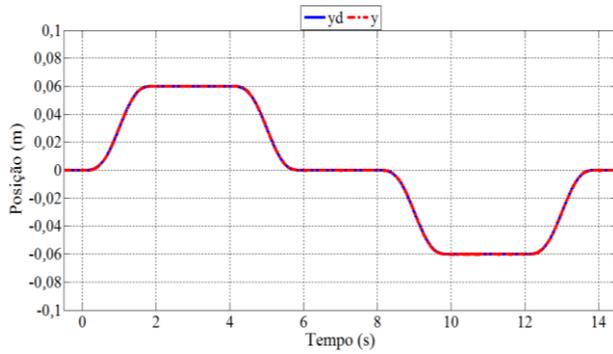
Os ensaios experimentais para os controladores em cascata utilizando redes neurais são apresentados na sequência. Os resultados inicialmente apresentados utilizam o controlador em cascata com mapa inverso neural com compensação da temperatura do fluido hidráulico e a compensação da força de atrito modificada, também com compensação da temperatura do fluido hidráulico.

Para aplicações não adaptativas, assim como Machado, 2003, e Gervini, 2014, adota-se para a compensação da força de atrito modificada uma rede neural com camada de saída não linear, descrita por meio da Equação (5.3). Segundo Masters, 1993, uma rede neural com camada de saída não linear apresenta melhor desempenho mediante entradas que apresentam ruído. A rede neural da Equação (5.3) é treinada e validada de maneira semelhante à rede neural descrita por meio da Equação (4.33), que é utilizada quando os pesos da camada de saída são adaptados *on-line*.

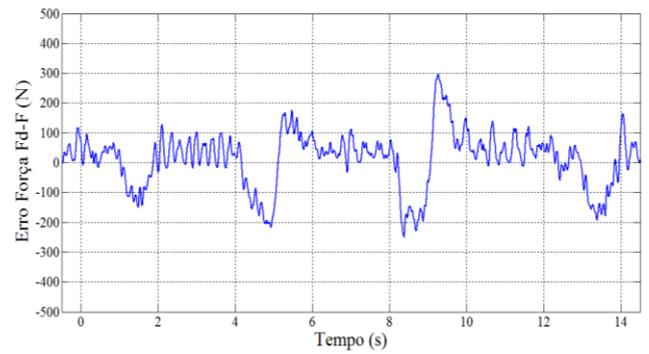
$$\Theta(\dot{y}, P_A, P_B, T) = \Psi_{3r}^* \left(\mathbf{W}_{3r}^T \Psi_{2r}^* \left(\mathbf{W}_{2r}^T \Psi_{1r}^* \left(\mathbf{W}_{1r}^T \mathbf{x}_{0r}^* \right) \right) \right), \quad (5.3)$$

onde $\mathbf{W}_{3r} \in \mathfrak{R}^{11 \times 1}$ é o vetor fixo dos pesos da saída da rede. A matriz $\mathbf{W}_{1r} \in \mathfrak{R}^{5 \times 10}$ é utilizada nos pesos de entrada. A rede neural possui 2 camadas ocultas e tem uma matriz de pesos $\mathbf{W}_{2r} \in \mathfrak{R}^{11 \times 10}$. O vetor das entradas da rede é $\mathbf{x}_{0r} = [\dot{y} \quad P_A \quad P_B \quad T]^T$. As funções não lineares Ψ representam a função logística sigmoideal. A saída da rede neural é normalizada para forças entre -500 N e 500 N.

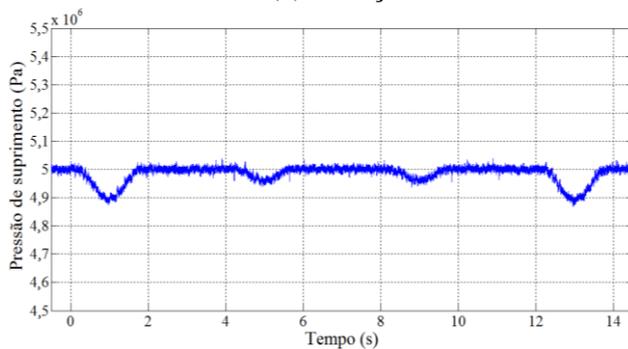
A Figura 5.21 apresenta a resposta de posição, pressão de suprimento, pressões P_A e P_B medidas por meio dos sensores conectados as portas 1 e 2 do cilindro hidráulico e o erro de seguimento de força referentes ao seguimento da trajetória polinomial na temperatura de 40 °C medida para o fluido hidráulico.



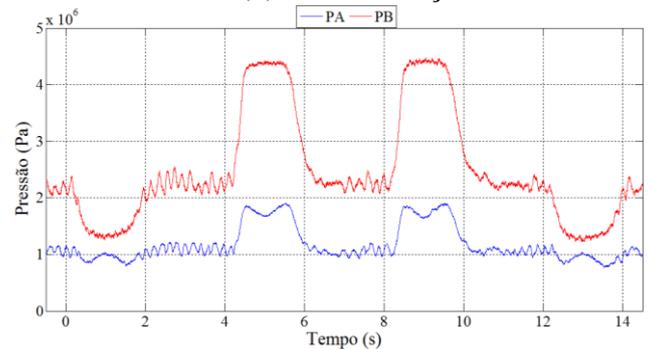
(a) Posição.



(b) Erro de força.



(c) Pressão de suprimento

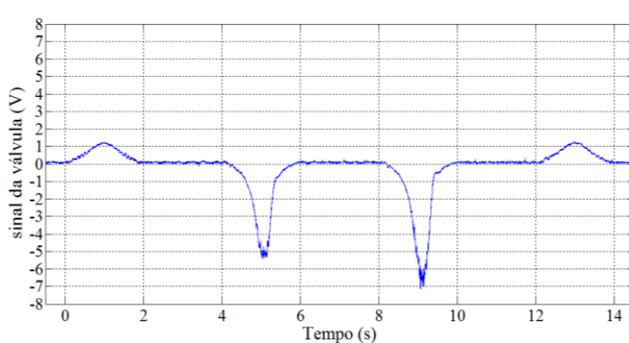


(d) Pressões medidas

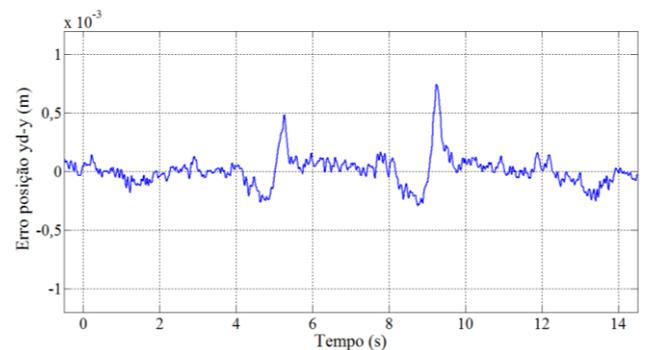
Figura 5.21 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória polinomial.

Observa-se por meio da Figura 5.21 que as curvas são semelhantes aquelas da Figura 5.13, porém com valores máximos menores para o erro de força.

As figuras 5.22 a 5.24 apresentam o erro de seguimento de posição e o respectivo sinal de controle para o seguimento de posição da trajetória polinomial.

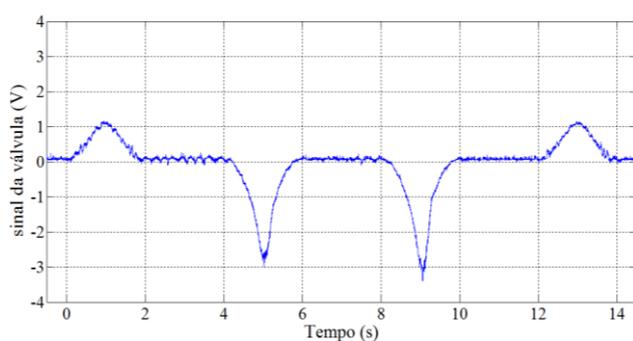


(a) Sinal da válvula

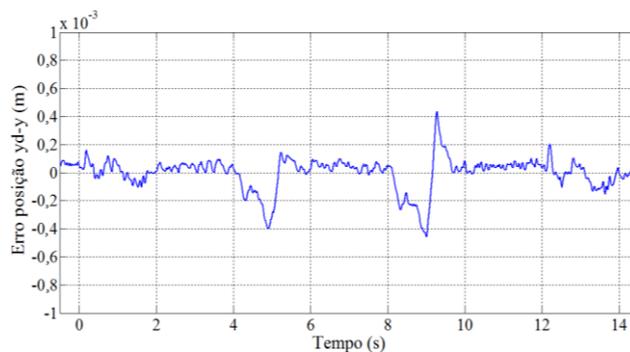


(b) Erro de posição

Figura 5.22 - Experimentos a 20 °C Para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória polinomial.

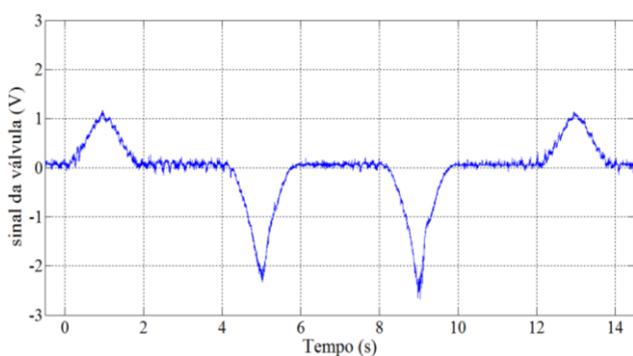


(a) Sinal da válvula

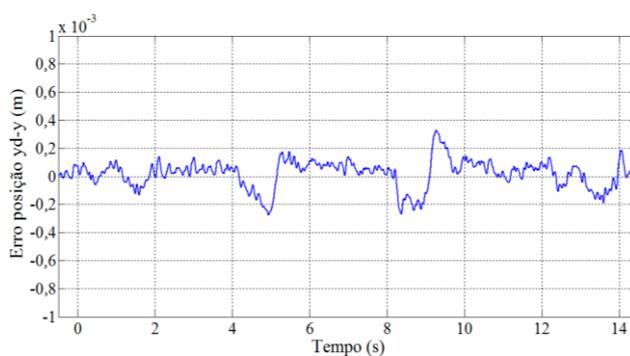


(b) Erro de posição

Figura 5.23 - Experimentos a 30 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória polinomial.



(a) Sinal da válvula



(b) Erro de posição

Figura 5.24 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória polinomial.

Observa-se por meio das figuras a influência do modelo neural nos resultados de erro de seguimento de posição. Há uma redução dos valores máximos absolutos do erro observada nas figuras 5.22b a 5.24b em relação as figuras 5.18b a 5.20b que podem ser atribuídas ao modelo neural. Considera-se não haver um aumento significativo em relação ao controlador em cascata analítico do ruído de alta frequência no sinal de controle.

A Figura 5.25 apresenta a resposta de posição, pressão de suprimento, pressões P_A e P_B medidas por meio dos sensores conectados as portas 1 e 2 do cilindro hidráulico e o erro de seguimento de força referentes ao seguimento da trajetória senoidal na temperatura de 40 °C medida para o fluido hidráulico.

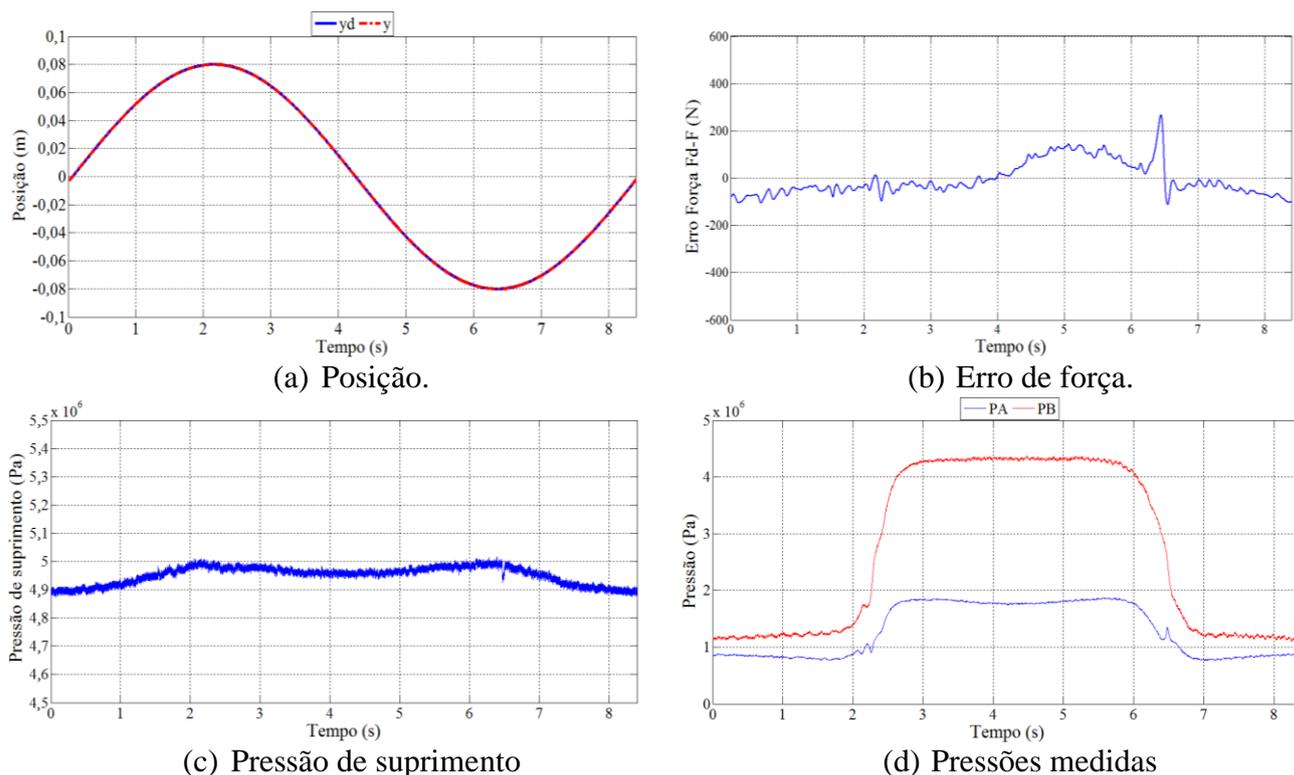


Figura 5.25 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória senoidal.

Observa-se por meio da Figura 5.25b o efeito da mudança de sentido da velocidade na trajetória senoidal. O modelo neural proporciona uma diminuição do erro de força, porém, no ponto de mudança de velocidade, percebe-se a variação mais brusca do erro de força devido à ação da compensação do atrito. Essa variação, porém, não proporciona efeitos prejudiciais que possam ser percebidos na posição do pistão.

As figuras 5.26 a 5.28 apresentam o erro de seguimento de posição e o respectivo sinal de controle para o seguimento de posição da trajetória senoidal.

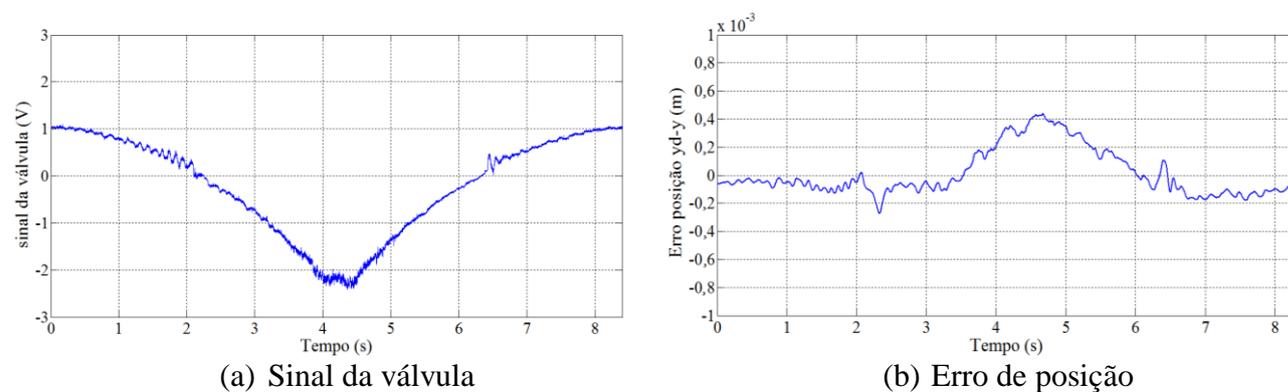
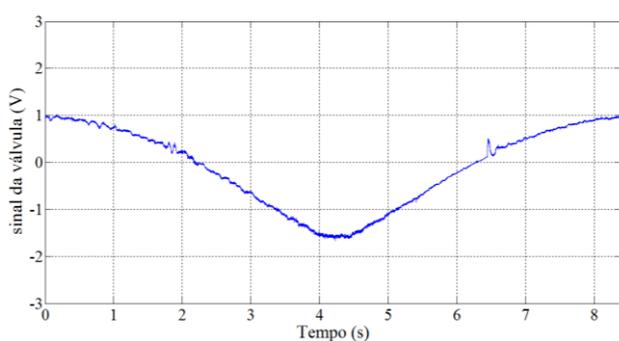
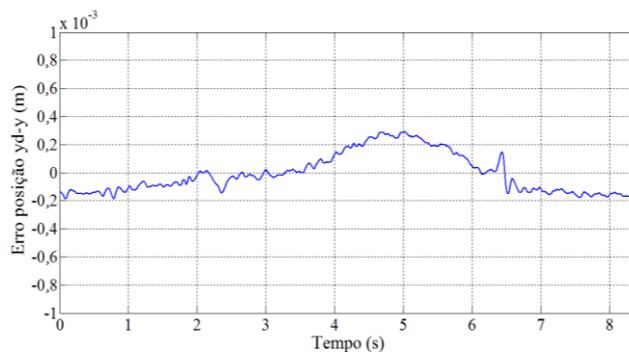


Figura 5.26 - Experimentos a 20 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória senoidal.

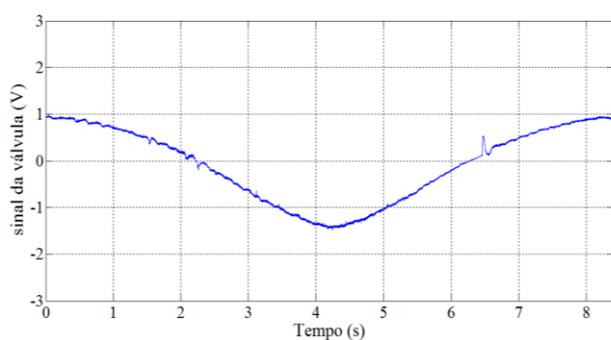


(a) Sinal da válvula

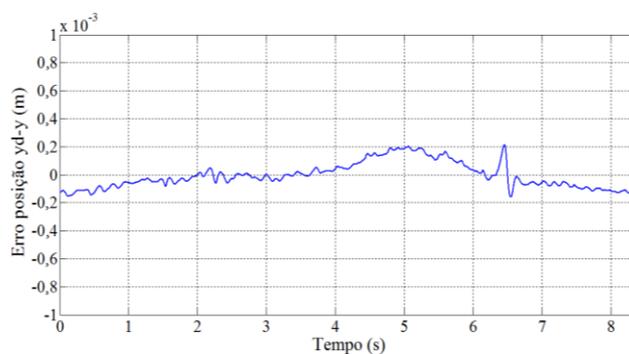


(b) Erro de posição

Figura 5.27 - Experimentos a 30 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória senoidal.



(a) Sinal da válvula



(b) Erro de posição

Figura 5.28 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural na trajetória senoidal.

Observa-se por meio das figuras uma redução no valor máximo do erro em relação ao controlador em cascata analítico, de forma semelhante ao destacado para a trajetória polinomial. Pode-se perceber também menor variação entre as curvas de erro de posição nas diferentes temperaturas do fluido hidráulico em relação as mesmas respostas oferecidas pelo controlador em cascata analítico.

A Tabela 5.4 apresenta a aplicação do RMSE (Equação (4.29)) nas curvas apresentadas nas figuras 5.15b a 5.16b e 5.22b a 5.24b, e também o valor máximo absoluto do erro para cada uma dessas curvas.

Tabela 5.4 – Comparação de erro entre os controladores em cascata para a trajetória polinomial.

temperatura (°C)	Cascata analítico		Cascata neural mapa inverso+atrito (temperatura)	
	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)
20	2,47	9,8	1,17	7,4
30	1,45	5,7	1,01	4,2
40	1,3	4,8	0,98	3,14

A Tabela 5.5 apresenta a aplicação do RMSE (Equação (4.29)) nas curvas apresentadas nas figuras 5.18b a 5.20b e 5.26b a 5.28b, e também o valor máximo absoluto do erro para cada uma dessas curvas.

Tabela 5.5 – Comparação de erro entre os controladores em cascata para a trajetória senoidal.

temperatura (°C)	Cascata analítico		Cascata neural mapa inverso+atrito (temperatura)	
	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)
20	2,67	6,8	1,40	4,2
30	1,63	5,4	1,17	2,8
40	1,80	4,5	0,83	2,0

As figuras 5.29 a 5.31 ilustram, em um mesmo gráfico, a resposta de erro de posição para os controladores na trajetória polinomial nas diferentes temperaturas do fluido hidráulico.

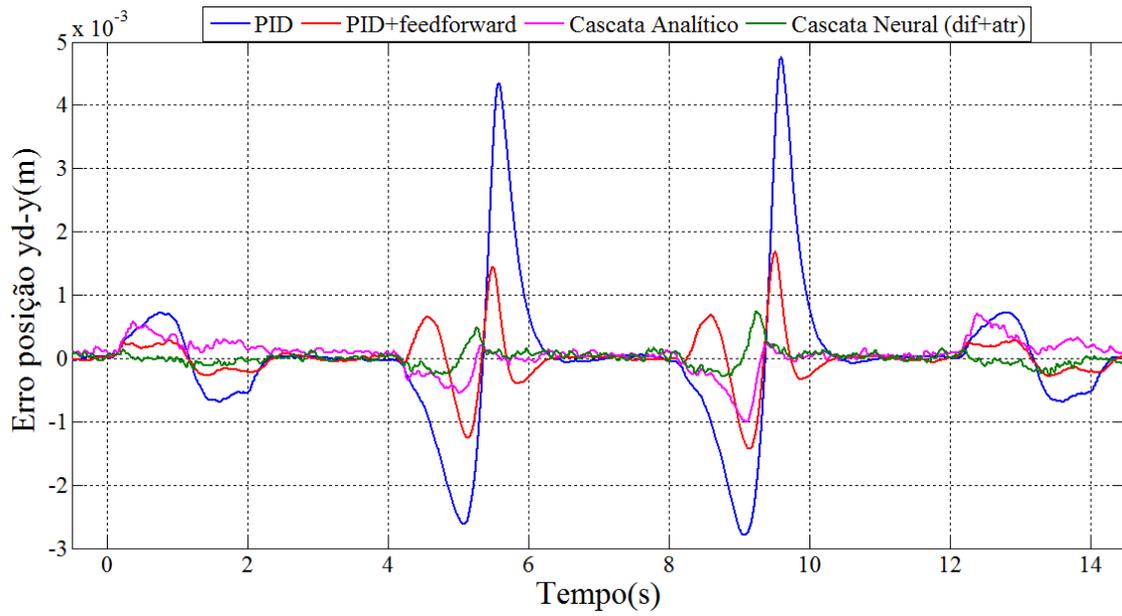


Figura 5.29 - Experimentos a 20 °C : Comparações entre os controladores para a trajetória polinomial.

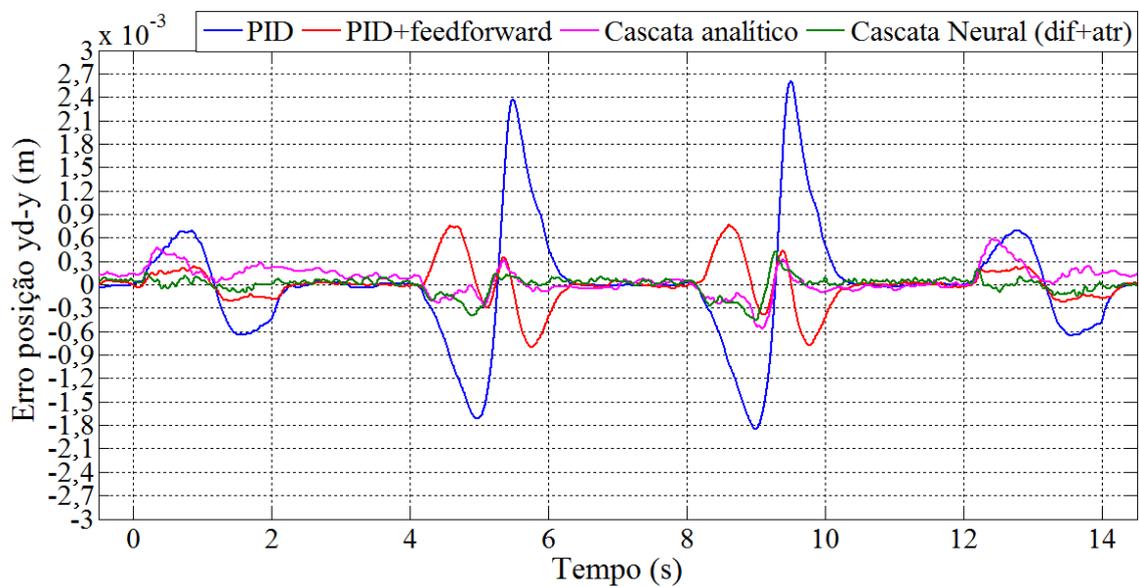


Figura 5.30 - Experimentos a 30 °C : Comparações entre os controladores para a trajetória polinomial.

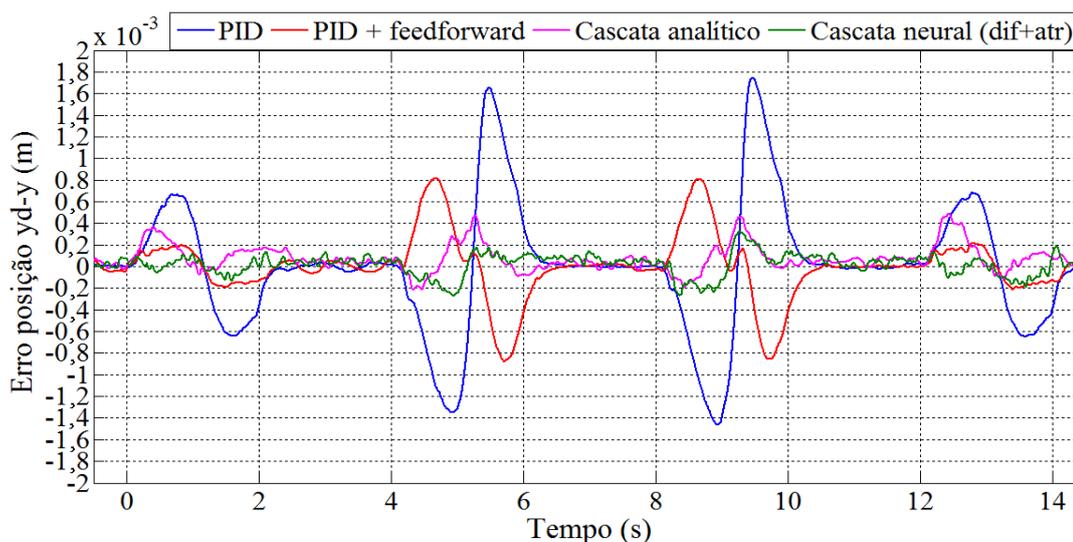


Figura 5.31 - Experimentos a 40 °C : Comparações entre os controladores para a trajetória polinomial.

É possível confirmar pela inspeção das figuras que ocorre um menor erro de posição para o controlador em cascata neural em todas as temperaturas do fluido hidráulico testadas. Há significativa diferença de desempenho entre o controlador PID e os demais controladores.

As figuras 5.32 a 5.34 ilustram, em um mesmo gráfico, a resposta de erro de posição para os controladores na trajetória senoidal nas diferentes temperaturas do fluido hidráulico.

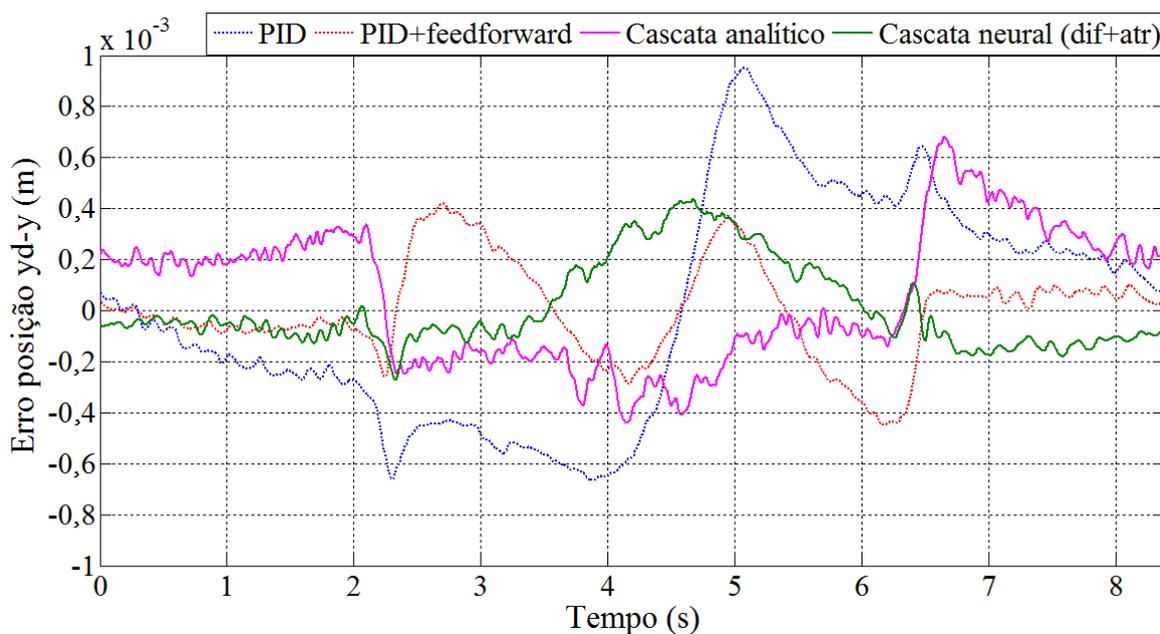


Figura 5.32 - Experimentos a 20 °C : Comparações entre os controladores para a trajetória senoidal.

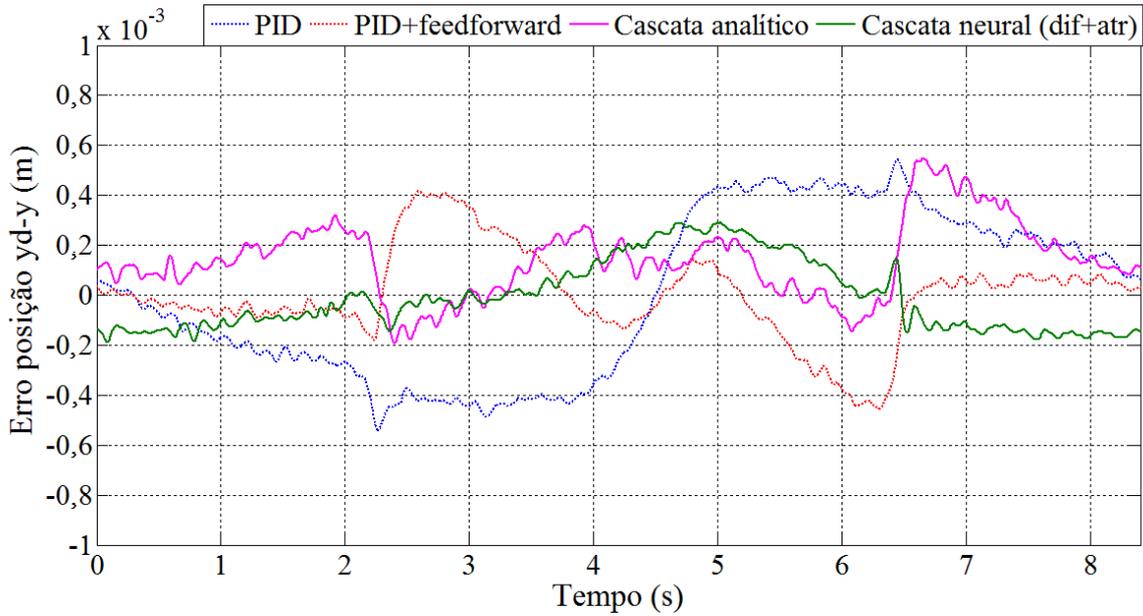


Figura 5.33 - Experimentos a 30 °C : Comparações entre os controladores para a trajetória senoidal.

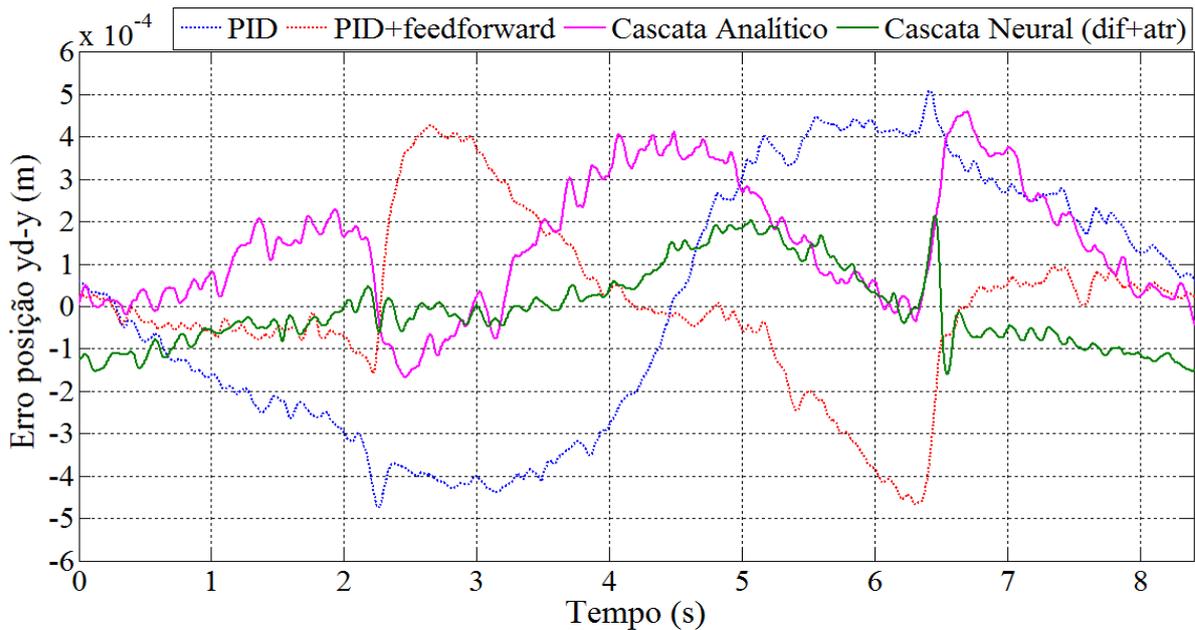


Figura 5.34 - Experimentos a 40 °C : Comparações entre os controladores para a trajetória senoidal.

Para a trajetória senoidal observa-se um comportamento semelhante aquele observado na trajetória polinomial, onde o controlador em cascata neural apresenta visualmente menor erro de posição em todas as temperaturas do fluido hidráulico testadas.

Pode-se, por meio das figuras apresentadas e pelos resultados apresentados por meio das tabelas 5.2, 5.3, 5.4 e 5.5, destacar os seguintes aspectos em relação ao controlador em cascata neural proposto:

- Em relação ao desempenho do erro de posição, o controlador em cascata neural apresenta melhores resultados (no mínimo 32% melhor em relação ao RMSE) que o controlador em cascata analítico e resultados melhores ainda em relação aos controladores lineares;
- Os resultados do controlador em cascata neural possuem menor variação com a temperatura (RMSE) em relação aos demais controladores;
- O controlador em cascata neural não acrescenta ruído significativo no sinal de controle em relação ao controlador em cascata analítico.

Os resultados do controlador em cascata neural evidenciam, portanto, a efetividade da estratégia de controle proposta. O treinamento apenas *off-line* realizado é capaz de proporcionar uma resposta ao erro de posição satisfatória mediante as trajetórias de posição utilizadas, ainda com vantagens em relação à estratégia baseada em um modelo analítico.

Com o objetivo de estudar o efeito da inclusão da temperatura na rede neural que representa o mapa inverso, foram realizados ensaios comparativos com o controlador em cascata neural onde uma função de compensação linear é utilizada para a representação da força de atrito modificada (parcela somente do atrito viscoso) em todos os controladores utilizados. A rede neural que representa o mapa inverso é utilizada com e sem a informação da temperatura. A rede neural que representa o mapa inverso sem a inclusão da temperatura é aquela descrita por meio da Equação (4.30), treinada utilizando medições realizadas com o fluido hidráulico a 30 °C. A outra rede neural que considera o efeito da temperatura é aquela descrita por meio da Equação (4.31). As figuras 5.35 a 5.37 ilustram as comparações do erro de posição medido para os controladores na trajetória polinomial.

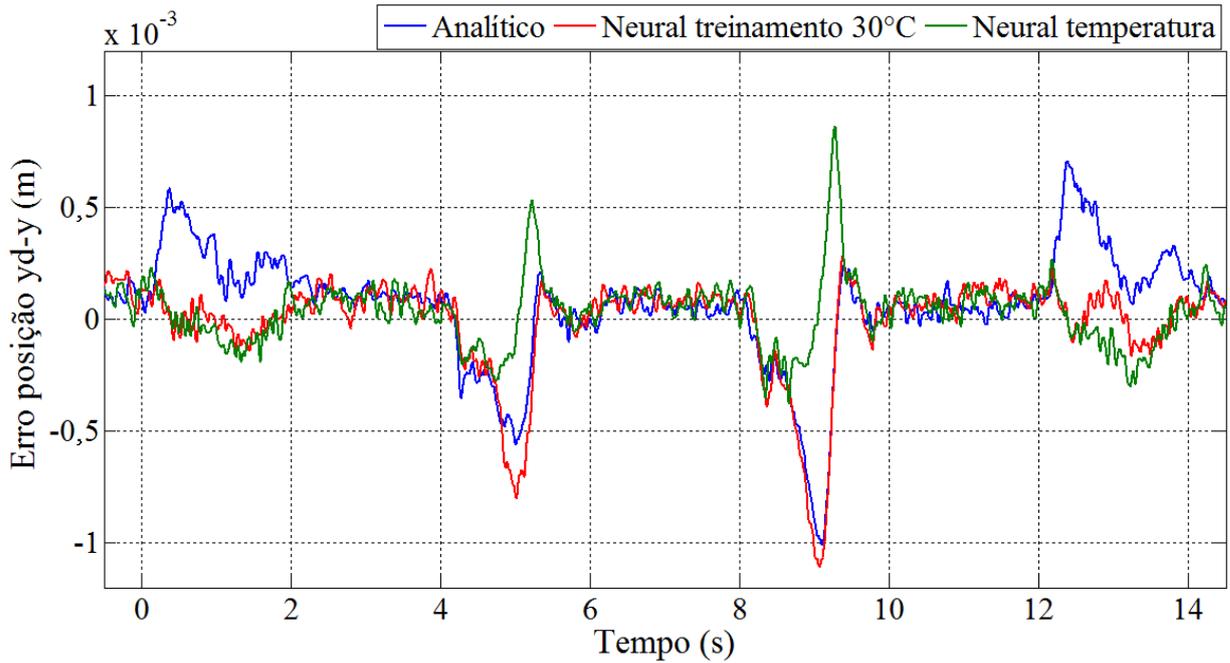


Figura 5.35 – Experimentos a 20 °C: comparações entre as funções de mapa inverso para a trajetória polinomial.

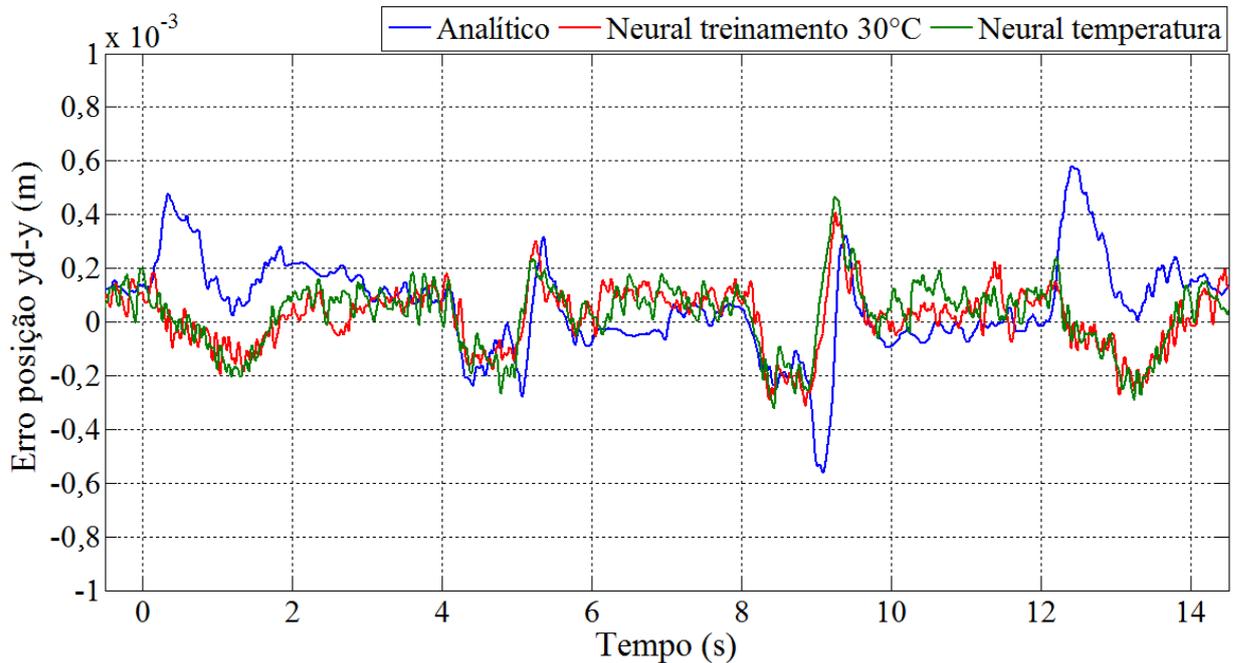


Figura 5.36 – Experimentos a 30 °C: comparações entre as funções de mapa inverso para a trajetória polinomial.

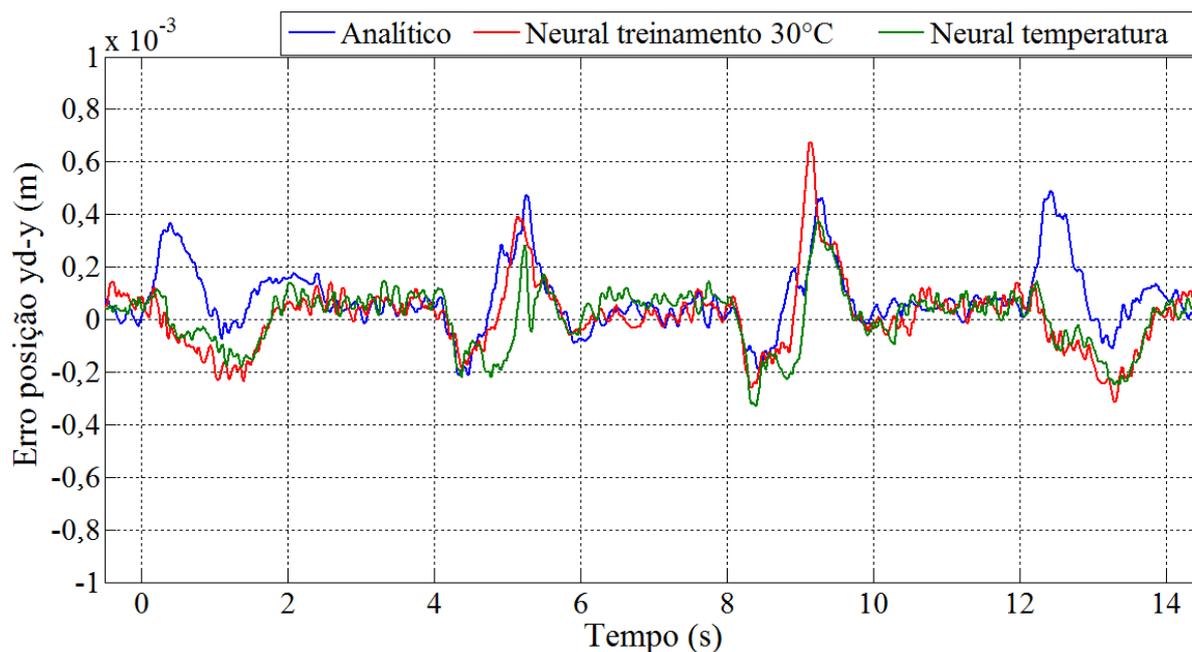


Figura 5.37 – Experimentos a 40 °C: comparações entre as funções de mapa inverso para a trajetória polinomial.

A Tabela 5.6 apresenta a aplicação do RMSE (Equação (4.29)) nas curvas apresentadas nas figuras 5.35 a 5.37, e também o valor máximo absoluto do erro para cada uma dessas curvas.

Tabela 5.6 – Comparação de erro entre as funções de mapa inverso para a trajetória polinomial.

	Analítico		Neural treinamento a 30°C		Neural temperatura	
temperatura (°C)	(RMSE) (10^{-4} m)	maior erro absoluto (10^{-4} m)	(RMSE) (10^{-4} m)	maior erro absoluto (10^{-4} m)	(RMSE) (10^{-4} m)	maior erro absoluto (10^{-4} m)
20	2,47	10,0	2,11	11,0	1,37	8,6
30	1,45	5,6	1,09	3,9	1,17	4,6
40	1,3	4,46	1,34	5,7	1,1	4,0

As figuras 5.38 a 5.40 ilustram as comparações do erro de posição medido para os controladores na trajetória senoidal.

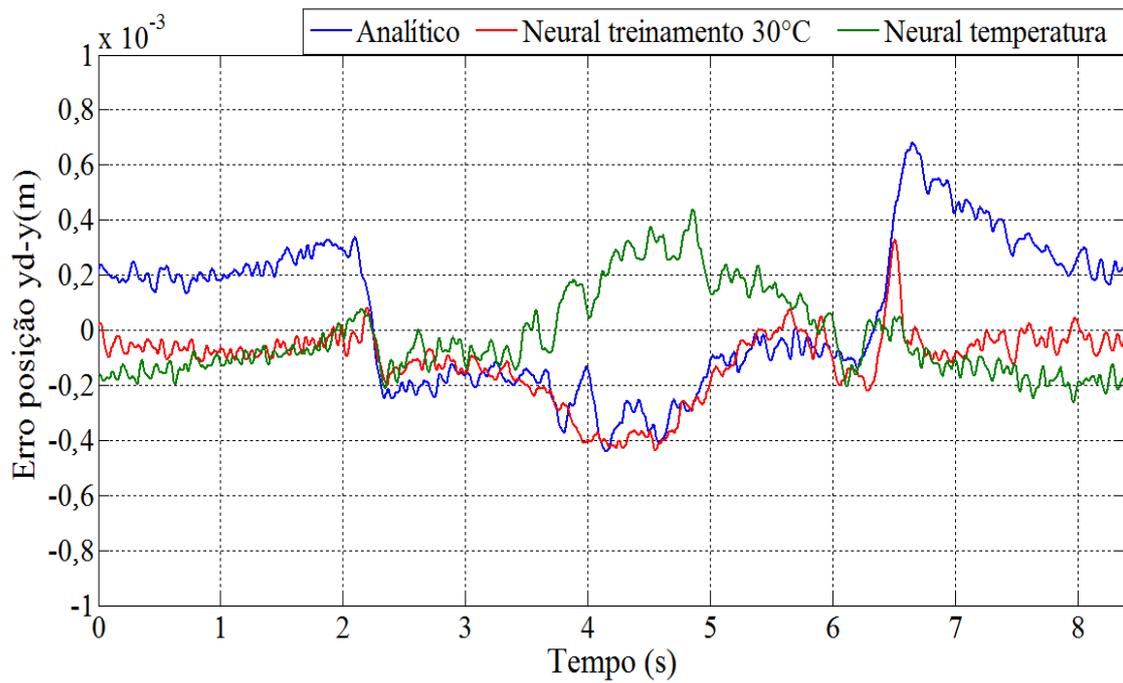


Figura 5.38 – Experimentos a 20 °C: comparações entre as funções de mapa inverso para a trajetória senoidal.

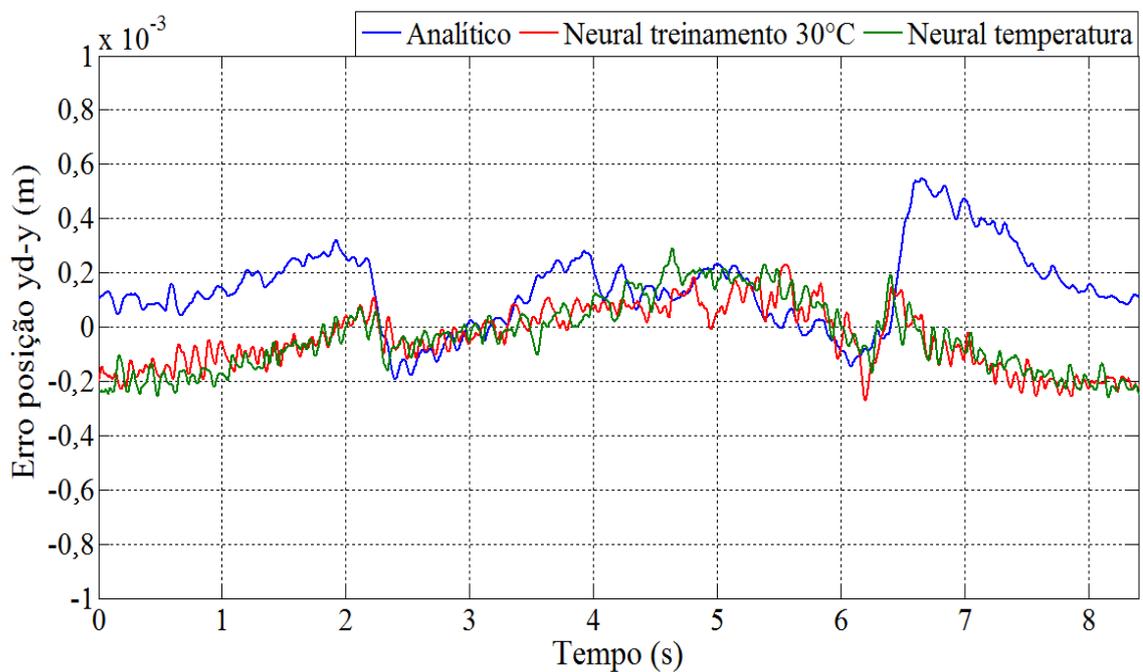


Figura 5.39 – Experimentos a 30 °C: comparações entre as funções de mapa inverso para a trajetória senoidal.

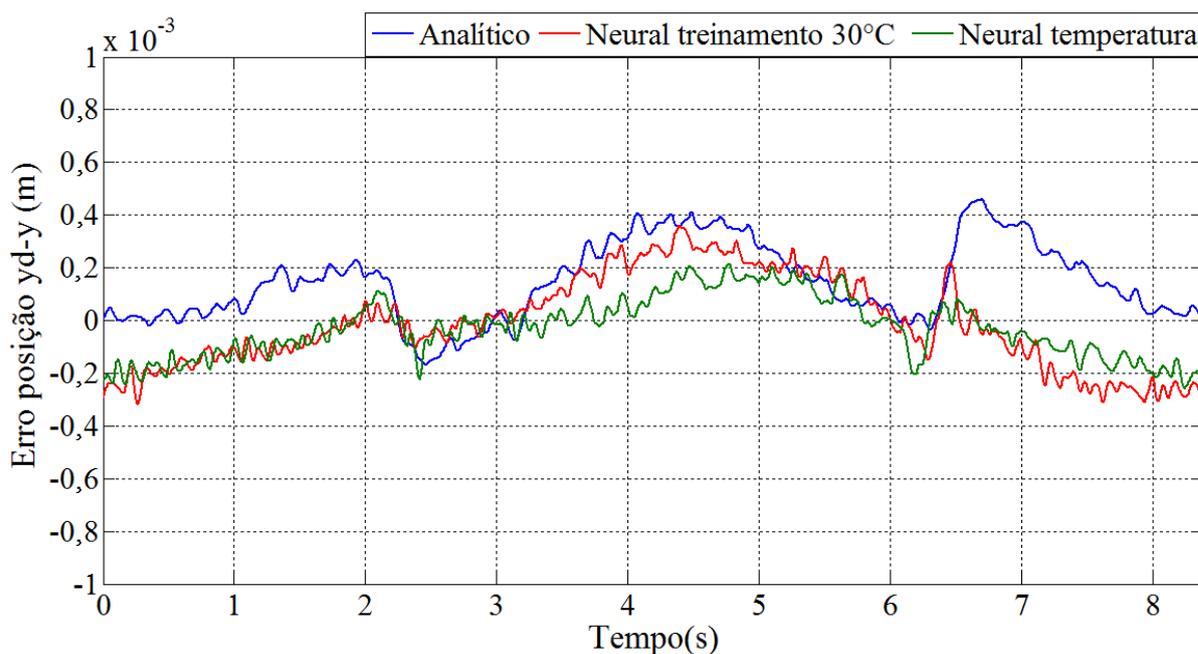


Figura 5.40 – Experimentos a 40 °C: comparações entre as funções de mapa inverso para a trajetória senoidal.

A Tabela 5.7 apresenta a aplicação do RMSE (Equação (4.29)) nas curvas apresentadas nas figuras 5.38 a 5.40, e também o valor máximo absoluto do erro para cada uma dessas curvas.

Tabela 5.7 – Comparação de erro entre as funções de mapa inverso para a trajetória senoidal.

temperatura (°C)	Analítico		Neural treinamento a 30°C		Neural temperatura	
	(RMSE) (10^{-4} m)	maior erro absoluto (10^{-4} m)	(RMSE) (10^{-4} m)	maior erro absoluto (10^{-4} m)	(RMSE) (10^{-4} m)	maior erro absoluto (10^{-4} m)
20	2,67	6,7	1,68	4,3	1,50	4,3
30	1,63	5,4	1,10	2,5	1,26	2,8
40	1,80	4,5	1,68	3,5	1,08	2,4

Por meio das figuras 5.35 a 5.40 e dos resultados de erro, sumarizados por meio das tabelas 5.6 e 5.7, observa-se que os resultados do erro de posição encontram um melhor desempenho quando utilizado o mapa inverso neural considerando a temperatura, tendo o mapa inverso neural sem considerar a temperatura um melhor resultado a 30°C, temperatura

onde ocorreu o treinamento. A consideração da informação da temperatura, portanto, mostra-se importante quando não existe um controle da temperatura do fluido hidráulico, como no caso do sistema hidráulico utilizado no presente trabalho.

5.4. Controlador em Cascata Neural Adaptativo.

Com o objetivo de realizar experimentos utilizando as estratégias de adaptação propostas em uma situação onde haja alterações paramétricas no modelo, propõe-se as seguintes alterações na configuração padrão da bancada descrita na Seção 2.3.1:

- Redução da pressão de suprimento para $P_S = 40 \cdot 10^5$ Pa;
- Inclusão, em um sistema com uma roldana, de uma massa $M_L = 15$ kg, proporcionando uma força de perturbação constante F_L .

A Figura 5.41 ilustra a bancada hidráulica com as alterações supracitadas.

Os ganhos utilizados nos controladores em cascata fixos, apresentados na Tabela 5.1, foram mantidos nos experimentos com o controlador em cascata neural adaptativo. Utiliza-se um mesmo valor de ganho de adaptação para todos os elementos da matriz diagonal $\Gamma_{11 \times 11}$, onde $\gamma_{11} = \gamma_{22} = \dots = \gamma_{1111} = 1000$ e o valor do ganho de adaptação do parâmetro $\hat{\alpha}$ é de $1 = 7 \cdot 10^{-9}$. Os ganhos de adaptação foram definidos por meio de interações experimentais sucessivas. O valor inicial para o parâmetro de ajuste do mapa inverso estimado é $\hat{\alpha} = 1$ e o valor inicial da matriz de pesos de saída estimada da rede neural adaptativa descrita por meio da Equação (4.33) é:

$$\hat{W}_{3r} = [60,17 \quad 66,71 \quad 36,46 \quad 66,71 \quad 36,46 \quad 66,71 \quad 60,17 \quad 66,71 \quad 66,71 \quad 66,71 \quad -217,21]^T,$$

onde os pesos estimados serão referenciados em uma numeração de 1 a 11, de acordo com a sua posição no vetor.

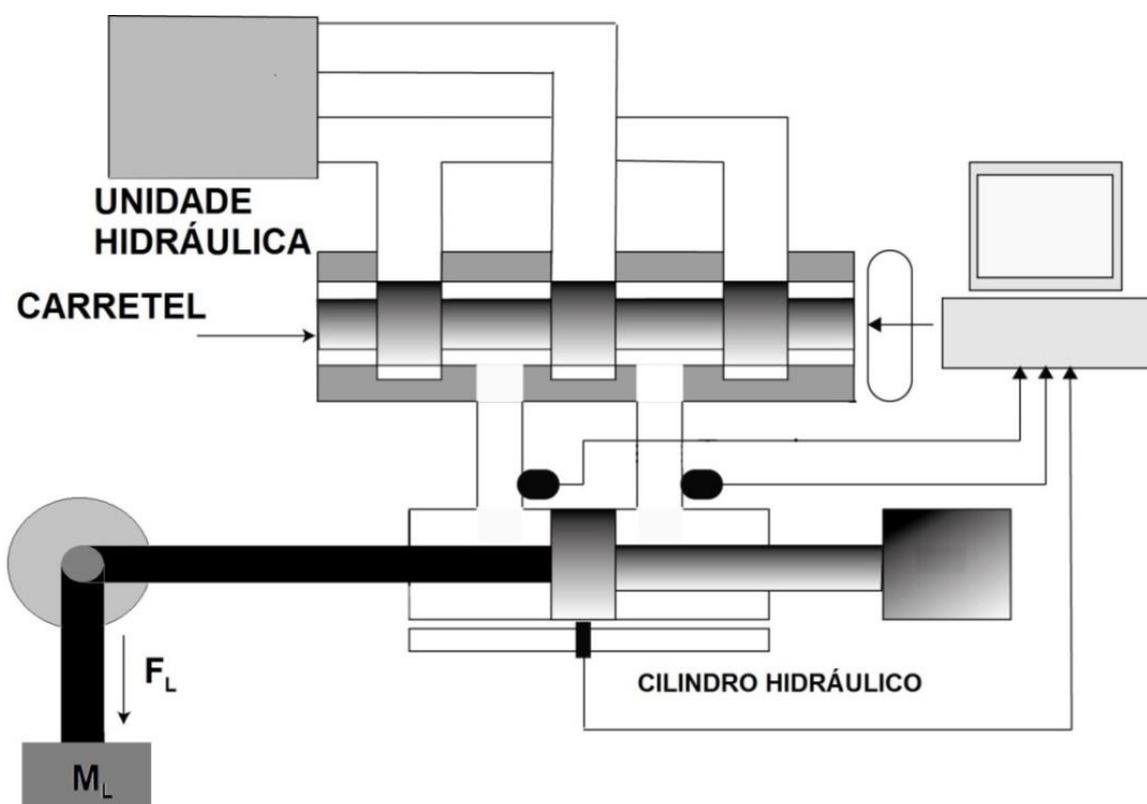
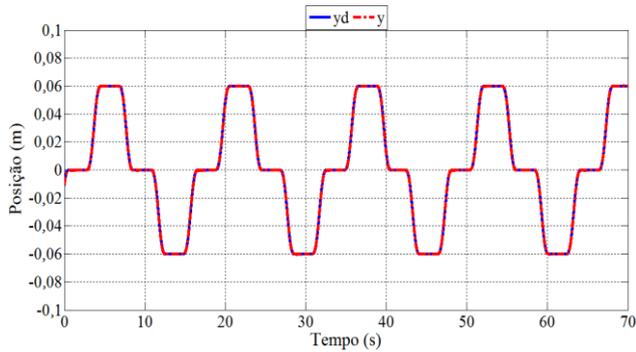
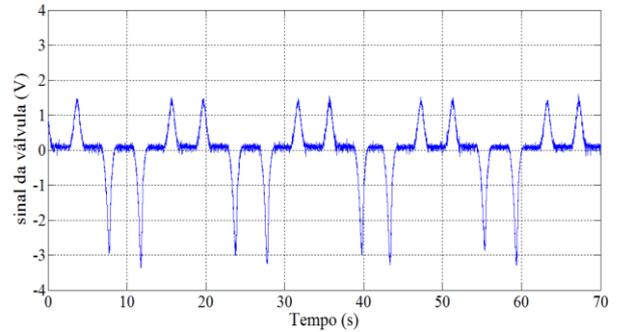


Figura 5.41 – Configuração da bancada hidráulica para os ensaios experimentais utilizando os controladores adaptativos propostos.

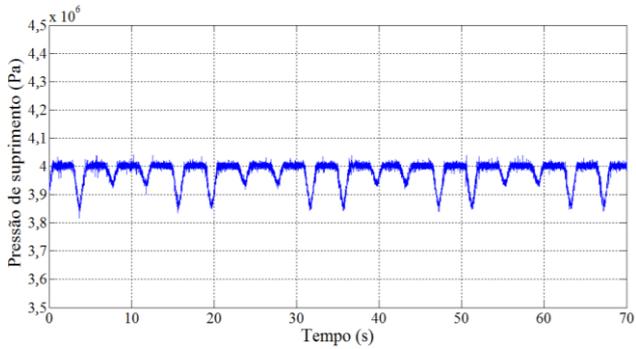
A Figura 5.42 apresenta a resposta de posição, pressão de suprimento, pressões P_A e P_B medidas por meio dos sensores conectados as portas 1 e 2 do cilindro hidráulico, o erro de seguimento de força, o erro de seguimento de posição, o sinal de controle, os pesos estimados da camada de saída da rede neural de compensação da força de atrito modificada e o parâmetro alfa estimado do mapa inverso referentes ao seguimento da trajetória polinomial. Estes resultados são apresentados somente para a temperatura de 40 °C do fluido hidráulico. Nas demais temperaturas do fluido hidráulico, pela relação entre os resultados ser semelhante ao que já foi apresentado anteriormente, apresenta-se somente os resultados de erro de seguimento de posição.



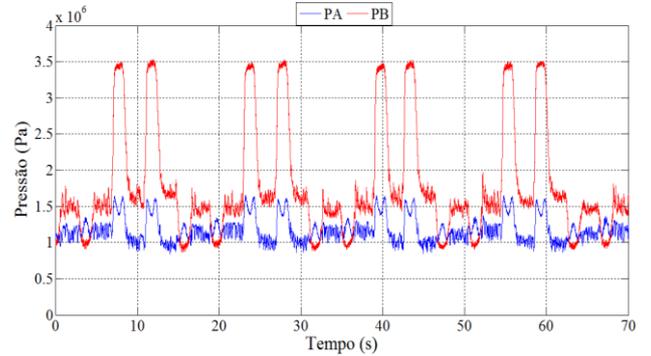
(a) Posição.



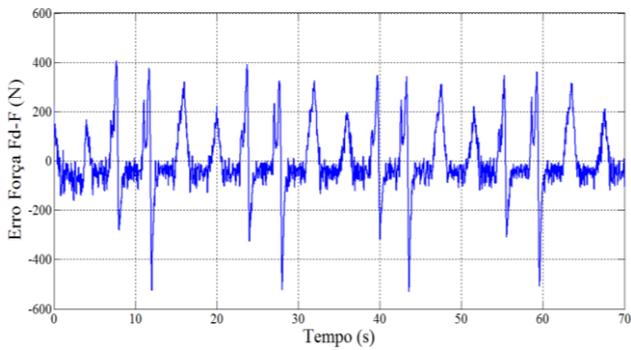
(b) Sinal de controle.



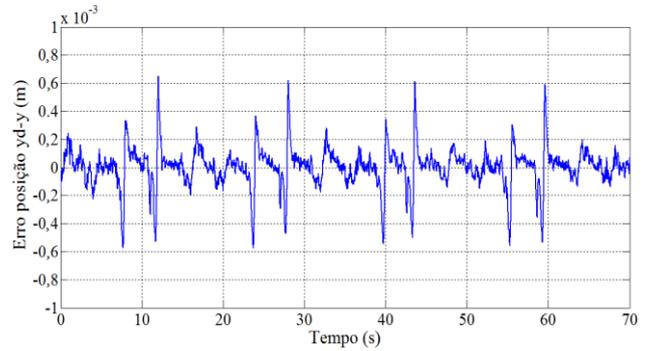
(c) Pressão de suprimento



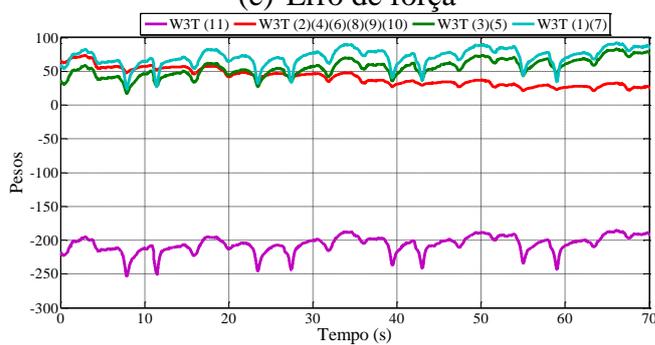
(d) Pressões medidas



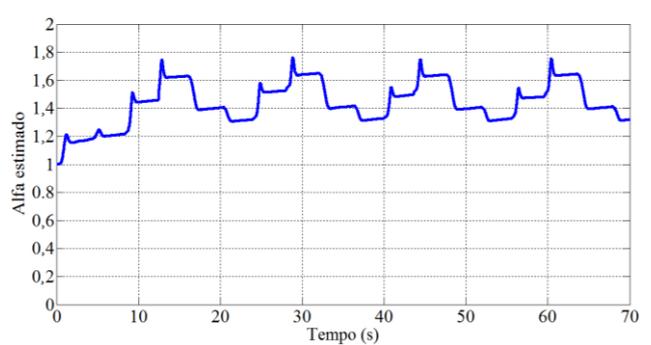
(e) Erro de força



(f) Erro de posição



(g) Adaptação de \hat{W}_{3r} (atrito modificado).



(h) Adaptação de $\hat{\alpha}$ (mapa inverso).

Figura 5.42 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória polinomial.

Destacam-se os seguintes aspectos observados na Figura 5.40:

- Os erros de seguimento de força e posição mantêm a mesma variação ao longo do tempo, com uma rápida convergência dos parâmetros adaptados para valores que proporcionam esse resultado;
- Os parâmetros adaptados permanecem estáveis, excursionando em torno de um valor médio ao longo do tempo observado, um comportamento típico de um controle adaptativo aplicado a uma planta não linear, que pode ser observado também em trabalhos como Coelho e Cunha, 2011 e Yao, et al.,2014;
- O sinal de controle altera-se em relação aos experimentos da Seção 5.4 devido às alterações realizadas na bancada de testes;
- A queda na pressão de suprimento e os limites para as pressões medidas também se alteram.

Com o objetivo de verificar se os parâmetros e o erro de seguimento de posição mantêm-se estáveis ao longo de um tempo maior de experimento, o mesmo foi realizado ao longo de 7 minutos. As figuras 5.43 a 5.46 ilustram os resultados obtidos.

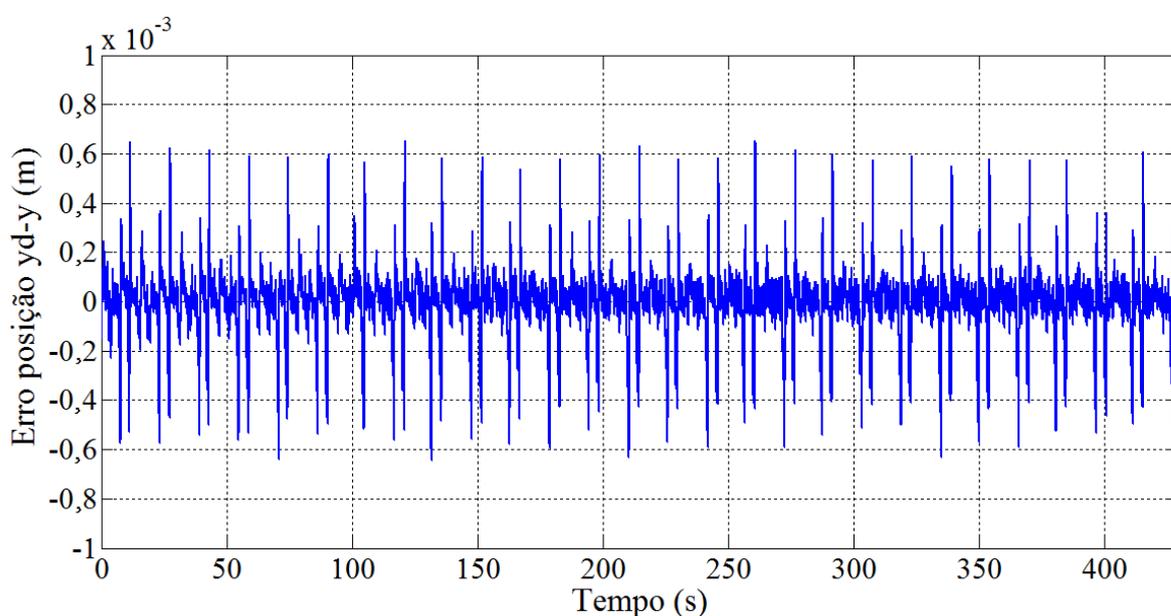


Figura 5.43 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória polinomial (7 min de experimento). Erro de posição.

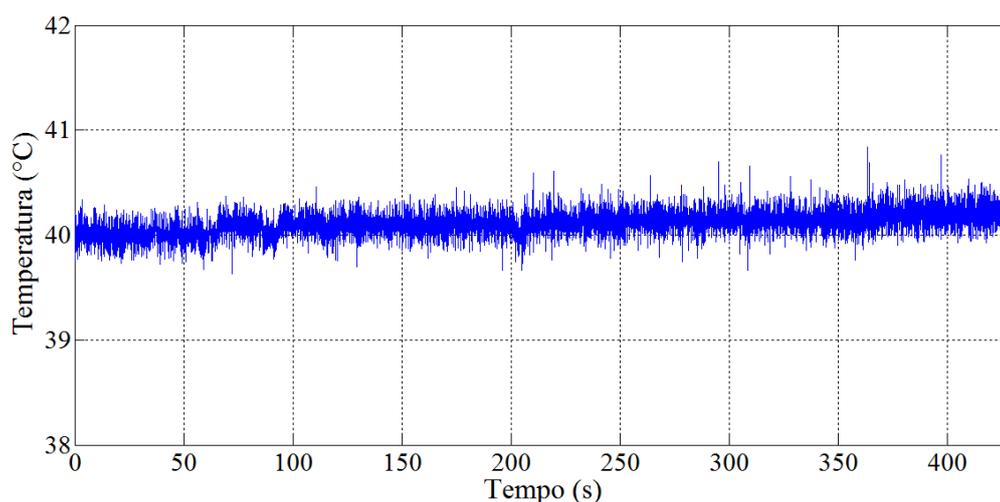


Figura 5.44 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória polinomial (7 min de experimento).
Temperatura do fluido hidráulico no experimento.

Por meio da Figura 5.43 é possível observar que o erro de seguimento de posição permanece com uma variação aproximadamente inalterada ao longo do experimento. Por meio da Figura 5.44 pode-se verificar um aumento de 0,25 °C na temperatura do fluido do valor inicial ao valor final no experimento.

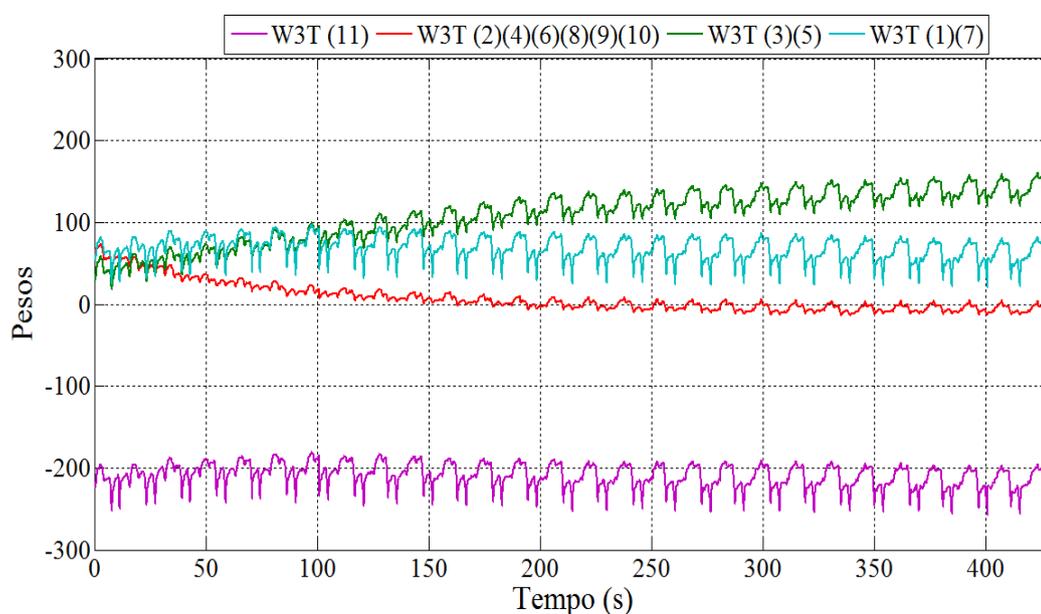


Figura 5.45 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória polinomial (7 min de experimento).
Adaptação de \hat{W}_{3r} (atrito modificado).

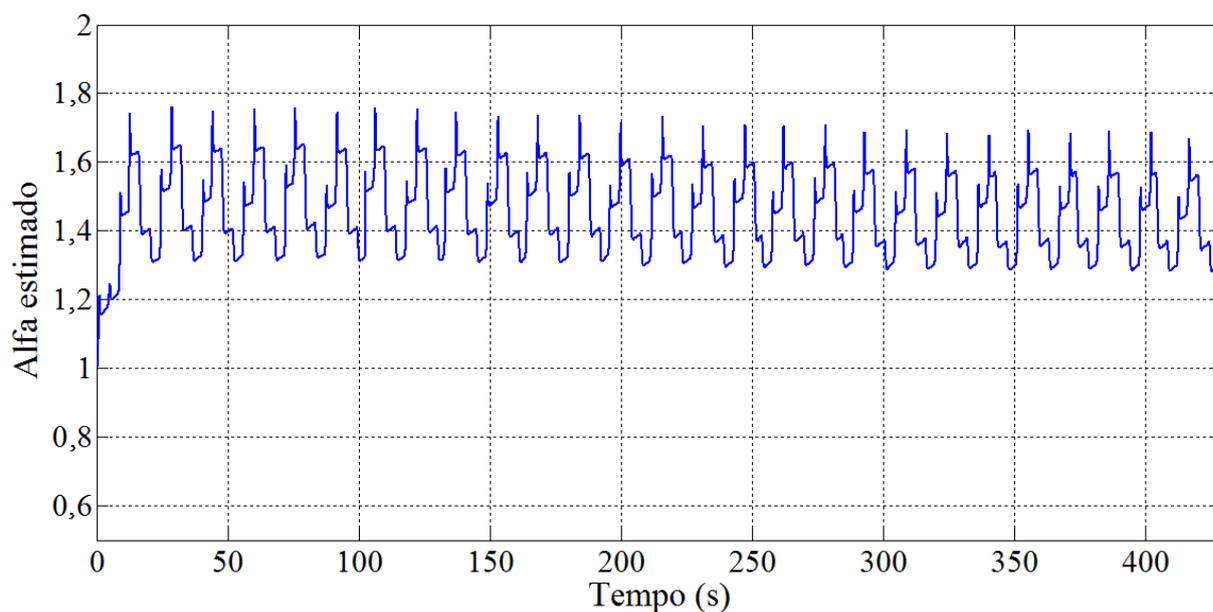
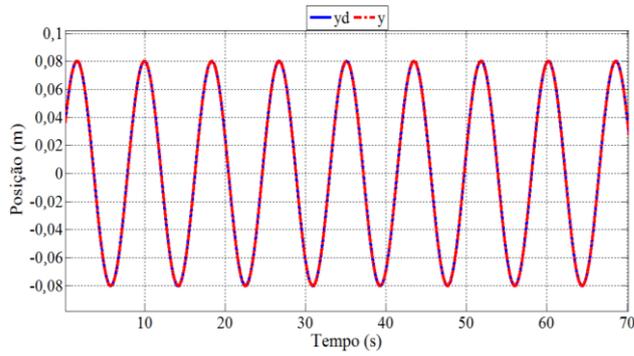


Figura 5.46 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória polinomial (7 min de experimento).

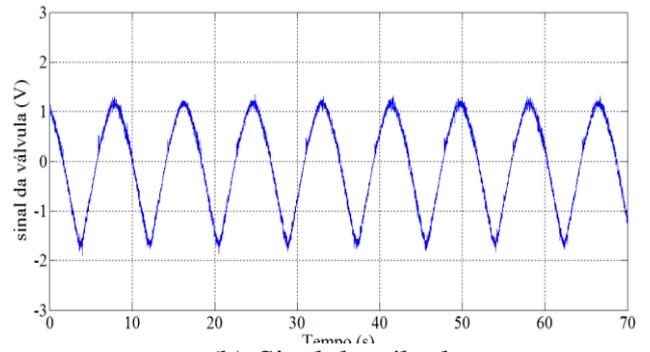
Adaptação de $\hat{\alpha}$ (mapa inverso).

Através das Figuras 5.45 e 5.46 é possível constatar que os parâmetros adaptados continuam convergindo após 70 s de experimento, com um valor médio aproximadamente constante após 300 s.

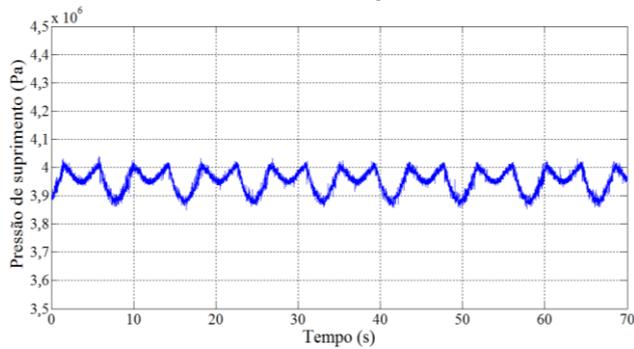
A Figura 5.47 apresenta a resposta de posição, pressão de suprimento, pressões P_A e P_B medidas por meio dos sensores conectados às portas 1 e 2 do cilindro hidráulico, o erro de seguimento de força, o erro de seguimento de posição, o sinal de controle, os pesos estimados da camada de saída da rede neural de compensação da força de atrito modificada e o parâmetro alfa estimado do mapa inverso referentes ao seguimento da trajetória senoidal.



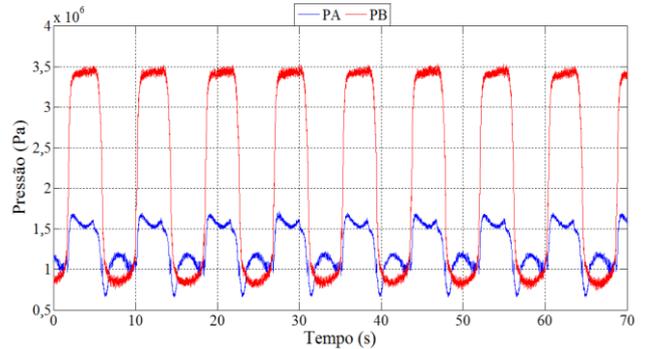
(a) Posição.



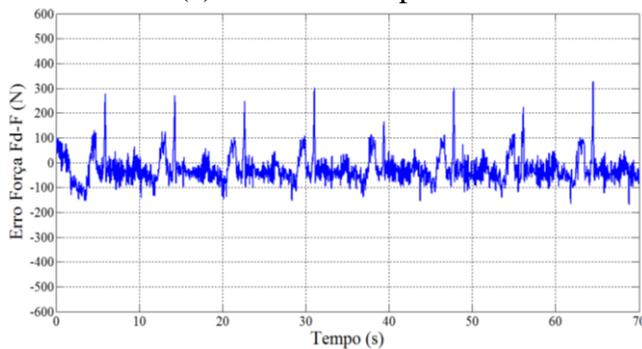
(b) Sinal da válvula.



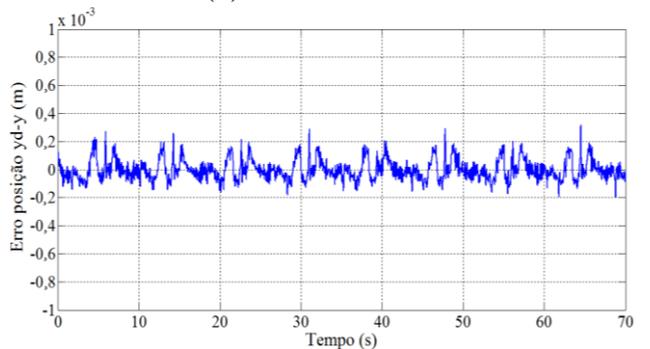
(c) Pressão de suprimento



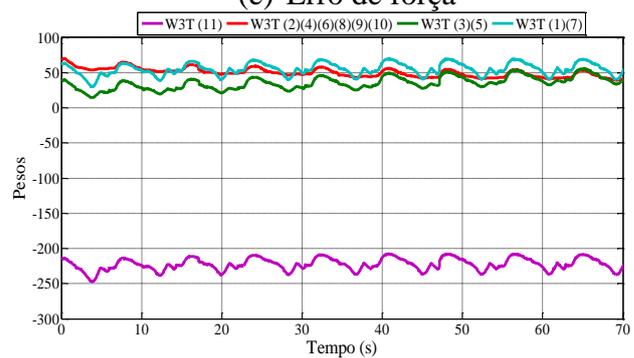
(d) Pressões medidas



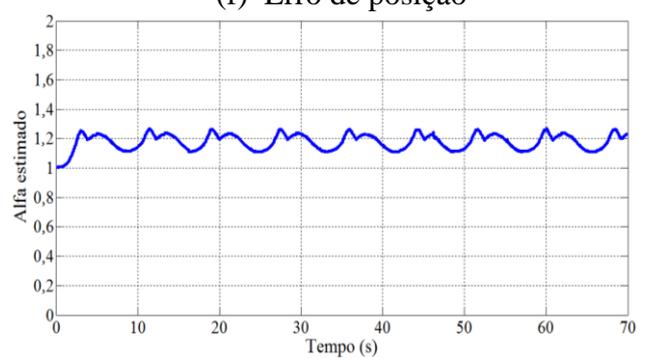
(e) Erro de força



(f) Erro de posição



(g) Adaptação de \hat{W}_{3r} (atrito modificado).



(h) Adaptação de $\hat{\alpha}$ (mapa inverso).

Figura 5.47 - Experimentos a 40 °C : Cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória senoidal.

As mesmas observações em relação à Figura 5.42 podem ser feitas também em relação à Figura 5.47. Os resultados de erro de seguimento de posição são semelhantes aos observados na Seção 5.3 para o controlador em cascata neural fixo na trajetória senoidal.

Assim como na trajetória polinomial, realiza-se um experimento de 7 minutos para verificar a estabilidade da adaptação de parâmetros do controlador em cascata neural adaptativo na trajetória senoidal. As figuras 5.48 e 5.51 apresentam os resultados desse experimento.

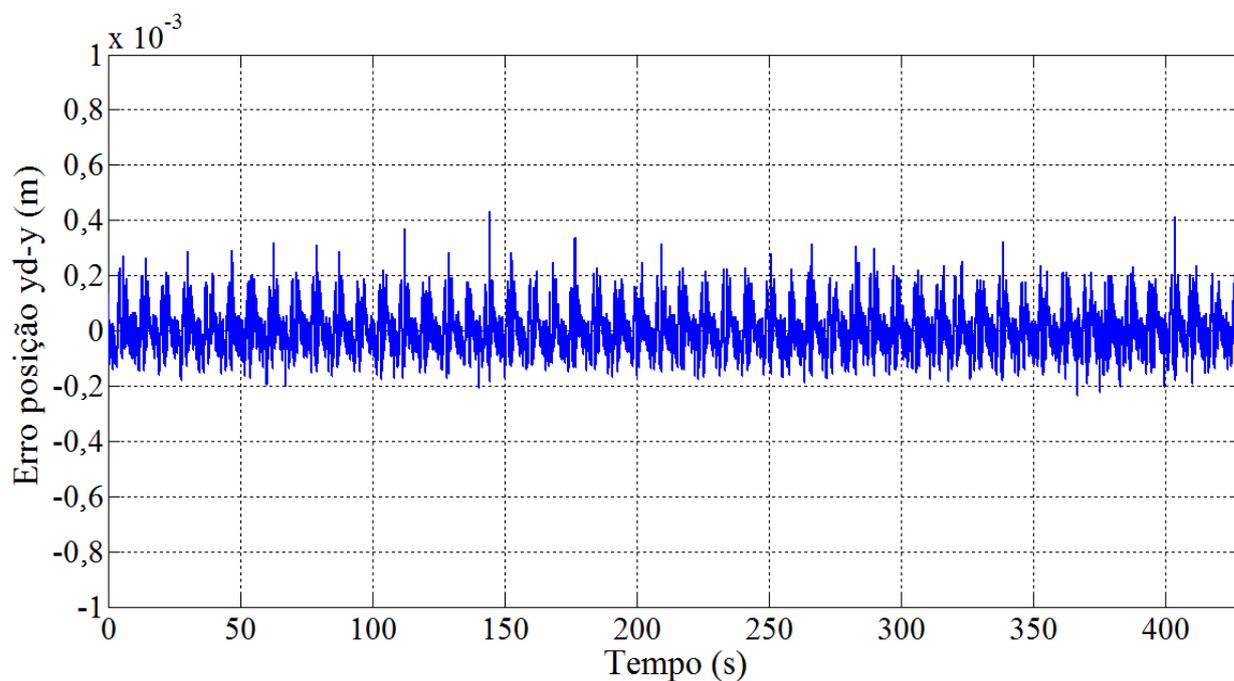


Figura 5.48 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória senoidal (7 min de experimento).
Erro de posição.

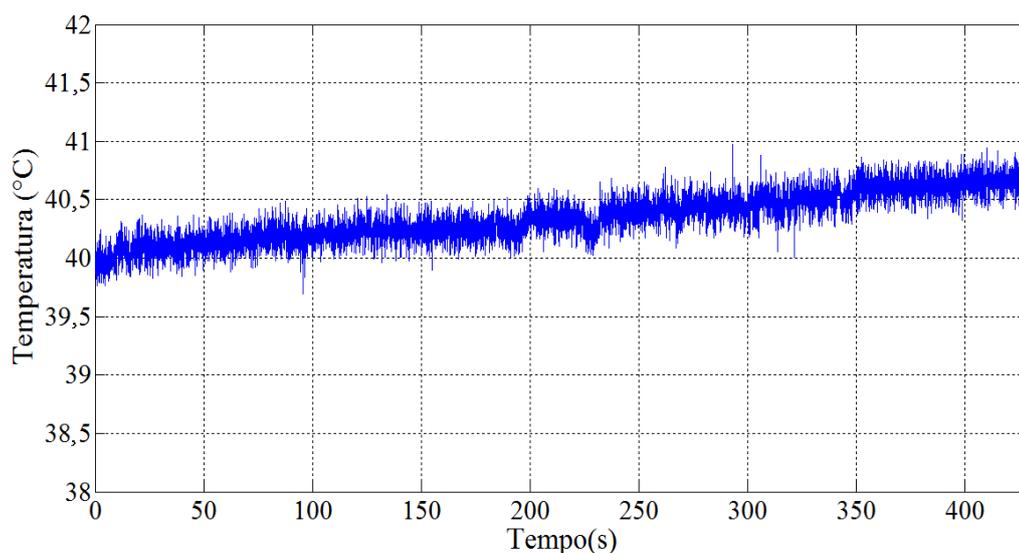


Figura 5.49 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória senoidal (7 min de experimento).
Temperatura do fluido hidráulico no experimento.

Conforme observa-se por meio da Figura 5.48, O erro de seguimento de posição permanece com uma variação aproximadamente inalterada ao longo do experimento. Por meio da Figura 5.49 pode-se verificar um aumento de 0,6 °C na temperatura do fluido do valor inicial ao valor final no experimento.

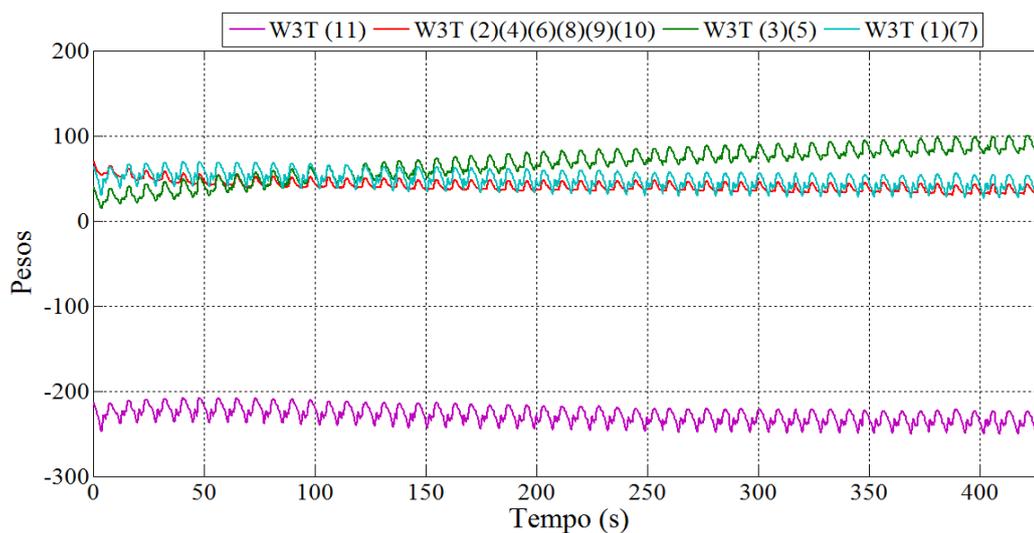


Figura 5.50 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória senoidal (7 min de experimento).
Adaptação de \hat{W}_{3r} (atrito modificado).

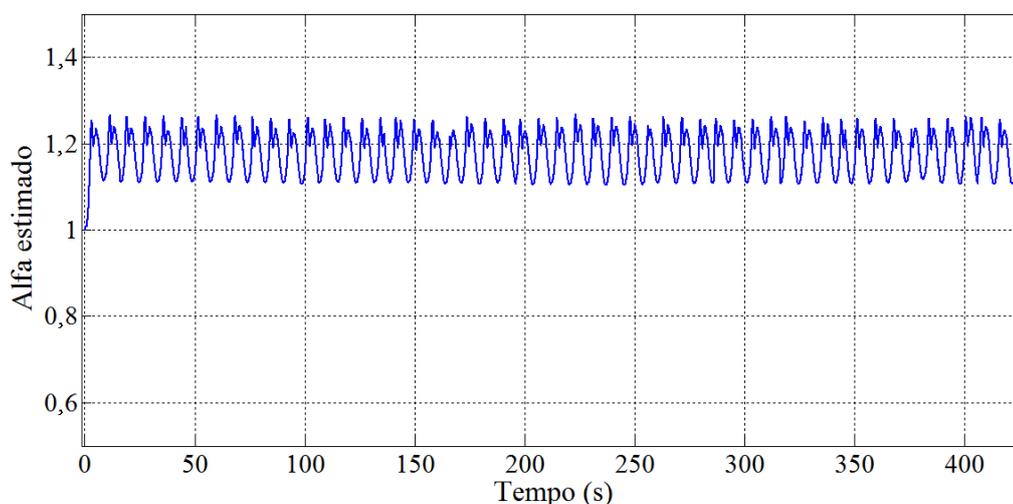


Figura 5.51 - Experimentos a 40 °C para o cascata neural considerando a temperatura e compensação de atrito neural adaptativo: trajetória senoidal (7 min de experimento). Adaptação de $\hat{\alpha}$ (mapa inverso).

Através das Figuras 5.50 e 5.51 é possível constatar que os pesos adaptados continuam convergindo lentamente até o final do experimento, mas permanecendo estáveis. O parâmetro alfa estimado permanece com valor médio constante ao longo do experimento.

Com o objetivo de comparar o desempenho em relação ao erro de seguimento de posição apresentado pelos controladores em cascata sem adaptação utilizados na Seção 5.3 e o controlador em cascata neural adaptativo, foram realizados experimentos com os controladores em cascata analítico, controlador em cascata neural considerando a temperatura e compensação de atrito neural sem adaptação e o controlador em cascata neural adaptativo. Os experimentos foram realizados nas temperaturas de 20 °C, 30 °C e 40 °C para o fluido hidráulico utilizando a configuração apresentada na Figura 5.41 para a bancada de testes com os controladores aplicados no seguimento das trajetórias polinomial e senoidal de posição.

As figuras 5.52 a 5.54 ilustram o erro de seguimento de posição em relação a trajetória polinomial medido para o controlador em cascata analítico e neural fixos e para o controlador em cascata neural adaptativo. Esses ensaios foram realizados após 60 s de adaptação.

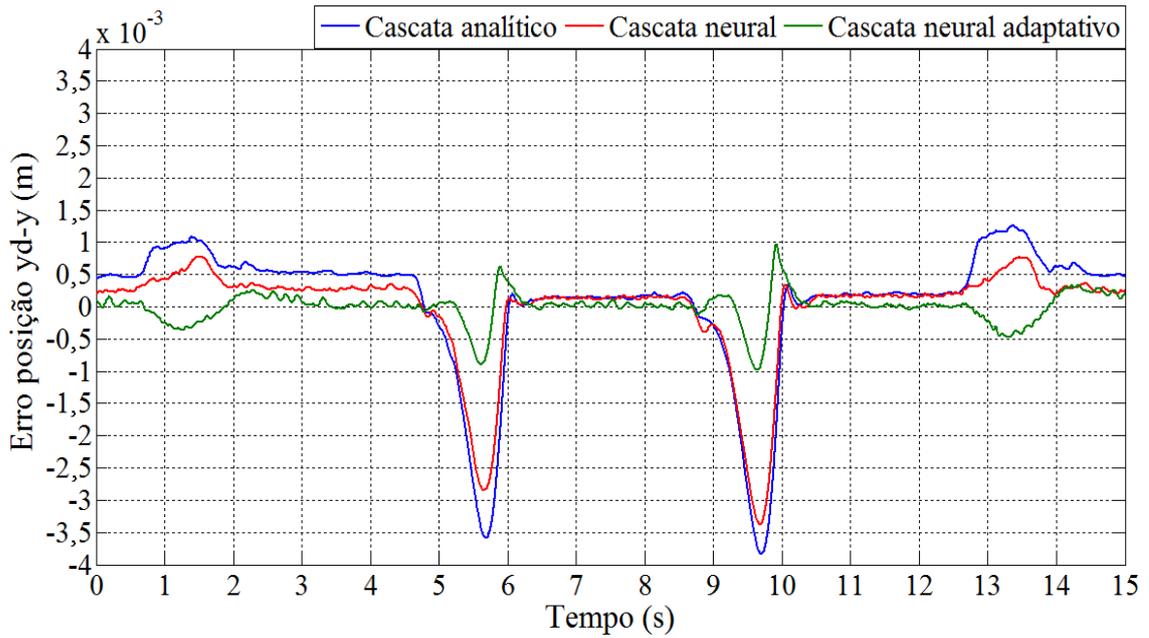


Figura 5.52 - Experimentos a 20 °C : Comparações entre os controladores em Cascata na trajetória polinomial.

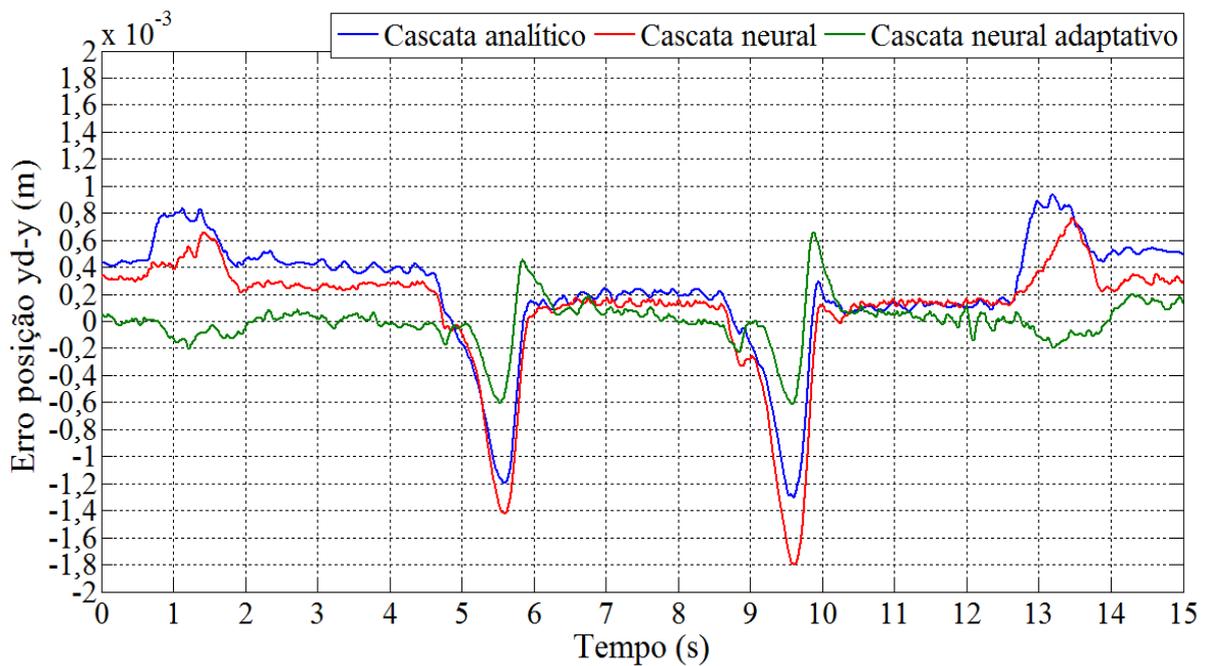


Figura 5.53 - Experimentos a 30 °C : Comparações entre os controladores em Cascata na trajetória polinomial.

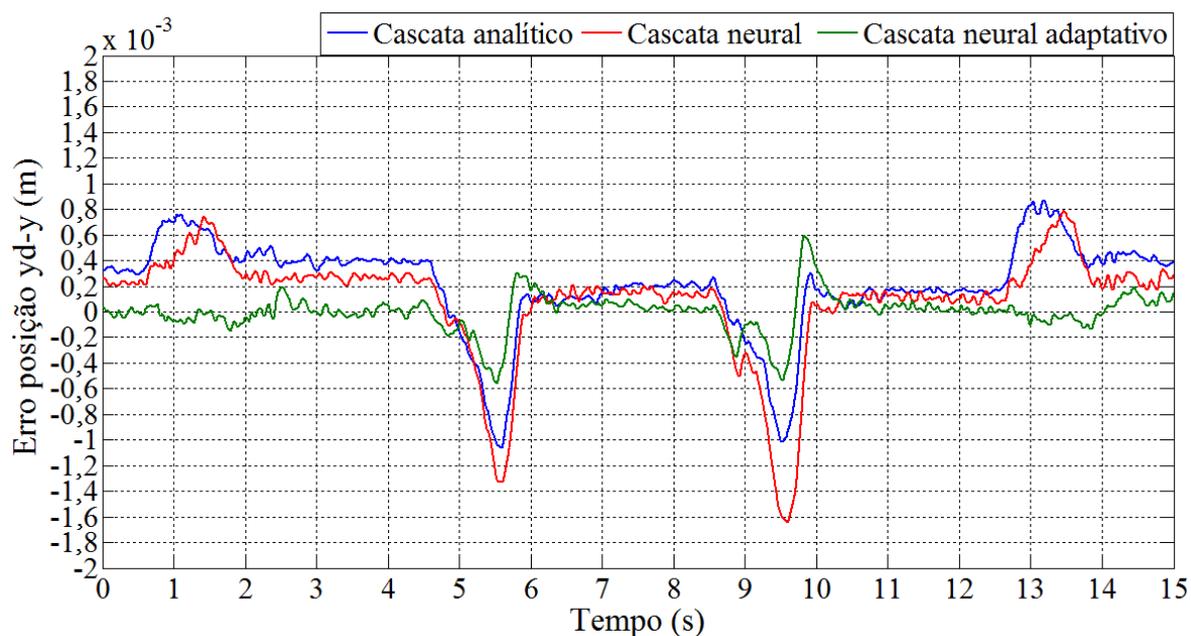


Figura 5.54 - Experimentos a 40 °C : Comparações entre os controladores em Cascata na trajetória polinomial.

Pode-se constatar por meio de inspeção nas Figuras 5.52 a 5.54 que o erro de seguimento de posição apresentado pelo controlador em cascata neural adaptativo é menor em todas as temperaturas do fluido hidráulico ensaiadas. As alterações paramétricas na planta fazem com que um erro de posição quando o pistão encontra-se parado seja percebido quando na utilização dos controladores não adaptativos. A adaptação dos parâmetros torna muito pequeno esse erro no controlador em cascata neural adaptativo, além disso, os valores máximos absolutos do erro para o controlador adaptativo são menores em relação às estratégias não adaptativas.

A Tabela 5.8 apresenta a aplicação do RMSE (Equação (4.29)) nas curvas apresentadas nas figuras 5.52 a 5.54, e também o valor máximo absoluto do erro para cada uma dessas curvas.

Tabela 5.8 – Comparação de erro entre os controladores em cascata para a trajetória polinomial.

temperatura (°C)	Analítico		Neural		Neural adaptativo	
	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)
20	9,9	38,0	7,62	33,5	2,42	9,7
30	4,76	12,8	4,46	17,8	1,66	6,5
40	4,14	10,5	4,26	16,1	1,46	5,9

As figuras 5.55 a 5.57 ilustram o erro de seguimento de posição em relação à trajetória senoidal medido para o controlador em cascata analítico e neural fixos e para o controlador em cascata neural adaptativo. Esses ensaios foram realizados após 60 s de adaptação.

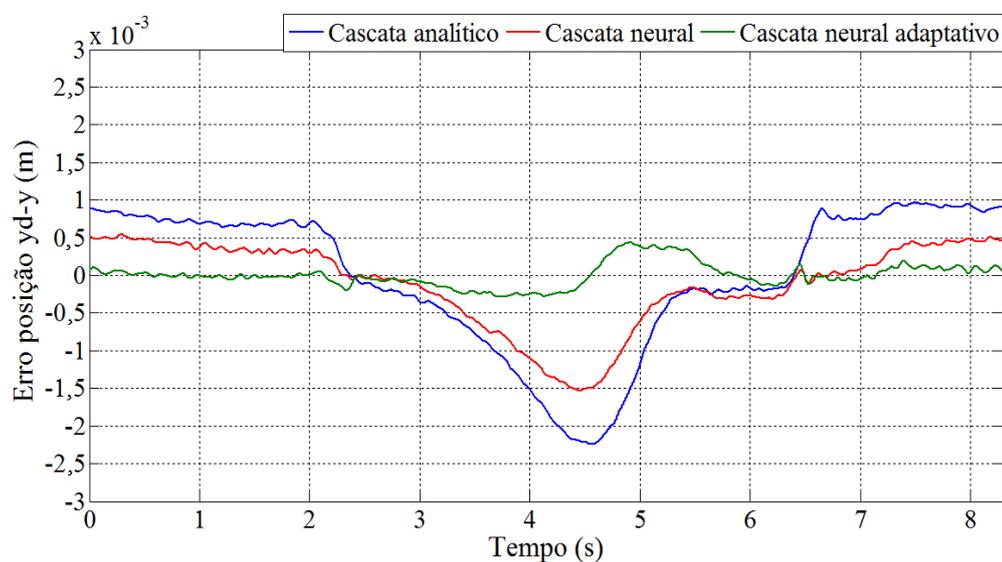


Figura 5.55 - Experimentos a 20 °C : Comparações entre os controladores em Cascata na trajetória senoidal.

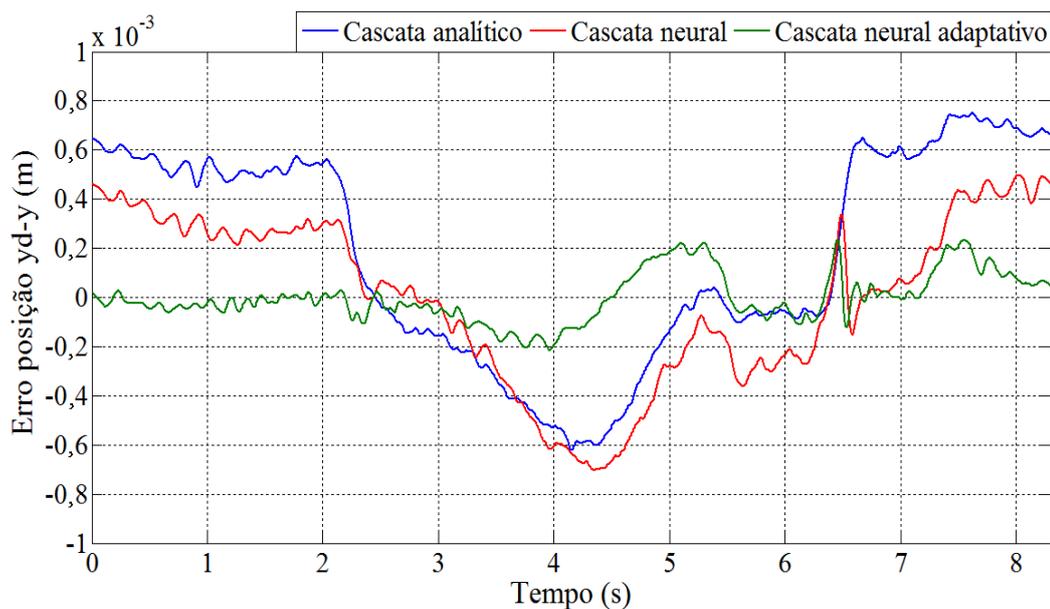


Figura 5.56 - Experimentos a 30 °C : Comparações entre os controladores em Cascata na trajetória senoidal.

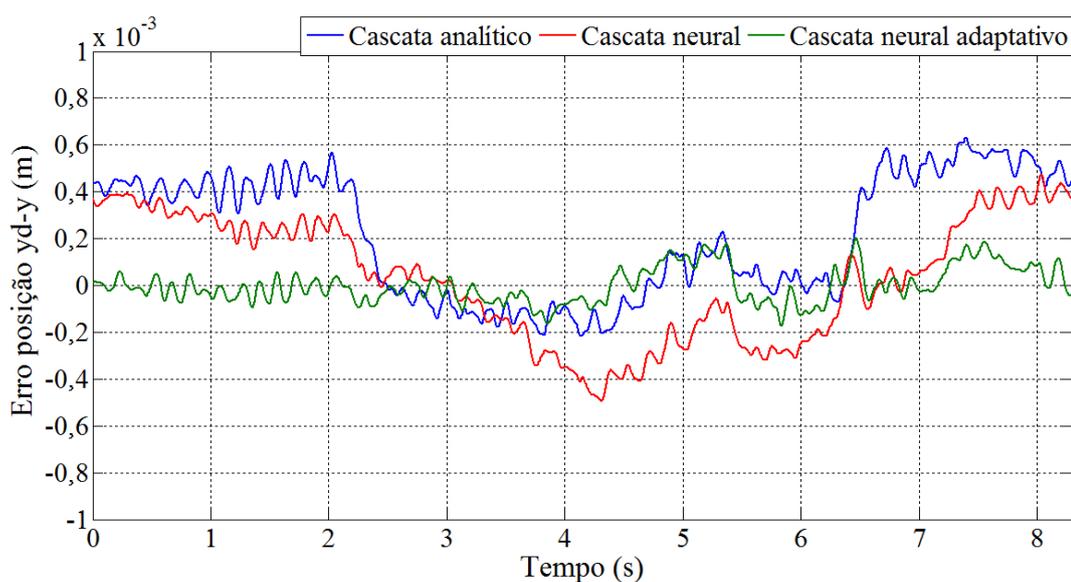


Figura 5.57 - Experimentos a 40 °C : Comparações entre os controladores em Cascata na trajetória senoidal.

Pode-se constatar, por meio de inspeção nas figuras, que o erro de seguimento de posição apresentado pelo controlador em cascata neural adaptativo é menor em todas as temperaturas do fluido hidráulico ensaiadas.

A Tabela 5.9 apresenta a aplicação do RMSE (Equação (4.29)) nas curvas apresentadas nas figuras 5.51 a 5.53, e também o valor máximo absoluto do erro para cada uma dessas curvas.

Tabela 5.9 – Comparação de erro entre os controladores em cascata para a trajetória senoidal.

	Analítico		Neural		Neural adaptativo	
temperatura (°C)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻³ m)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)	(RMSE) (10 ⁻⁴ m)	maior erro absoluto (10 ⁻⁴ m)
20	9,24	22,4	5,67	15,2	1,55	4,3
30	4,77	7,5	3,43	7,0	0,95	2,3
40	3,49	6,2	2,73	4,9	0,79	2,0

Pode-se observar, por meio das figuras 5.48 a 5.54 e pelos resultados das tabelas 5.8 e 5.9, que o controlador em cascata neural adaptativo apresenta desempenho de erro de posição superior ao controlador em cascata analítico e neural não adaptativos, em todas as temperaturas do fluido hidráulico as quais foram realizados experimentos.

5.5. Discussões do Capítulo 5.

A partir dos resultados experimentais apresentados, é possível concluir que o controlador em cascata utilizando o mapa inverso neural e a compensação neural de atrito apresenta resultados satisfatórios quanto ao controle de trajetória de posição de um atuador hidráulico. Observam-se, também, vantagens em relação à utilização do mapa inverso neural na lei de controle do subsistema hidráulico em relação à utilização da função analítica para o mesmo fim. Quando a temperatura do fluido hidráulico apresenta variações, a função de mapa inverso neural que é treinada considerando essas variações de temperatura apresenta um melhor desempenho quando em temperaturas diferentes daquela na qual a rede que não considera a temperatura foi treinada, mostrando ser interessante essa estratégia quando não é

possível manter o fluido hidráulico em uma temperatura constante. A exemplo de Machado, 2003, a compensação neural do atrito apresenta resultados satisfatórios, com vantagens em relação à compensação simples do atrito viscoso, conforme pode ser observado por meio dos resultados das tabelas 5.4 e 5.5, onde utiliza-se compensação de atrito neural, com o resultado das tabelas 5.6 e 5.7, onde utiliza-se somente a compensação do atrito viscoso. Quando a configuração da bancada hidráulica é alterada, observa-se uma piora de desempenho nos controladores em cascata fixos, pois o modelo já não aproxima satisfatoriamente a situação da planta. Utilizando o controlador em cascata neural adaptativo proposto, o desempenho em relação ao erro de posição é significativamente melhorado. Os parâmetros adaptados permanecem estáveis ao longo do tempo e o erro de posição é mantido aproximadamente constante.

6. CONCLUSÕES DA TESE.

Baseado no trabalho desenvolvido e nos resultados obtidos destacam-se as seguintes contribuições do presente trabalho:

- Desenvolvimento de uma modelagem que envolve uma metodologia de levantamento de perdas de carga através de simulações interativas;
- Desenvolvimento de uma função de representação do mapa inverso do subsistema hidráulico através da utilização de Redes Neurais do tipo multicamadas alimentadas adiante com treinamento *off-line*;
- Comprovação de que essa função representa adequadamente o comportamento do mapa inverso, com algumas vantagens em relação à mesma representação utilizando uma função analítica clássica. Essa comprovação se dá através de:
 - Aplicação da raiz do erro quadrático médio ao desvio observado entre curvas experimentais com valores do mapa inverso do subsistema hidráulico e curvas construídas através de dados experimentais que são aplicados na função neural e na função analítica que representam o mapa inverso. Os resultados dos indicadores mostram que a função neural aproxima melhor as curvas experimentais;
- Proposta de um controlador que utiliza a estratégia em cascata, onde o mapa inverso do subsistema hidráulico na estratégia da linearização por realimentação é representado por uma função neural, aliado ao uso de compensação de atrito utilizando redes neurais no subsistema mecânico;
- Proposição de uma metodologia de treinamento das redes neurais com foco em sistemas hidráulicos;
- Comprovação de que os resultados experimentais desse controlador são satisfatórios, preservando as vantagens do controlador em cascata analítico em relação aos controladores clássicos e apresentando alguma vantagem em relação ao uso do controlador em cascata neural em relação ao controlador em cascata analítico. Considera-se ainda a vantagem de projeto utilizando redes neurais, que necessitam somente de amostras do comportamento do sistema

para a síntese das funções, evitando a execução de trabalhos experimentais extensos;

- Desenvolvimento de um prova formal de estabilidade do controlador em cascata neural não adaptativo, mostrando que o mesmo é capaz de manter o sistema estável mediante erros limitados da rede, provando, assim, que o controlador em cascata neural fixo é robusto para variações limitadas de estimação da rede neural que representa o mapa inverso na linearização por realimentação;
- Proposição de uma rede neural treinada ao longo de variações da temperatura e inclusão da própria temperatura como entrada dessa rede neural. Comprovação experimental de que a função de mapa inverso neural, treinada com essas características, apresenta melhores resultados com a variação da temperatura do fluido hidráulico;
- Proposição de um esquema de adaptação nas funções neurais por meio de parâmetros lineares na saída das mesmas. Utilizam-se os próprios pesos lineares da rede neural que representa o atrito e propõe-se um fator de ajuste para a rede neural que representa o mapa inverso. A eficácia do controlador proposto é comprovada por meio de experimentos, que mostram que o desempenho do erro de posição é melhorado em relação ao desempenho de controladores em cascata sem adaptação; e
- Desenvolvimento de uma prova formal de estabilidade do controlador em cascata neural adaptativo mediante suposições simplificadoras adotadas.

6.1. Sugestões de trabalhos futuros.

Baseando-se nos elementos reunidos na revisão bibliográfica e nas contribuições obtidas, propõe-se os seguintes trabalhos futuros:

- Construção de uma bancada utilizando uma válvula assimétrica e um pistão de haste simples. Essa bancada deverá ter perdas de carga menores que a bancada atual e ser capaz de incluir variação na massa posicionada e variação de componente gravitacional. Sugere-se ainda a utilização de um pistão em malha

aberta em série com o pistão de atuação, de modo a incluir uma força de perturbação. Desta forma, será possível avaliar a variação na massa e os efeitos da inclusão de perturbações de força temporárias;

- Avaliação experimental, assim como em Yao et al., 2014a, Guo et al, 2016, e Yang et al., 2016, do controlador adaptativo proposto mediante significativas perturbações de força não previstas.
- Realização de teste do controlador proposto na plataforma de Stewart do LAMECC. A operação dos algoritmos propostos em um manipulador de seis graus de liberdade em cadeia cinemática fechada pode ser realizada por meio da utilização de uma matriz diagonal contendo funções neurais do mapa inverso em conjunto com um controlador do tipo torque computado, que fornecerá os torques e forças desejados. A compensação de atrito neural pode ser realizada por meio de um vetor de compensação de atrito neural, que fará parte do controlador torque computado;
- Extensão da prova de estabilidade formal para o controlador com múltiplas entradas e múltiplas saídas; e
- Automatização do processo de treinamento das redes neurais por meio de rotinas computacionais que proporcionem entradas e saídas amigáveis ao usuário.

REFERÊNCIAS BIBLIOGRÁFICAS

Armstrong, B.; Canudas de Wit, C. **Friction Modeling and Compensation**. The Control Handbook, Cleveland, CRC Press, 1996.

Ayalew, B.; Kulakowski B. T. Cascade tuning for nonlinear position control of an electrohydraulic actuator. **Proceedings of the 2006 American Control Conference.**, Minneapolis, Minnesota, USA, p. 4627-4632, 2006.

Bai, Y.; Li, P. Adaptive Fuzzy Sliding Mode Control for Electro-hydraulic Position Servo System. **2010 Chinese Control and Decision Conference**, p. 3250-3253, 2010.

Bessa, W. M. ; Dutra, M. S. ; Kreuzer E. An adaptive fuzzy dead-zone compensation scheme and its application to electro-hydraulic systems. **Journal of ABCM**, v. XXXII n. 1, p. 1-7, 2010.

Borges, F.A.P. **Um Estudo de Controladores Robóticos Utilizando Redes Neurais**. Dissertação de Mestrado, Universidade Federal de Santa Catarina. 1999.

Breemen, A. J. N. V.; Veelenturf, L.P.J. Neural Adaptive Feedback Linearization **Journal A.**, p. 65-71, 1996.

Bu, F; Yao, B. Nonlinear adaptive robust control of actuators regulated by proportional directional control valves with deadband nonlinear flow gains. **The American Control Conference**, Chicago, Illinois, p. 4129-4133, 2000.

Canaves, M.; Pompeia, P. J. Uncertainty of the density of moist air :Gum x Monte Carlo. **Brazilian Archives of Biology and Technology**, p. 87-95, 2006.

Canudas de Wit, C.; Olsson, H. Astrom, K. J; Lichinsky, P. A new model for control systems with friction. **IEEE Transaction on Automatic Control**, v. 40, n.3, p. 419-425, 1995.

Cerman, O.; Hušek, P. Adaptive fuzzy sliding mode control for electro-hydraulic servo mechanism. **Expert Systems with Applications**, p. 10269–10277, 2012.

Chen, F.; Liu C. Adaptively Controlling Nonlinear Continuous-Time Systems Using Multilayer Neural Networks. **IEEE Transactions on Automatic Control**, v. 39, p. 1306-1310, 1994.

Chiang, M. H.; Huang, C. C. Experimental implementation of complex path tracking control for large robotic hydraulic excavators. **International Journal of Advanced Manufacturing Technology**, v. 23, p. 126-132, 2004.

Coelho, L. S.; Cunha, M. A. B. Adaptive cascade control of a hydraulic actuator with an adaptive dead-zone compensation and optimization based on evolutionary algorithms. **Expert Systems with Applications**, n. 38, p. 12263-12269, 2011.

Coleman, H. W.; Steele W. G. **Experimentation, Validation, and Uncertainty Analysis for Engineers**. John Wiley & Sons. 2009.

Craig, J. J. **Robótica**. Pearson. 3.ed..2013.

Cunha, M. A. B.; Guenther, R.; De Pieri, E. R.; De Negri, V. J. Design of cascade controllers for a hydraulic actuator. **International Journal of Fluid Power**, v.3, n.2, p. 35-46, 2002.

Cunha, M. A. B.; Guenther, R.; De Pieri, E. R.; De Negri, V. J. **A fixed cascade controller applied to a hydraulic actuator including the servovalve dynamic**. PTMC. Suffolk, UK. Prof.Eng. Publishing. 2000.

Cunha, M. A. B. Adaptive cascade controller applied to a hydraulic actuator. **International Conference on Control and Automation**, Budapest, Hungary, p. 622-627, 2005.

Cunha, M. A. B.; Guenther, R. Adaptive cascade control of a hydraulic actuator with an adaptive dead-zone compensation. **ABCm symposium series in mechatronics**, v. 2, p. 385-392, 2006.

Cunha, M. A. B.; Guenther, R. Adaptive cascade control of a hydraulic actuator with an adaptive dead-zone compensation. **COBEM 2005**, Ouro Preto, MG, Brasil, 2005.

Cunha, M. A. B. **Controle em Cascata com Adaptação de Parâmetros Aplicado a um Atuador Hidráulico**. Dissertação de Mestrado, Universidade Federal de Santa Catarina. 1997.

Cunha, M. A. B. **Controle em Cascata de um Atuador Hidráulico: Contribuições Teóricas e Experimentais**. Tese de Doutorado, Universidade Federal de Santa Catarina. 2001.

Cunha, M. A. B.; Guenther, R.; De Pieri, E. R.; De Negri, V. J. Controle em cascata com adaptação de parâmetros aplicado a um atuador hidráulico. **Congresso Brasileiro de Automática**, Uberlândia, MG, Brasil, p. 211-216, 1998.

Cybenko, G. Approximation by superpositions of sigmoidal functions. **Mathematics of Control, Signals, and Systems**, 1989.

Daachi, B.; Madani, T.; Daachi, M. E.; Djouani, K. MLPNN Adaptive Controller Based on a Reference Model to Drive an Actuated Lower Limb Orthosis. **2014 5th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechanics (BioRob)**, São Paulo, Brasil, p. 638-643, 2014.

Daachi B.; Sirdi, M. K. M. A stable neural adaptive force controller for a hydraulic actuator. **Proceeding of the 2001 IEEE international conference on robotics and automation**, Seoul, Korea, p. 3465-3470, 2001.

De Negri, V. J. **Sistemas Hidráulicos e Pneumáticos para Automação e Controle**. Apostila didática, EMC, Universidade Federal de Santa Catarina. 2001.

Dorf, R. C.; Bishop, R. H. **Modern Control Systems**. Pearson Prentice Hall, 11.ed. 2008.

Fahlman, S. Faster Learning variations on backpropagation: an empirical study **Proceeding of the 1988 connectionist models summer school**, p. 38-51, 1988.

Fales R.; Kelkar, A. Robust control design for a wheel loader using H_{∞} and feedback linearization based methods, **ISA Transactions**, p. 312-320, 2009.

Fialho, I.; Balas, G. Adaptive Vehicle Suspension Design Using LPV Methods. **Proceedings of the 37th IEEE Conference on Decision & Control**, Tampa, Florida, p. 469-474, 1998.

Fitch, E. C. Temperature Stability of Lubricants and Hydraulic Fluids. **Machinery Lubrication**, july, 2002.

Franklin, G. F. **Feedback Control of Dynamical Systems**. Prentice Hall. New Jersey. 2014.

Fregene, K. O. C. **Neural Adaptive Feedback Linearizing Control of a High-Order Power System**. Master Thesis, University of Waterloo. 1999.

Furst, F. **Sistematização do Projeto Preliminar de Circuitos Hidráulicos com Controle de Posição**. Dissertação de Mestrado, Universidade Federal de Santa Catarina. 2001.

Gervini, V. I.; Gomes, S.C.P. Compensação de Atritos em Atuadores Robóticos do Tipo Moto-Redutores Via Redes Neurais Artificiais. **XVI Congresso Brasileiro de Engenharia Mecânica**, Uberlândia-MG, 2001.

Gervini, V. I. **Modelagem e Controle de um Servoposicionador Pneumático via Redes Neurais**. Tese de Doutorado, Universidade Federal do Rio Grande do Sul. 2014.

Ghazali R. ; Sam, Y. M.; Rahmat, M. F.; Zulfatman; Hamzah, N. Chaotic Trajectory Tracking of an Electro-hydraulic Actuator System using Discrete Sliding Mode Control. **2011 IEEE International Conference on Control System, Computing and Engineering**, p. 500-506, 2011.

Ghazali R.; Sam, Y. M.; Rahmat, M. F.; Hashim, A. W.; Zulfatman, I. M. Performance comparison between sliding mode control with PID sliding surface and PID controller for an electro-hydraulic positioning system. **Proceeding of the International**

Conference on Advanced Science, Engineering and Information Technology, p. 447-452, 2011.

Ghosh, B. B.; Sarkar, B. K.; Saha R. Real time performance analysis of different combinations of fuzzy–PID and bias controllers for a two degree of freedom electrohydraulic parallel manipulator. **Robotics and Computer-Integrated Manufacturing**, p. 62-69, 2015.

Gomes S. C. P.; Da Rosa V. S. A new approach to compensate friction in robotic **Proceeding of 2003 IEEE international conference on robotic and automation**. Taipei, Taiwan, v. 1, p. 622-627, 2003.

Guan, C.; Pan, S. Adaptive sliding mode control of electro-hydraulic system with nonlinear unknown parameters. **Control Engineering Practice**, p. 1275-1284, 2008.

Guan, C.; Pan, S. Nonlinear Adaptive Robust Control of Single-Rod Electro-Hydraulic Actuator With Unknown Nonlinear Parameters. **IEEE Transactions on Control System Technology**, p. 434-445, maio, 2008.

Guenther, R.; De Pieri, E. R. Cascade Control of the Hydraulic Actuators. **Jornal da Revista Brasileira de Ciências Mecânicas, ABCM**, v. 19, p. 108-120, 1997.

Guenther, R. **Controle Adaptativo e a Estrutura Variável de Robôs Manipuladores com Incertezas Dinâmicas no Acionamento Elétrico ou Nas Transmissões Flexíveis**. Tese de Doutorado, COPPE/UFRJ. 1993.

Guenther, R.; Cunha M. A. B.; De Pieri, E. R. **Experimental Implementation of the Variable Structure Adaptive Cascade Control for Hydraulic Actuators**, PTMC. Suffolk, UK, Prof.Eng.Publishing, 2000.

Guo, K.; Wei, J.; Fang, J.; Feng, R.; Wang, X. Position tracking control of electro-hydraulic single-rod actuator based on an extended disturbance observer. **Mechatronics**. p. 47-56, 2015.

Guo, Q.; Zhang, Y.; Celler, B. G.; Su, Steven W. Backstepping Control of Electro-Hydraulic System Based on Extended-State-Observer With Plant Dynamics Largely Unknown. **IEEE Transaction on Industrial Eletronic**. v.. 63, n. 11, p. 6909-6920, 2016.

Guo, Q.; PingSun; Ing-min,Y.; Tian,Y.; DanJiang. Parametric adaptive estimation and backstepping control of electro-hydraulic actuator with decayed memory filter. **ISA Transactions**, p. 202-214, 2016.

Hagan, M. T.; Demuth, H. B. Neural Networks for Control. **Proceedings of the American Control Conference**, p. 1642-1656, San Diego, California, 1999.

Han J. From PID to Active Disturbance Rejection Control. **IEEE Transactions on Industrial Eletronic**, v. 56, p. 900-906, março, 2009.

Hayakawa, T.; Haddad, W. M.; Hovakimyan, N. Neural Network Adaptive Control for a Class of Nonlinear Uncertain Dynamical Systems With Asymptotic Stability Guarantees **IEEE Transactions on Neural Networks**, p. 80-89, 2008.

Haykin, S. **Redes Neurais, Princípios e Prática**. Bookman. 2.ed. 2001.

He, S.; Sepehri, N. Modeling and predictions of hydraulic servo actuators with neural networks. **Americal Control Conference**, p. 3708-3712, San Diego, US, 1999.

Heintze, H. **Design and Control of a Hydraulically Actuated Industrial Brick Laying Robot**. PhD Thesis, Delft Technology University. 1997.

Hoekstra, A.; Duin R. P. W. Investigating redundancy in feed-forward neural classifiers. **Pattern Recognition Letters**, p. 1293–1300, 1997.

Honegger, M.; Corke, P. Model-Based Control of Hydraulically Actuated Manipulators. **Proceedings of the 2001 IEEE International Conference on Robotics & Automation**. p. 2554-2559, Seul, Korea, 2001.

Hong, Z.; Dang K.; Lin T. A Online-Trained Neural Network Controller for Electro-hydraulic Servo System. **4th World Congress on Intelligent Control and Automation**. p. 2983-2986, Shangay, China, 2002.

Honkakorpi, J., Vihonen J. e Matilla J. MEMS-based State Feedback Control of Multi-Body Hydraulic Manipulator. **IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)**, p. 4419-4425, Tokio, 2013.

Hornik, K. Approximation Capabilities of Mutilayer Feedforward Networks. **Neural Networks**, v.4, p. 251-257, 1991.

Hovakimyan, N.; Nardi, F.; Calise, A.; Kim, N. Adaptive Output Feedback Control of Uncertain Nonlinear Systems Using Single-Hidden-Layer Neural Networks. **IEEE Transactions on Neural Networks**, v.13, n. 6, p. 1420-1431, 2002.

Huang, A.; Rong, Y.; Zhang, Z.; Hu, J. Identification and adaptive control for electro-hydraulic servo-systems using neural networks. **IEEE international conference on intelligent processing systems**. p. 688-692, Pequim, China, 1997.

Ioannou, P. A.; Sun, J. **Robust Adaptive Control**. Prentice-Hall,Inc, 1996.

Ishak, N.; Tajjudin, M.; Ismail, H.; Sam, Y. Real-time Application of Self-tuning PID in Electro-hydraulic Actuator. **IEEE International Conference on Control System, Computing and Engineering**, p. 364-368, 2011.

Isidori A.; Benedetto, M. D. **Feedback Linearization of Nonlinear Systems**. Control Handbook. CRC. 1996.

JCGM. **100:2008: Evaluation of measurement data—guide to the expression of uncertainty in measurement. GUM 1995 with minor corrections.** 2008a.

JCGM. **101:2008: Evaluation of measurement data—Supplement 1 to the guide to the expression of uncertainty in measurement-propagation of distributions using a Monte Carlo method.** 2008b.

Johnson, J. **Hydraulics & Pneumatics**, 2011. Disponível em:
<http://hydraulicspneumatics.com/200/TechZone/HydraulicValves/Article/False/87725/TechZone-HydraulicValves>.

Jones J. C. Developments in Design of Electrohydraulic control valves from their initial design concept to present day design and applications. **Workshop on Proportional and Servovalves**, Melbourne, Australia, 1997.

Jornada, D.; Jornada F. H. Cálculo de Incerteza da Medição: estudo comparativo entre os métodos do GUM, de Monte Carlo e de Integração Numérica. **ENQUALAB-2007, Congresso da Qualidade em Metrologia**, São Paulo, 2007.

Kaddissi, C.; Kenne J.; Saad, M. Indirect Adaptive Control of an Electrohydraulic Servo System Based on Nonlinear Backstepping. **IEEE/ASME Transactions on Mechatronics**, v.16, n.6, p. 1171-1177, 2011

Karpenko, M; Sepehri, N. Hardware-in-the-loop simulator for research on fault tolerant control of electrohydraulic actuators in a flight control application. **Mechatronics.**, v.19, p. 1067-1077, 2009.

Kawato, M.; Uno, Y.; Isobe, M.; Suzuki, R. Hierarchical Neural Network Model for Voluntary Movement with Application to Robotics. **IEEE Control System Magazine**. p. 8-16, 1988.

Khalil Hassan K. **Nonlinear Systems**, Prentice-Hall, 3.ed. 2002.

Kim, W.; Won, D.; Shin, D.; Chung, C. C. Output feedback nonlinear control for electro-hydraulic systems. **Mechatronics**, p. 766-777, 2012.

Knohl, T.; Unbehauen, H. Adaptive position control of electrohydraulic servo systems using ANN. **Mechatronics**, p. 127-143, 2000.

Krstic, M.; Kanellakopoulos, I.; Kokotovic, P. **Nonlinear and Adaptive Control Design**. John Wiley and Sons. 1995.

Kurková, V. Kolmogorov's Theorem and Multilayer Neural Networks. **Neural Networks**, v. 5, p. 501-506, 1992.

Levin, A. U.; Naredra, K. S. Control of Nonlinear Dynamical System using Neural Networks - Part II - Observability, Identification and Control. **IEEE Transaction on Neural Networks**, v.. 7, p. 30-42, 1996.

Lewis, F. L.; Jagannathan, S.; Yesildirak, A. **Neural Network Control of Robot Manipulators and Nonlinear Systems**. Taylor & Francis. 1999.

Lewis, F. L.; Yesildirek; Liu, K. Multilayer neural-net robot controller with guaranteed tracking performance. **IEEE Transactions on Neural Networks**. v.2, n.2, p. 388-399, 1996.

Lewis, F.; Abdallah C. T.; Dawson D.M. **Control of Robot Manipulators**. Macmillan Publishing Company. 1993.

Li, X.; Xu, F.; Zhang, J.; Wang, S. A multilayer feed forward small-word neural network controller and its application on electrohydraulic actuation system. **Journal of Applies Mathematics**, p. 1-8, 2013.

Liang, F.; ElMaraghy, H. A. Model Reference Adaptive Neurocontrol of Flexible Joint Robot. **IEEE World Congress on Computational Intelligence**, p. 2765-2770, 1993.

Linsingen, I. V. **Fundamentos de Sistemas Hidráulicos**. Editora da UFSC. 2001.

Lo S. W. e Yang T. C. Closed-loop control of the blank holding force in sheet metal forming with a new embedded-type displacement sensor. **International Journal of Advanced Manufacturing Technology**, vl. 24, p. 553-559, 2004.

Machado, C. L. D.; Guenther, R.; Gomes S. C. P. Cascade control with friction compensation based on artificial neural networks for a hydraulic actuator. **ASME (IMECE2006)**, p. 121-130, Chicago, Illinois, USA, 2006.

Machado, C. L. D. **Compensação de Atrito em Atuadores Hidráulicos Utilizando Redes Neurais**. Dissertação de Mestrado, Universidade Federal de Santa Catarina. 2003.

Machado, C. L. D. **Controlador em Cascata com Adaptação de Parâmetros para Robôs Hidráulicos**. Tese de Doutorado, Universidade Federal de Santa Catarina. 2010.

Martin, H. **The Design of Hydraulic Components and Systems**. Redwood Books. 1995.

Martins, N. A.; Bertol, D. W.; Lombardi, W. C.; Pieri, E. R. D.; Neto, E. B. C. Neurocontrollers for Trajectory Tracking Problem of a Nonholonomic Mobile Robot. **Proceedings of the 17th World Congress The International Federation of Automatic Control**, Coreia do Sul. p. 5371-5376, 2008.

Masters, T. **Practical Neural Networks Recipes in C++**. Academic Press, Inc. 1993.

Mendel, J. M. Fuzzy Logic Systems for Engineering: A Tutorial. **Proceeding of IEEE**, v. 83, p. 345-377, 1995.

Merrit, H. E. **Hydraulic control systems**. John Wiley & Sons, 1967.

Mintsa, H. A.; Venugopal, R.; Kenné, J.; Belleau, C. Feedback Linearization-Based Position Control of an Electrohydraulic Servo System With Supply Pressure Uncertainty. **IEEE Transactions on Control Systems Technology**, v.20, n.4, p. 1092-1098, 2012.

Mohanti, A.; Yao, B. Integrated Direct/Indirect Adaptive Robust Control of Hydraulic Manipulators With Valve Deadband. **IEEE/ASME Transactions on Mechatronics**, p. 707-715, agosto, 2011.

Muraro, I. **Estudo das Características Comportamentais de Válvulas Proporcionais e Seus Efeitos nos Posicionadores Eletro-hidráulicos**. Dissertação de Mestrado, Universidade Federal de Santa Catarina. 2010.

Myer, K. **Mechanical Engineers' Handbook, Volume 2: Design, Instrumentation, and Controls**. Wiley, 2015.

Nachtwey, P. Closed-loop tuning secrets revealed! **Hydraulics & Pneumatics**, 2006. disponível em:
<http://hydraulicspneumatics.com/200/IndZone/Entertainment/Article/False/31840/IndZone-Entertainment>.

Naredra, K.; Parthasarathy, K. Identification and Control of Dynamical Systems Using Neural Networks. **IEEE Transaction on Neural Networks**, v.1, n.1, 1990.

Naredra, K. S. Neural Networks for Control: theory and practice. **Proceeding of IEEE**. v. 84, n.10, p. 1385-1406, 1996.

Noble, B.; Daniel, J. W. **Álgebra Linear Aplicada**. Phb. 1986.

Ogata, K. **Engenharia de Controle Moderno**. Prentice/Hall do Brasil, 1990.

Paim, C. C. **Técnicas de Controle Aplicadas a um Atuador Hidráulico**. Dissertação de Mestrado. Universidade Federal de Santa Catarina, 1997.

Park, J.; Sandenberg, I. W. Universal approximation using radial-basis-function networks . **Neural Comp**. v.3, p.246-257, 1991.

Park, J.; Lee, B.; Kang, S.; Kim, P. Y.; Kim, J. Online Learning Control of Hydraulic Excavators Based on Echo-State Networks. **IEEE Transactions on Automation Science and Engineering**, v. 14, n.1, p. 249-259, 2017.

Pedro, J.; Ekorn J. NARMA L-2 control of a nonlinear half-car servo-hydraulic vehicle suspension system. **Acta polytechnica hungarica**, v. 10, n. 4, pp. 4-6, 2013.

Pedro, J. O.; Dahunsi, O. A. Neural Network Based Feedback Linearization Control of a Servo-Hydraulic Vehicle Suspension System. **Int. J. Appl. Math. Comput. Sci**, v. 21, n.1, p. 137-147, 2011.

Pereira, P. I. I. **Análise Teórico-Experimental de Controladores para Sistemas Hidráulicos**. Dissertação de Mestrado, Universidade Federal de Santa Catarina. 2006.

Pereira, P. I. I. Guenther, R.; De Negri, V. J. Tracking control in hydraulic actuators using slow proportional directional valves. **ABCM Symposium Series in Mechatronics**, v. 3, p. 66-75, 2008.

Perondi, E. A. **Controle Não-Linear em Cascata de um Servoposicionador Hidráulico com Compensação de Atrito**. Tese de Doutorado, Universidade Federal de Santa Catarina, 2002.

Pluta, J. Hydraulic press with L. S. system for modelling of Plastic working operations. **Acta Montanistica Slovaca**, p. 152-157, 2008.

Polycarpou, M. M.; Ioannou P. A. Modelling, Identification and Stable Adaptive Control of Continuous-Time Nonlinear Dynamical Systems Using Neural Networks. **American Control Conference**, 1992.

Prabel, R.; Aschemann, H. Nonlinear Adaptive Backstepping Control of two Coupled Hydraulic Servo Cylinders. **American Control Conference (ACC)**, p. 1310-1315, Portland, US, 2014.

Prokhorov, D. V. Toyota Prius HEV neurocontrol and diagnostics. **Neural Networks**, n.21, p. 458-465, 2008.

Psaltis, D.; Sideris, A.; Yamamura, A. A. A Multilayered Neural Network Controller. **IEEE Control Systems Magazine**, p. 18-21, 1988.

Rong, H.; Bao, R; Zhao, G. Model Reference Adaptive Neural Control for Nonlinear Systems Based on Back-Propagation and Extreme Learning Machine. **2014 IEEE Ninth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)**, p. 1-6, Singapura, 2014.

Rost, K.; Wendt, K; Härtig, F. Evaluating a task-specific measurement uncertainty for gear measuring instruments via Monte Carlo simulation. **Precision Engineering**, p. 220-230, 2016.

Rozali, S. M.; Kamarudin, M.; Rahmat, M. F.; Husain, A. R. Asymptotic Tracking Position Control for Nonlinear Systems using Backstepping Technique. **Malaysian Technical Universities Conference on Engineering & Technology**, p. 255-263, 2012.

Ruan, J.; Pe, X.; Zhu, F.M. Identification and modeling of electrohydraulic force control of the material test system (MTS). *Journal of Physics: Conference Series*, v. 48, p. 1322-1326, 2006.

Rumelhart, D.; McClelland, J. L. **Parallel distributed processing**. Foundations The MIT Press, third printing : Vol. I. 1988.

Sadati, S. H.; Parvar, M. S.; Menhaj, M. B.; Bahrami, M. Backstepping Controller Design Using Neural Networks for a Fighter Aircraft. **European Journal of Control**, p. 516–526, 2007.

Sadegh, N. A Perceptron Network for Functional Identification and Control of Nonlinear Systems. **IEEE Transactions on Neural Networks**, v. 4, n.6, p. 982-988, 1993.

Sanner, R. M.; Slotine J. J. Gaussian networks for direct adaptive control. **IEEE Transaction on Neural Networks**, v. 6, n.3, p. 837-864, 1992.

Santolaria, J.; Gines, M. Uncertainty estimation in robot kinematic calibration. **Robotics and Computer-Integrated Manufacturing**, p. 370-384, 2013.

Seo, J., Venugopal, R; Kenne, J. Feedback linearization based control of a rotational hydraulic drive. **Control Engineering Practice**, n.15, p. 1495-1507, 2007.

Sirouspour, M. R.; Salcudean, S. On the nonlinear control of hydraulic servo-systems. **IEEE International Conference on Robotics and Automation**, v. 2, p. 1276–1282 - San Francisco, US , 2000.

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

Slotine, J. J.; Li, W. Adaptive Manipulator Control: A Case Study. **IEEE Transaction on Automatic Control**, v. 33, n. 11, p. 995-1003, 1988.

Smithson, S. C.; Yang, G.; Gross, W. J.; Meyer, B. H. Neural Networks Designing Neural Networks: Multi-Objective Hyper-Parameter Optimization. **Proceedings of the 35th International Conference on Computer-Aided Design, ICCAD 2016**, Austin, USA, 2016.

Sontag, E. D. On the observability of polynomial systems. **SIAM Journal Control and Optimization**, v. 17, p. 139-151, 1979.

Szpack, R. **Análise Teórico-Experimental das Pressões em Posicionadores Hidráulicos**. Dissertação de Mestrado, Universidade Federal de Santa Catarina. 2008.

Tamura, S.; Tateishi, M. Capabilities of a Four-Layered Feedforward Neural Network: Four Layers Versus Three. **IEEE Transactions on Neural Networks**, v. 8, n.2, p. 251-255, 1997.

Tao, G.; Kokotovic, P. V. **Adaptive Control of Systems With Actuator and Sensor Nonlinearities**. John Wiley & Sons, 1996.

Ursu, L.; Toader, A.; Halanay, A.; Balea, S. New stabilization and tracking control laws for electrohydraulic servo mechanisms. **European Journal of Control**, p. 65-80, 2013.

Utkin, V. I. Discontinuous Control Systems: State of Art in Theory and Applications [Conference]// IFAC - World Congress on Automatic Control. Preprints. - Munich, Germany : [s.n.], 1987. - Vol. Vol I. - pp. 75-94.

Utkin, V. I. **Sliding Mode Control in Electromechanical System**. Taylor Francis, 1999.

Utkin, V. I. Variable structure systems with sliding modes. **IEEE Transactions on Automatic Control**, v. 22, n.2, p. 212-222, 1997.

Valdiero, A. C.; Guenther, R.; De Pieri, E. R.; De Negri, V. J. Cascade Control of Hydraulic Driven Manipulators With Friction Compensation. **International Journal of Fluid Power**, v. 8, p. 7-16, 2007.

Valdiero, A. C. **Controle de Robôs Hidráulicos com Compensação de Atrito**. Tese de Doutorado, Universidade Federal de Santa Catarina, 2005.

Virvalo, T. Comparing Controllers in Hydraulic Motion Control. **Power Transmission and Motion Control**, p. 215-228, London, 2002.

Vossoughi, E.; Donath, M. Dynamic Feedback Linearization for Electro Hydraulically actuated control systems. **Journal of Dynamics Systems, Measurement and Control**, v. 117, p. 468-477, 1995.

Wang, J.; Gong, G.; Yang, H. Control of Bulk Modulus of Oil in Hydraulic Systems. **2008 IEEE/ASME International Conference on Advanced Intelligent Mechatronics**, p. 1390-1395, Xi'an, China, 2008.

Watton, J. **Fundamentos de Controle em Sistemas Fluidomecânicos**. LTC. 2012.

Werbos, P. J. Neural Networks for Control and System Identification. **Proceedings of 28th Conference of Decision and Control**, p. 260-265, Tampa, Florida, 1989.

Wubbeler, G.; Krystek, M.; Elster, C. Evaluation of measurement uncertainty and its numerical calculation by a Monte Carlo method. **Measurement Science and Technology**, n.19, 2008.

Xinliang, L.; Shan, J.; Jing, Z.; Wang, X. Adaptive Sliding Mode Position Control of Electro-Hydraulic Servo System with Single-Rod Actuators. **IEEE International Symposium on Robotic and Sensors Environments (ROSE)**, p. 878-983, Nanking, China, 2013.

Yang, G.; Yao, J.; Le, G.; Ma, D. Asymptotic output tracking control of electrohydraulic systems with unmatched disturbances. **IET Control Theory & Applications**, p. 2543-2551, 2016.

Yang, Y; Balakrishnan, S. N.; Tang, I; Landers, R. G. Electro-hydraulic piston control using neural MRAC based on a modified state observer. **American Control Conference On O'Farrel Street**, p. 25-30, San Francisco, CA, USA, 2011.

Yang, Y.; Balakrishnan, S. N.; Tang, L.; Landers, R. G. Electrohydraulic Control Using Neural MRAC Based on a Modified State Observer. **IEEE/ASME Transactions on Mechatronics**, v. 18, n.3, p. 867-877, junho, 2013.

Yao, B.; Bu, F.; Reedy, J. ; Chiu, G. Adaptive Robust Control of Single-Rod Hydraulic Actuators: Theory and Experiments. **IEEE/ASME Transactions on Mechatronics**. v.5, março, 2000.

Yao, J.; Wang, X.; Hu, S.; Fu, W. Adaline neural network-based adaptive inverse control for an electro-hydraulic servo system. **Journal of Vibration and Control**, p 1-8, 2011.

Yao, J.; Deng, W.; Jiao, Z. Adaptive Control of Hydraulic Actuators with LuGre Model Based Friction Compensation. **IEEE Transactions On Industrial Electronics**, 2015.

Yao, J., Jiao, Z.; Ma, D.; Extended-State-Observer-Based Output Feedback Nonlinear Robust Control of Hydraulic Systems With Backstepping. **IEEE Transactions On Industrial Electronics**, v. 61, n.11, p. 6285-6293, 2014a.

Yao, J., Jiao, Z.; Ma, D; Yan, L.. High-Accuracy Tracking Control of Hydraulic Rotary Actuators With Modeling Uncertainties. **IEEE/ASME Transactions on Mechatronics**, v.19, p. 633-641, abril, 2014b.

Yu, H.; Park, Y.; Cho, I.; Chung, W.; Kim, K. Design and Control of Multi-degree-of-freedom Shroud Nozzle Hydraulic Manipulator in Steel Manufacturing. **8th IEEE International Conference on Automation Science and Engineering**, p. 538-543, Seul, Korea, 2012.

Zhang, Y.; Gui, W. Compensation for secondary uncertainty in electro-hydraulic servo system by gain adaptive sliding mode variable structure control. **J. Cent. South Univ. Technol.**, p. 256-263, 2008.

Zhao, H.; Dang, K.; Lin, T. A online-trained neural network controller for electro-hydraulic servo system. **Proceeding of the 4th World Congress on Intelligent Control and Automation**, p. 2983-2986, Shangai, China, 2002.

Zibin, X.; Jianqing, M.; Jian, R. Adaptive Backstepping Neural Network Control of Electro-Hydraulic Position Servo System. **2nd International Symposium on Systems and Control in Aerospace and Astronautics**, pp. 1-4, Shenzhen, 2008.

APÊNDICE A. RESULTADOS EXPERIMENTAIS NÃO UTILIZADOS NO MODELO.

Neste Apêndice, apresentam-se alguns procedimentos experimentais de identificação das características da planta. Esses experimentos não são utilizados diretamente no modelo apresentado no Capítulo 2, mas são importantes para confirmar algumas considerações e simplificações adotadas no processo de construção do modelo.

A.1. Parâmetros da Dinâmica da válvula

O ensaio para a determinação dos parâmetros da válvula realizado pelo fabricante é descrito por meio da Figura A.1 e consiste na determinação da resposta em frequência da válvula através da aplicação na entrada da mesma de sinais senoidais de diferentes frequências e a medição na saída do sensor LVDT do sinal resultante. O catálogo da válvula traz informações para sinais de amplitude 10 V (100%) e 0,5 V (5%).

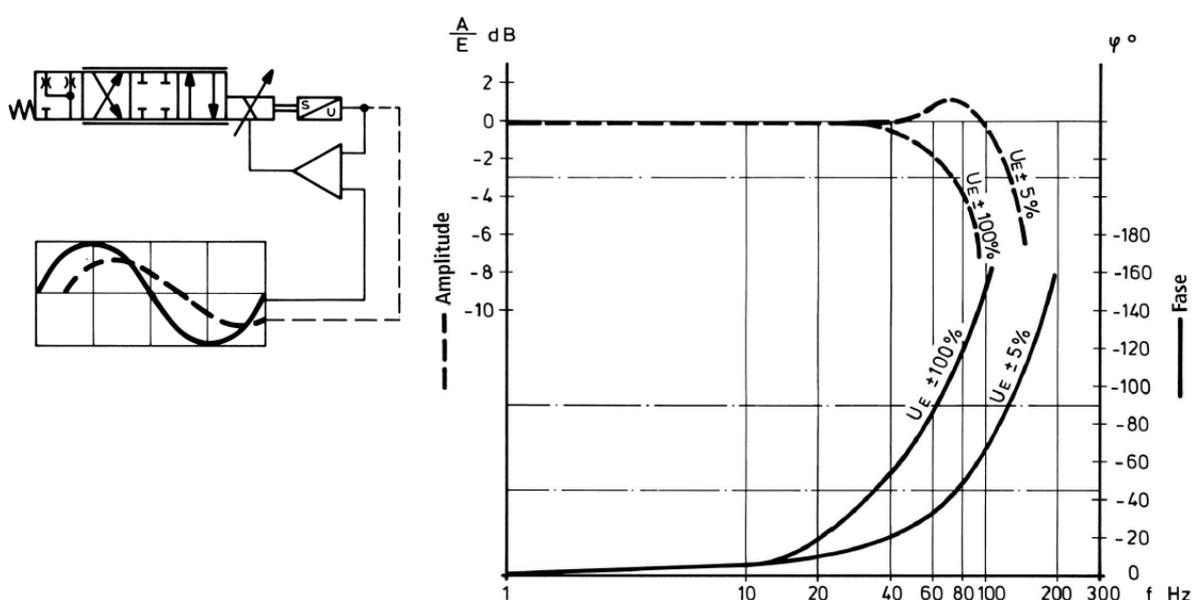


Figura A.1 - Resposta em frequência da válvula - catálogo do fabricante.

No presente trabalho, o ensaio experimental da resposta em frequência foi realizado para as mesmas amplitudes de 0,5 V e 10 V ilustradas no catálogo da válvula, acrescentando

ainda uma amplitude intermediária de 5 V, com objetivo de avaliar a aproximação dos dados do mesmo. Os resultados são ilustrados por meio da Figura A.2.

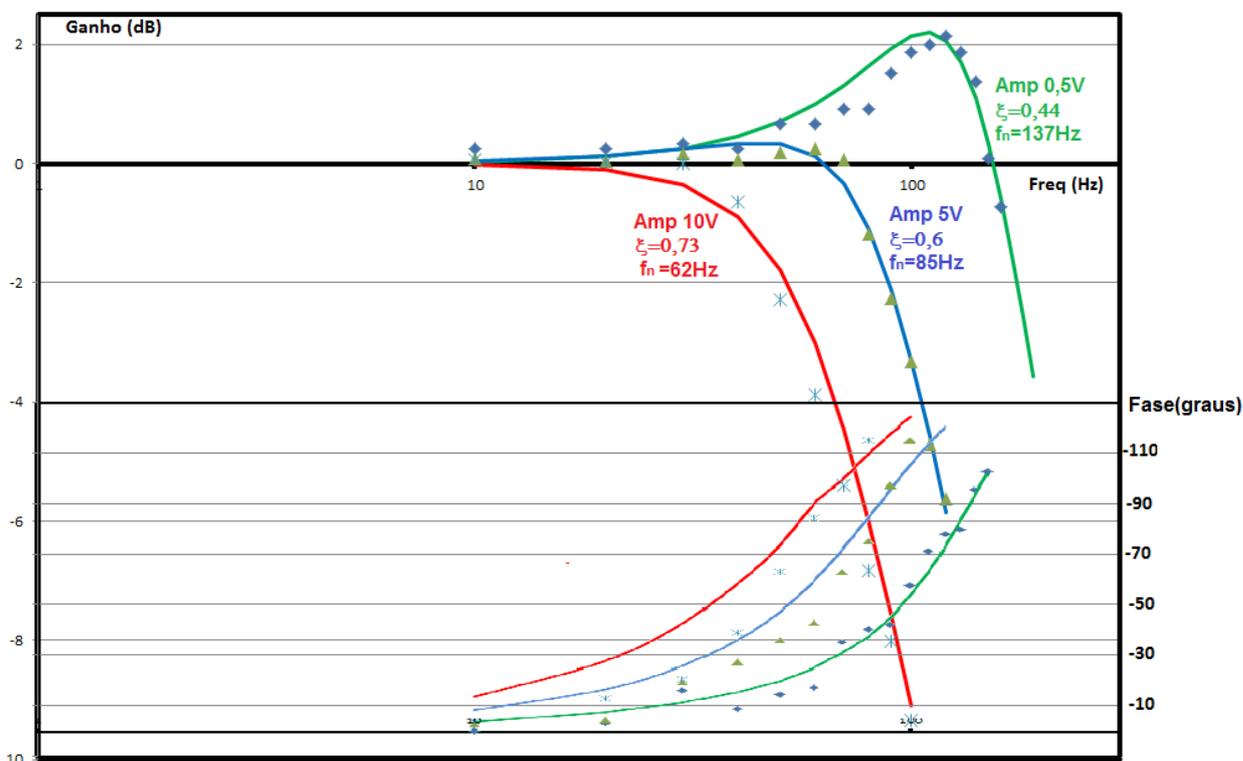


Figura A.2 - Resposta em frequência – levantamento experimental.

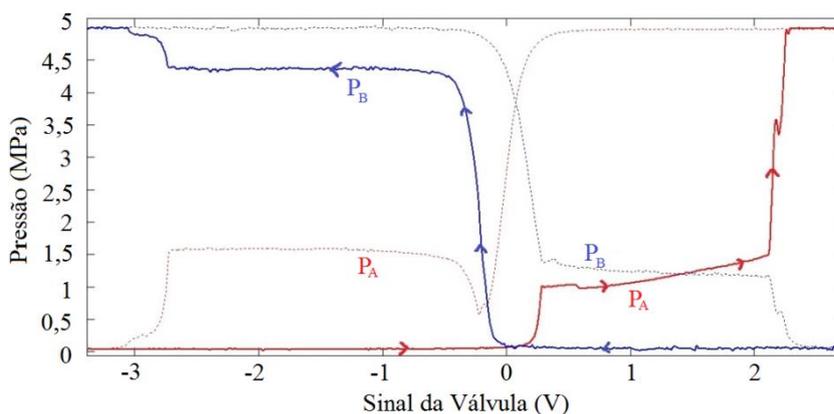
Para fins de modelagem, Cunha, 2001, considera uma largura de banda média entre os dois valores extremos fornecidos pelo catálogo.

Adota-se, no presente trabalho, igual procedimento, considerando como dinâmica da válvula o seu comportamento médio, associado à aplicação de sinais senoidais de 5V de amplitude. Assim, de acordo com o levantamento experimental ilustrado na Figura A.2, na Equação (2.71) tem-se: $\omega_v = 533,8$ rad/s ou 85 Hz, $\xi = 0,6$ e $K=1$.

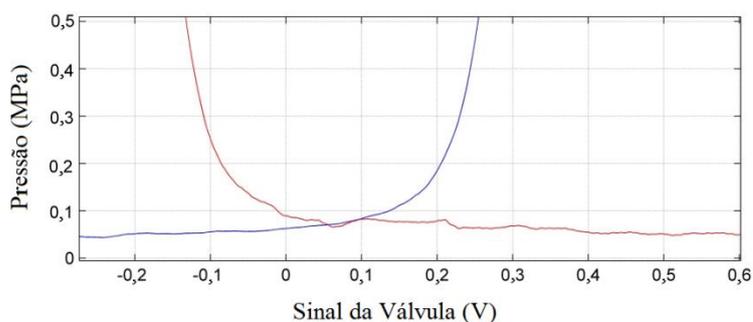
A.2. Medição da zona morta

A zona morta é normalmente determinada com o auxílio de um medidor de vazão, variando-se lentamente a entrada de sinal da válvula, em uma situação onde a pressão de carga é considerada próxima de zero, mantendo-se uma pressão de suprimento constante, como em Bu e Yao, 2000 e Valdiero, 2005. No presente trabalho, adotou-se o método proposto por Valdiero, 2005, no qual a zona morta é determinada a partir da variação das pressões nas câmaras do cilindro durante a aplicação de um sinal senoidal relativamente lento na entrada da válvula, cuja amplitude deve ser igual aos limites máximo e mínimo de variação do sinal de entrada.

A Figura A.3 ilustra o experimento de Valdiero, 2005, realizado na válvula utilizada no presente trabalho.



(a) Ensaio completo.



(b) Ensaio na região da zona morta.

Figura A.3 – Variação das pressões medidas na bancada experimental.

Pela análise do experimento, realizada por meio da inspeção da Figura A.3, pode-se concluir que a zona morta é muito pequena, compreendida entre -0,1 e 0,2 V. Nessa região ocorre a sobreposição (*overlap*) do carretel com o pórtilo, mas não há ausência de vazão (pois há movimento do pistão). A zona morta propriamente dita costuma ser atribuída a válvulas de centro fechado, como visto em várias referências [Merrit, 1967; De Negri, 2001; Linsingen, 2001; Mohanti e Yao, 2011]. No presente trabalho, optou-se pela não inclusão da zona morta no modelo do servoposicionador pelas razões anteriormente citadas na Seção 2.1.4.

APÊNDICE B. FORÇA DE ATRITO

A força de atrito pode ser definida como a força de resistência ao movimento relativo entre dois corpos [Machado, 2003]. O fenômeno do atrito é uma sobreposição de efeitos físicos:

Atrito de Coulomb – O modelo de atrito proposto por Coulomb e mostrado na Figura B.1 estabelece que a força de atrito seja independente da área de contato e da velocidade de deslizamento e proporcional a força normal ao plano e a um coeficiente de atrito μ . Segundo o modelo de Coulomb, existe uma descontinuidade na força de atrito quando a velocidade é nula.

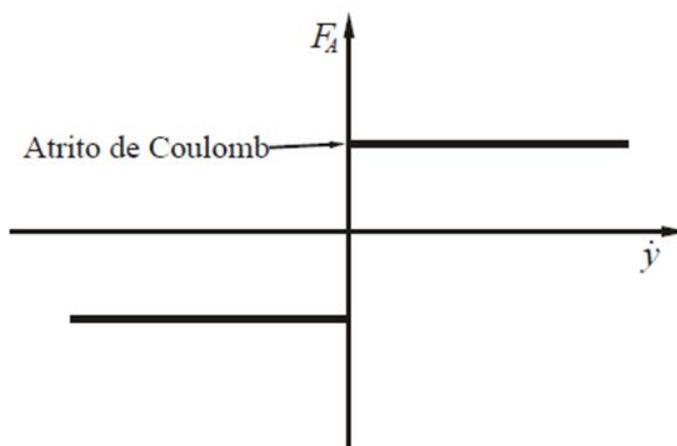


Figura B.1 - Modelo de Atrito de Coulomb [Machado, 2003]

Atrito Estático – A Força de atrito estático F_c é aquela que se opõe ao início do movimento e ocorre, portanto, em velocidade nula. A Figura B.2 mostra o modelo.

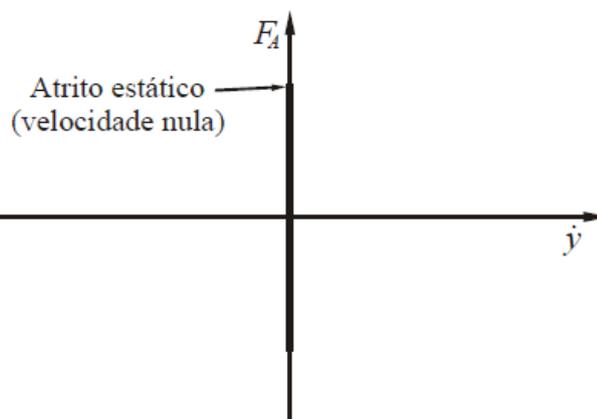


Figura B.2 - Força de atrito estático

Atrito viscoso – No atrito viscoso a força de atrito é proporcional à velocidade. Esse fenômeno ocorre em superfícies lubrificadas e não possui descontinuidade em velocidade nula. O modelo é descrito na Figura B.3.

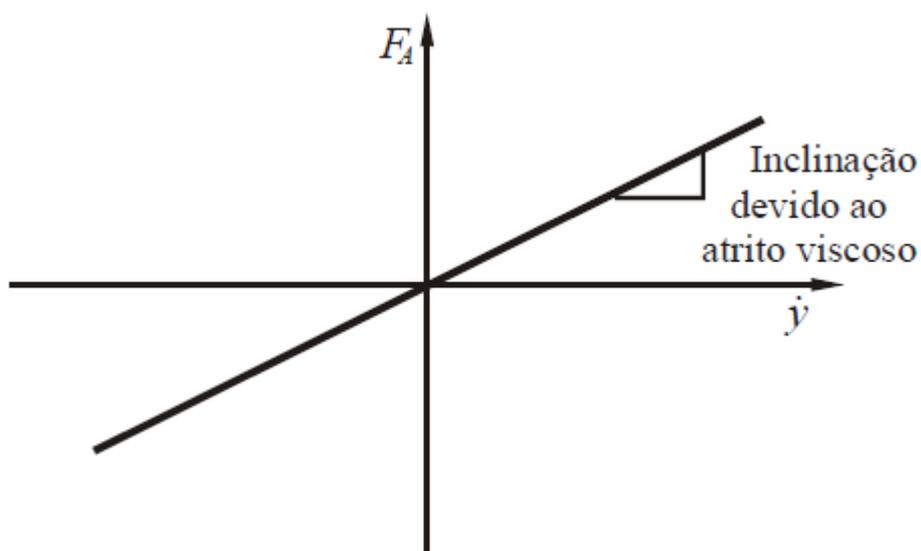


Figura B.3 - Atrito viscoso [Machado, 2003].

Efeito Stribeck – Associado ao atrito viscoso, tem-se o efeito Stribeck que consiste em uma rápida redução na força de atrito, que ocorre quando o corpo parte da velocidade nula em superfícies lubrificadas.

O modelo completo do atrito deve contemplar a sobreposição de todos os efeitos anteriormente descritos. A Figura B.4 ilustra tal modelo.

No trabalho de Armstrong e Canudas de Wit, 1996, destacam-se alguns fenômenos importantes em relação ao atrito que ocorrem em baixas velocidades de operação:

- Oscilações em torno da posição desejada – *hunting*;
- Permanece parado – *standstill*;
- Adere desliza – *stick slip*.

De acordo com Machado, 2003, o efeito *stick slip* pode ser observado experimentalmente em um bloco sendo deslocado pela força de uma mola. A força aplicada deforma a mola e em determinado momento a deformação é tal que proporciona o deslocamento da massa, vencendo o atrito estático. Com a massa em movimento, parte da força é utilizada para acelerar a mesma, diminuindo a força sobre a mola. Quando a força aplicada na massa cai abaixo da força de atrito, o movimento cessa novamente. O movimento é, portanto, intermitente, com paradas (adere ou *stick*) e deslizamentos (desliza ou *slip*). A Figura B.5 ilustra o fenômeno.

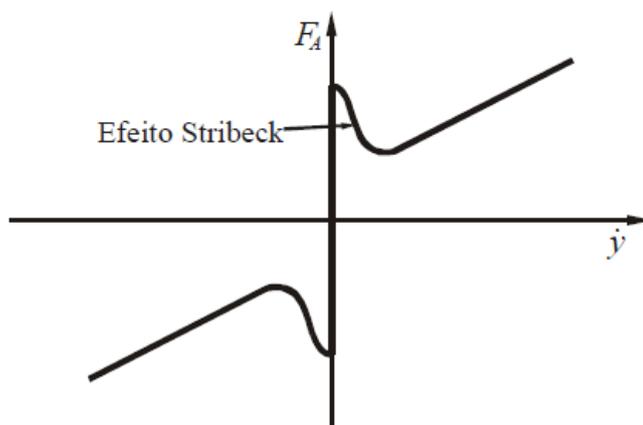


Figura B.4 - Modelo completo de atrito [Machado, 2003].

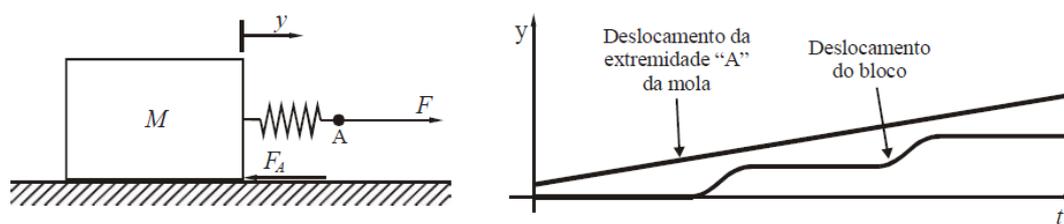


Figura B.5 - Efeito Adere Desliza [Machado, 2003].

APÊNDICE C. EQUIPAMENTOS UTILIZADOS NOS EXPERIMENTOS E INCERTEZAS.

Neste Apêndice é feita uma descrição sucinta dos equipamentos utilizados na parte experimental do presente trabalho, bem como um estudo das incertezas no controlador em cascata neural proposto.

C.1. Descrição dos equipamentos hidráulicos

Na Tabela C.1 encontram-se as principais características técnicas da servoválvula utilizada nos experimentos. As demais características foram expostas ao longo do trabalho. A válvula pode ser visualizada na Figura C.1.

Tabela C.1- Características da servoválvula

Fabricante	Bosch Rexroth
Nome	4WRPEH 6
Vazão nominal	24 L/min
Razão entre orifícios	1:1
Pressão diferencial	70 bar, 35 bar por aresta
Frequência de resposta 5%	80 Hz
Tensão de alimentação	24 Vcc
Entrada de comando	± 10 V
Característica de vazão	linear
Pressão máxima de operação	315 bar
Histerese	$\leq 0,2\%$
Equalização zero	$\pm 1\%$

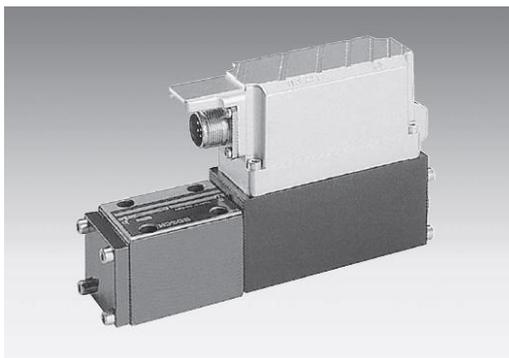


Figura C.1- Servoválvula

Na Tabela C.2 encontram-se as principais características técnicas do cilindro utilizado nos experimentos. O mesmo pode ser visualizado na Figura C.2.

Tabela C.2 - Características do cilindro hidráulico

Fabricante	Bosch Rexroth
Nome	CDT3
Curso	200 mm
tipo	diferencial
Pressão Nominal	160 bar
Diâmetro do êmbolo	25 mm
Diâmetro da haste	18 mm
Relação entre áreas	2,08
Área do êmbolo	4,91 cm ²

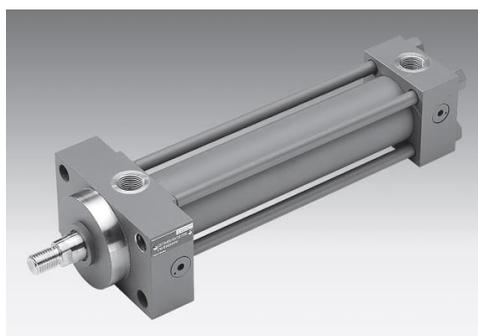


Figura C.2- Cilindro Hidráulico.

A Figura C.3 mostra a unidade de potência hidráulica utilizada no presente trabalho. A Tabela C.3 descreve as características da mesma.



Figura C.3 - Unidade de Potência e Condicionamento Hidráulicos.

Tabela C.3 - Características da unidade de potência e condicionamento hidráulicos.

vazão máxima	6,55 L/min
pressão máxima	250 bar
potência motor	3 CV

C.2. Descrição dos sensores

A Régua Potenciométrica é descrita na Tabela C.4 e na Figura C.4.

Tabela C.4 - Características da Régua Potenciométrica

Fabricante	Novotechnic
Nome	TLH300
Curso	300 mm
Linearidade	$\pm 0,06\%$ fs
Precisão	0,01 mm
Tensão máxima	42 V
Corrente máxima	10 mA

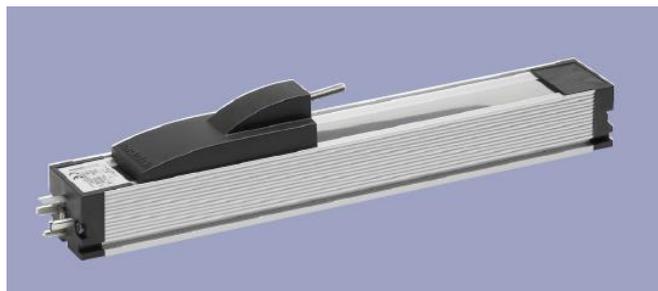


Figura C.4 - Régua Potenciométrica

Os sensores de pressão são descritos nas Tabelas C.5 e C.6 e nas figuras C.5 e C.6.



Figura C.5 - Sensor da Pressão A.

Os Condicionadores de sinais são equipamentos pertencentes a placa dSpace DS1104. Suas características são descritas nas Tabelas C.7 e C.8.

Tabela C.5 - Características do Sensor da Pressão A.

Fabricante	Bosch Rexroth
Nome	HM 18
Valor de pressão de fundo de escala (fs)	210 bar
Resposta dinâmica	< 1 ms
Precisão (histerese e não linearidade inclusas)	< 0,5% fs
Tensão de Alimentação	14 a 30 Vcc
Saída	0-10 V

Tabela C.6 - Características do Sensor da Pressão B.

Fabricante	Huba (No Brasil, Novus)
Nome	TP-691
Valor de pressão de fundo de escala (fs)	400 bar
Resposta dinâmica	< 5 ms
Precisão (histerese e não linearidade inclusas)	< 0,3% fs
Tensão de Alimentação	11 a 33 Vcc
Saída	4-20 mA



Figura C.6 - Sensor da Pressão B.

Tabela C.7 - Características Conversor A/D.

Fabricante	dSpace
Nome	DS-1104
Equipamento	Conversor ADC
Resolução	16 bits
Alcance da Entrada	± 10 V
Tempo de conversão	± 2 μ s
Erro de <i>offset</i>	± 5 mV
Erro de ganho	$\pm 0,25\%$ Fs

Tabela C.8 - Características Conversor D/A.

Fabricante	dSpace
Nome	DS-1104
Equipamento	Conversor DAC
Resolução	16 bits
Alcance da Saída	± 10 V
Tempo de conversão	< 10 μ s
Erro de <i>offset</i>	± 1 mV
Erro de ganho	$\pm 0,1\%$ Fs
Corrente máxima	5 mA

O transmissor de temperatura utilizado no presente trabalho é ilustrado na Figura C.4. As características do mesmo são descritas por meio da Tabela C.9. O sensor utilizado para a medição é um Pt100 a três fios.



Figura C.7 – Transmissor de Temperatura.

Tabela C.9 - Características Transmissor de Temperatura.

Fabricante	Novus
Equipamento	TxRail
Saida	0 a 10 Vcc linear
Resolução	12 bits (2,5 mV)
Resposta	≤ 100 ms
Erro máximo (Pt100)	$\pm 1,7$ °C

C.3. Filtros e incertezas dos sensores.

Os filtros utilizados no presente trabalho são todos filtros digitais Butterworth de primeira ordem definidos no Simulink. As frequências de corte dos mesmos estão descritas na Tabela C.10.

Tabela C.10 - Frequência de corte filtros (Butterworth primeira ordem)

Filtro	Frequência de corte (rad/s)
Posição	100
Velocidade	20
Aceleração	16
Pressões	50
Derivada da Força	20
Força	20

As incertezas do tipo A [JCGM, 2008a] dos sensores do presente trabalho foram obtidas por meio de medidas experimentais. As grandezas foram medidas após a aplicação das constantes de calibração. Os condicionadores de sinal não foram considerados por serem elementos passivos (somente resistores). Dois filtros analógicos de primeira ordem de

frequência de corte de 1000 rad/s na saída dos condicionadores para evitar picos de alta frequência prejudiciais à placa de aquisição de dados também não são analisados.

A Figura C.8 mostra as medidas do mesurando posição na saída do filtro digital em relação a uma medida de 0,1 m. A Tabela C.11 mostra que a distribuição de probabilidade da medida.

Tabela C.11 - Estatísticas da Medida de Posição

Desvio médio	-0,0018 mm
Desvio padrão	0,012 mm
Desvio máximo positivo	0,27 mm
Desvio máximo negativo	-0,35 mm

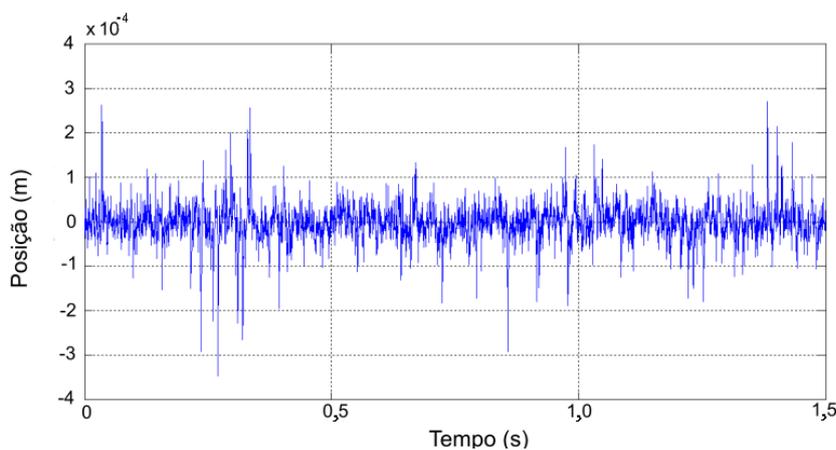


Figura C.8 - Medida de Posição

A Figura C.9 mostra as medidas do mesurando pressão A na saída do filtro digital em relação a uma medida de 10 bar. A Tabela C.12 mostra que a distribuição de probabilidade.

Tabela C.12 - Estatísticas da medida da Pressão A.

Média	0,0011 bar
Desvio padrão	0,0974 bar
Desvio máximo positivo	0,85 bar
Desvio máximo negativo	-1,2 bar

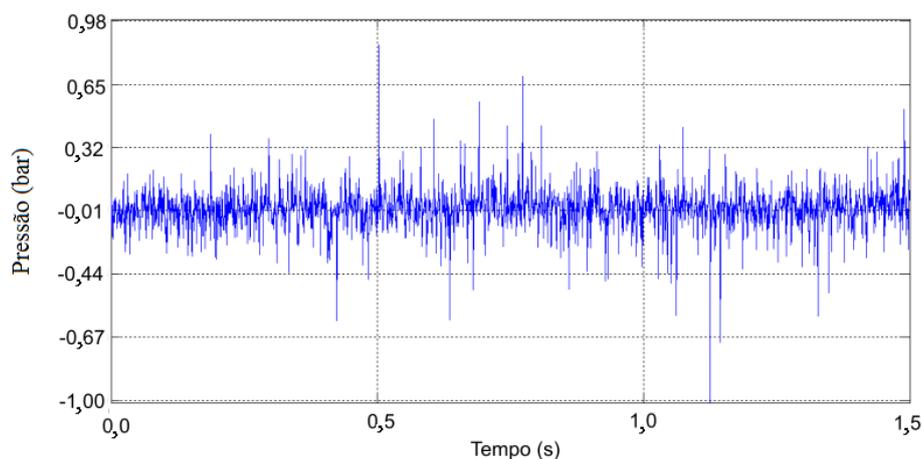


Figura C.9 - Medida da Pressão A.

A Figura C.10 mostra as medidas da pressão B na saída do filtro digital em relação a uma medida de 10 bar. A Tabela C.13 mostra que a distribuição de probabilidade.

Tabela C.13 – Estatísticas da medida da Pressão B.

Média	0 bar
Desvio padrão	0,3698 bar
Desvio máximo positivo	3,963 bar
Desvio máximo negativo	-2,7163 bar

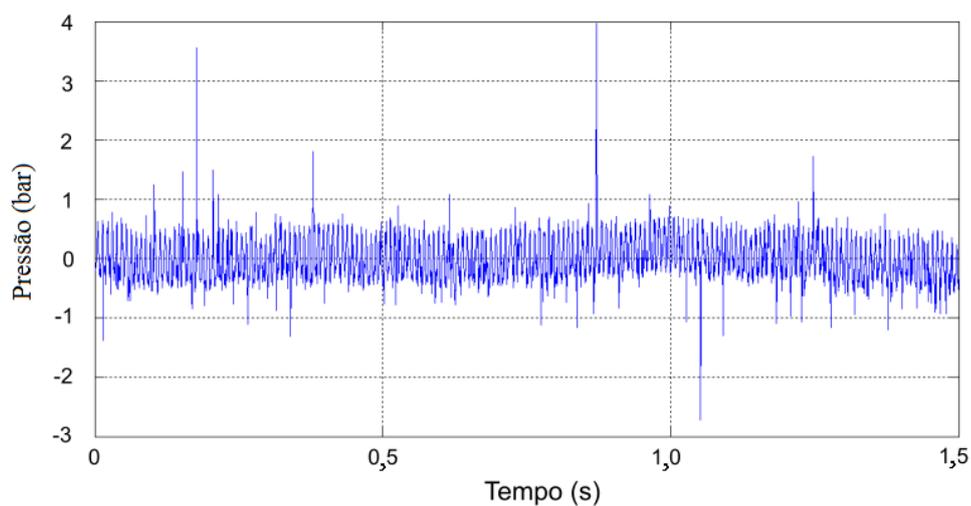


Figura C.10 - Medida da Pressão B.

As incertezas dinâmicas não foram analisadas porque a trajetória envolvida tem frequências baixas, de aproximadamente 0,15 Hz, e a resposta dinâmica mais lenta encontrada para os sensores é de 200 Hz, segundo as informações de catálogo.

C.4. Estudo das incertezas na medição do erro de posição do controlador em cascata neural.

O erro em sistemas de controle em malha fechada é definido como sendo a diferença entre um sinal de referência desejado e o sinal efetivamente medido na saída da planta [Franklin, 2014]. Em metrologia mecânica, no entanto, a medida absoluta e determinística do erro está sempre associada a uma medida estatística, chamada incerteza [Coleman e Steele, 2009]. Segundo [JCGM, 2008a], incerteza é o parâmetro não negativo que caracteriza a dispersão dos valores atribuídos a um mesurando, com base nas informações utilizadas, não sendo possível comparar dois resultados oriundos de medições sem a presença da incerteza em uma faixa de dispersão estatística com um determinado nível de confiança. Em vários trabalhos experimentais na área de sistemas de controle, com foco aqui na área de atuadores hidráulicos, tais como [Prabel e Aschemann, 2014; Yang, et al. 2011; Kim, et al. 2012], são encontradas comparações de desempenho entre diferentes controladores, aplicados a mesma planta, considerando somente medições de erro sem a presença da incerteza. Devido ao fato das comparações serem realizadas sobre as mesmas condições de repetibilidade [JCGM 2008a], tais comparações levam em conta somente o valor absoluto observado para o erro segundo um determinado critério estatístico, como a raiz do erro quadrático médio (RMSE), ao longo de um intervalo de tempo. Nenhuma informação, geralmente, é fornecida sobre a incerteza em relação ao erro medido em um instante de tempo t , informação esta que é importante para a comparação com algum outro experimento realizado em uma configuração experimental diferente desta do presente trabalho. Os modelos matemáticos adotados para a descrição do comportamento dinâmico de um atuador hidráulico, que é o objeto de estudo do presente trabalho, são constituídos por sistemas não lineares de terceira ou quarta ordem, conforme apresentado no Capítulo 1. Essas características conferem uma alta complexidade em termos da obtenção analítica das incertezas dos mesurandos envolvidos quando na utilização do método GUM (Guia para Medição de Incertezas), conforme a sequência de passos definida em JCGM, 2008a, para esse método. Segundo Santolaria e Gines, 2013, o

método Monte Carlo constitui uma alternativa para o cálculo de incertezas quando na presença de sistemas complexos e não lineares. Trabalhos como Canaves e Pompeia, 2006, Wubbeler et al., 2008, mostram que os resultados obtidos são semelhantes ao método GUM. A limitação principal do método Monte Carlo, segundo JCGM, 2008b, encontra-se no elevado número de interações necessário à convergência do mesmo.

No presente trabalho, as distribuições de probabilidade dos mesurandos, necessárias à aplicação do método Monte Carlo, são obtidas por meio dos catálogos dos fabricantes dos sensores utilizados e também de forma experimental, utilizando medidas em repetibilidade em relação à cada sensor, conforme apresentado na Seção C.3. Com o objetivo de determinar a incerteza na medição do erro de posição em um dado instante t , esses dados são aplicados em uma simulação utilizando o método Monte Carlo. A simulação é feita utilizando o modelo matemático não linear do atuador hidráulico apresentado no Capítulo 2 e o controlador em cascata neural atuando em um controle de trajetória de posição em malha fechada. Uma metodologia de normalização das medidas de erro de posição é então proposta com o objetivo de encontrar uma incerteza média ao longo da trajetória de posição. Utilizando os resultados do erro de posição resultante da simulação, a distribuição de probabilidade da incerteza desse erro é então obtida. Com o objetivo de validar o procedimento, os resultados são comparados com a aplicação do mesmo método em dados oriundos de um controle de trajetória do mesmo atuador hidráulico realizado na bancada de testes descrita no Capítulo 2.

C.4.1 Métodos de análise de incertezas.

Realiza-se, a seguir, uma sucinta descrição dos métodos de análise de incerteza mais utilizados [Jornada e Jornada, 2007].

C.4.1.1. Método GUM.

O método GUM é descrito em detalhes em JCGM, 2008a. O método consiste em um guia para os laboratórios de metrologia no sentido de padronizar os procedimentos para o levantamento das incertezas de um mesurando. Segundo Santolaria e Gines, 2013, o método constitui-se na elaboração de um modelo matemático, que é utilizado como base para a propagação das incertezas. O modelo matemático em questão deverá incluir todas as contribuições relevantes em termos de incerteza para o ensaio ou calibração. A incerteza global é estimada pela propagação de todas as contribuições individuais das incertezas através

do modelo matemático. O modelo matemático criado é baseado na lei da propagação das incertezas, que consiste na expansão de primeira ordem da serie de Taylor de cada mesurando [JCGM, 2008a]. Segundo Jornada e Jornada, 2007, para a aplicação do método, as seguintes premissas devem ser válidas:

- i. linearização suficiente do modelo matemático da medição;
- ii. aplicabilidade do Teorema do Limite Central, implicando na representação da função densidade de probabilidade do mensurando através de uma distribuição Normal (Gaussiana) ou tipo t-Student, com média e desvio-padrão conhecidos;
- iii. adequação da equação de Welch-Satterthwaite [Coleman e Steele, 2009].

Alguns trabalhos como Santolaria e Gines, 2013 e Rost et al.,2016, mostram que, para sistemas constituídos de muitas não linearidades, tais como manipuladores robóticos, por exemplo, o método é de difícil aplicação, pois não se encontram condições de estabelecer uma linearização adequada que venha a possibilitar a propagação das incertezas. Pode-se afirmar, com base no Capítulo 2, que o atuador hidráulico se encaixa nessa condição, sendo difícil, senão inviável, a aplicação do método para esse tipo de sistema.

C.4.1.2. Método Monte Carlo.

A Simulação de Monte Carlo, descrita em detalhes em JCGM, 2008b, utiliza informações *a priori* das grandezas de entrada que afetam a incerteza que se deseja encontrar, e, através da propagação das distribuições de probabilidade dessas grandezas de entrada, gera n números aleatórios, obtendo uma probabilidade *a posteriori*. Nesse sentido, o método de Monte Carlo, diferentemente do método do GUM, utiliza o conceito de propagação das distribuições de probabilidade das grandezas de entrada, ao invés de somente propagar as suas incertezas. Segundo Jornada e Jornada, 2007, a simulação Monte Carlo consiste em um método exato para o cálculo da incerteza, no qual se assume distribuições de probabilidade apropriadas (como retangular, uniforme, normal, triangular, entre outras) para as fontes de incerteza do ensaio ou calibração. Essas distribuições são propagadas através da equação da medição desejada e os valores para a saída da mesma são obtidos. A incerteza resultante será calculada de acordo com um determinado nível da confiança, normalmente 95%, após um grande número de repetições executadas dessas propagações. Como vantagem do método, os

procedimentos adotados pela simulação Monte Carlo dispensam os cálculos das derivadas parciais, o que em muitos casos pode ser um fator de complicada obtenção. Além disso, o método dispensa a atribuição de graus de liberdade para as fontes de incerteza e não requer a linearização do modelo matemático da medição [Jornada e Jornada, 2007]. Uma desvantagem do método é a carga computacional necessária e a quantidade mínima de interações para a convergência. Segundo JCGM, 2008b são necessárias, no mínimo, 10.000 interações. Alguns trabalhos na área de manipuladores robóticos, tais como Santolaria e Gines, 2013, e Rost et al., 2016, são exemplos da aplicação do método em sistemas não lineares.

C.4.2. Cálculo das incertezas do controlador em cascata neural utilizando a simulação Monte Carlo.

De acordo com JCGM, 2008b, para a aplicação do método Monte Carlo deve-se, primeiramente, definir as distribuições de probabilidade que serão propagadas através de modelo de simulação. O modelo de simulação adotado é definido por meio das equações da Tabela 2.4. A simulação é realizada considerando o seguimento de uma trajetória de posição desejada em malha fechada, onde as leis de controle utilizadas são definidas por meio das equações (4.42), (4.43) e (4.44). A trajetória de posição desejada é definida por meio da Equação (3.1) e ilustrada pela Figura 3.1 As distribuições de probabilidade da posição, temperatura do fluido hidráulico e das pressões medidas são propagadas através do modelo. A velocidade e aceleração são obtidas por derivação numérica. Segundo as recomendações de JCGM, 2008b, são adotadas distribuições de probabilidade retangulares para as incertezas fornecidas por meio dos dados de catálogo dos instrumentos de medição. Complementando essas informações, utilizam-se as distribuições de probabilidade do tipo A, definidas por meio da Seção C.3. A Figura C.11 ilustra o processo de simulação e as tabelas C.14 e C.15 resumam as distribuições de probabilidade propagadas.

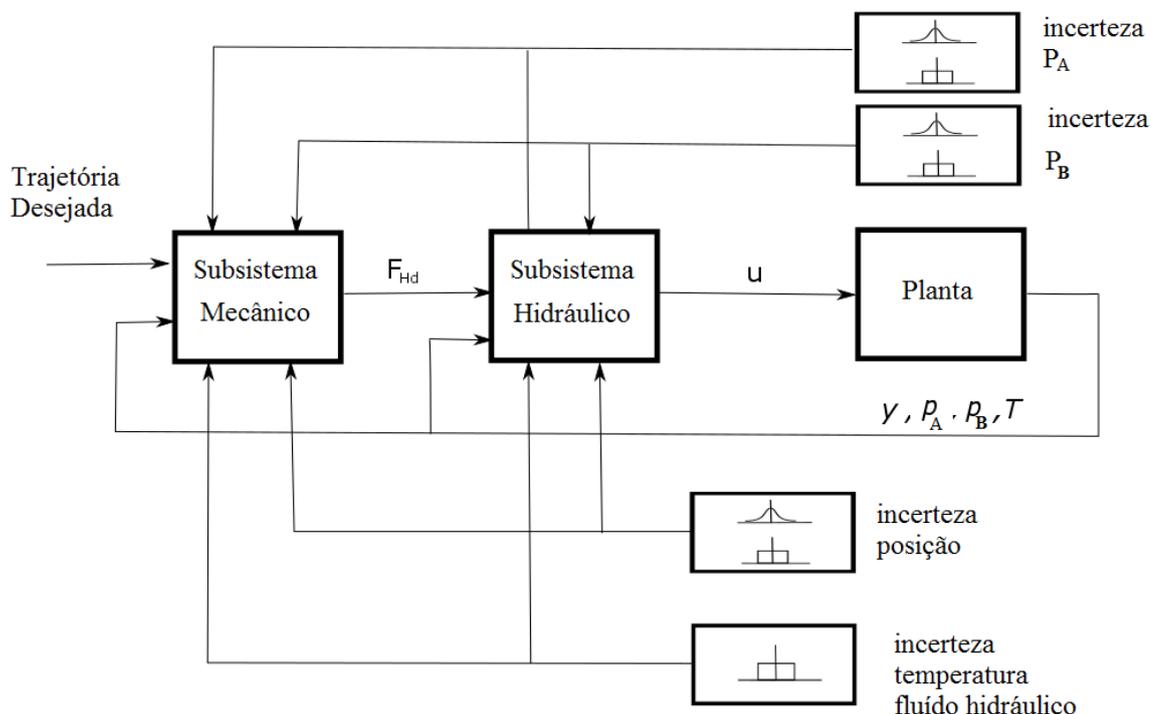


Figura C.11 – Simulação Monte Carlo.

Tabela C.14. Distribuições de probabilidade retangulares dos mesurandos.

Limites	Temperatura (°C)	Pressão A (MPa)	Pressão B (MPa)	Posição (m)
Limite superior	1,7	0,105	0,12	$1,0 \cdot 10^{-5}$
Limite Inferior	-1,7	-0,105	-0,12	$-1,0 \cdot 10^{-5}$

Tabela C.15. Distribuições normais de probabilidade dos mesurandos.

parâmetros	Pressão A (MPa)	Pressão B (MPa)	Posição (m)
média	0,00011	0	$-1,8 \cdot 10^{-6}$
Desvio padrão	0,00974	0,03698	$1,2 \cdot 10^{-5}$

A distribuição de probabilidade da incerteza a ser definida à posteriori tem como mesurando o erro de posição. De acordo com Watton, 2012, a frequência natural do conjunto massa-pistão é diferente para cada posição do pistão, resultando, portanto, em uma resposta dinâmica diferente a cada posição. Tal propriedade faz com que a propagação das distribuições de probabilidade através do modelo resulte em diferentes probabilidades de

incerteza para o erro de posição em cada diferente posição do pistão. O resultado procurado, porém, é uma distribuição de probabilidade para o erro de posição que seja representativa, independente da posição do pistão. Para contornar esse problema propõe-se a seguinte metodologia:

- i. Realiza-se m repetições do controle do seguimento da trajetória descrita pela Figura 3.1 ao longo do tempo;
- ii. Separa-se os valores das repetições de posição em dois diferentes grupos: velocidades positivas (pistão movendo-se para frente) e negativas (pistão movendo-se para trás).
- iii. Define-se n intervalos fixos de posição na trajetória. Por exemplo: se o intervalo definido estabelece o agrupamento dos resultados a cada 0,1 mm, então se tem que entre a posição 3 mm e 3,1 mm haverá k amostras na velocidade positiva e outras k amostras na velocidade negativa observadas para esse intervalo dentro das m repetições da trajetória da Figura 3.1 realizadas.
- iv. Por meio da Equação (C.1), encontra-se a média do erro das k amostras dentro de cada intervalo em ambos os grupos;
- v. Através da Equação (C.2), encontra-se os desvios em relação ao erro médio de cada amostra k contida em cada intervalo em ambos os grupos;
- vi. Agrupa-se todos os desvios encontrados nos dois grupos em um grande grupo de dados e constrói-se uma distribuição normal com os mesmos.

$$\mu(j) = \sum_{i=1}^{k_j} \frac{e_j(i)}{k_j} \text{ para } j = 1, 2, \dots, n, \quad (\text{C.1})$$

$$\sigma_j(i) = e_j(i) - \mu(j) \text{ para } i = 1, 2, \dots, k \text{ e } j = 1, 2, \dots, n. \quad (\text{C.2})$$

Seguindo essa metodologia, chega-se a uma distribuição de probabilidade para a incerteza do erro de posição que é válida para toda a trajetória e que traduz o comportamento médio da incerteza ao longo da mesma, com um determinado intervalo de confiança.

As simulações do presente trabalho são realizadas utilizando o software Simulink, do Matlab. O período de amostragem utilizado é de 0,5 ms, o que proporciona um total de 28.000 amostras para a trajetória da Figura 3.1. As distribuições de probabilidade descritas por meio

das Tabelas C.11 e C.12 são propagadas utilizando funções randômicas existentes no Simulink, que são somadas com os respectivos valores atribuídos aos mesurandos em questão. O controle de seguimento de trajetória consta de 4 repetições da trajetória de referência da Figura 3.1 A temperatura do fluido hidráulico atribuída na simulação é de 30 °C. O erro de posição resultante da simulação é ilustrado na Figura C.12 A metodologia é aplicada a esses dados considerando um intervalo de posição de 0,1 mm para cada intervalo k de amostras, conforme as equações (A.1) e (A.2), resultando na distribuição de probabilidade para a incerteza do erro ilustrada na Figura C.13.

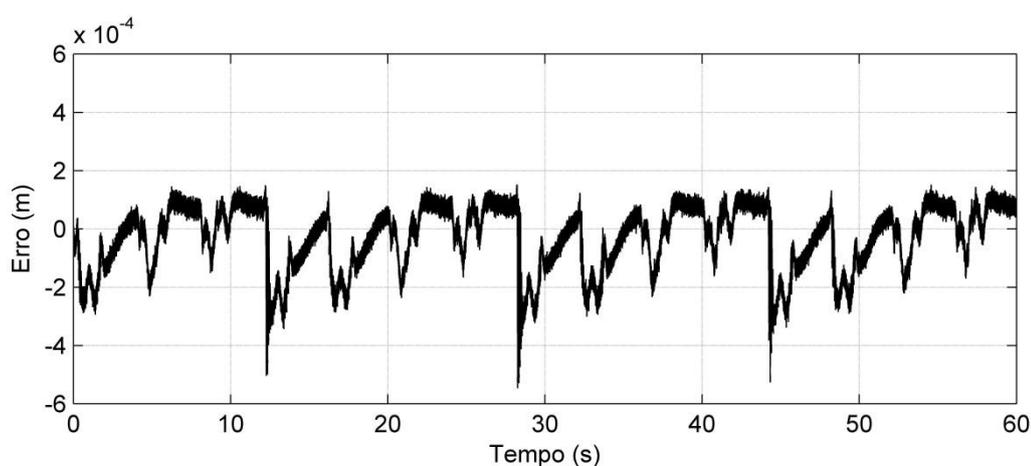


Figura C.12. Erro de posição da simulação do modelo.

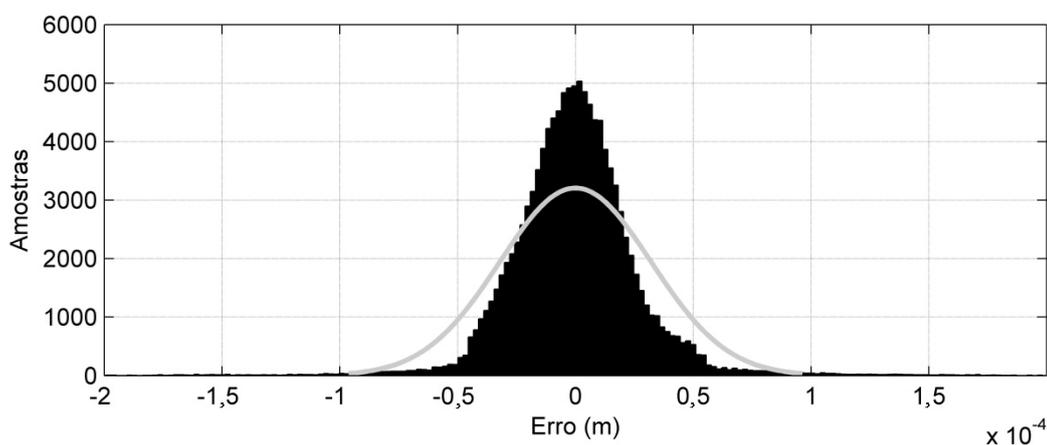


Figura C.13. Distribuição normal dos desvios de erro agrupados na simulação.

Com o objetivo de validar a metodologia de medição da incerteza do erro de posição por simulação Monte Carlo proposta, é realizado um experimento de controle de seguimento de trajetória utilizando a bancada experimental descrita no Capítulo 2. O período de

amostragem, temperatura do fluido hidráulico, a trajetória e o número de repetições da mesma são os mesmos utilizados na simulação, no entanto, o número de amostras efetivo utilizado para o cálculo da incerteza é 4 vezes menor. Essa redução é necessária devido a limitações no software da placa DS1104 em armazenar a mesma quantidade de dados utilizada na simulação. A metodologia de agrupamento de desvios do erro de posição proposta é aplicada aos dados experimentais de erro de posição ilustrados na Figura C.14. A distribuição de probabilidade resultante para a incerteza do erro de posição experimental é ilustrada na Figura C.15.

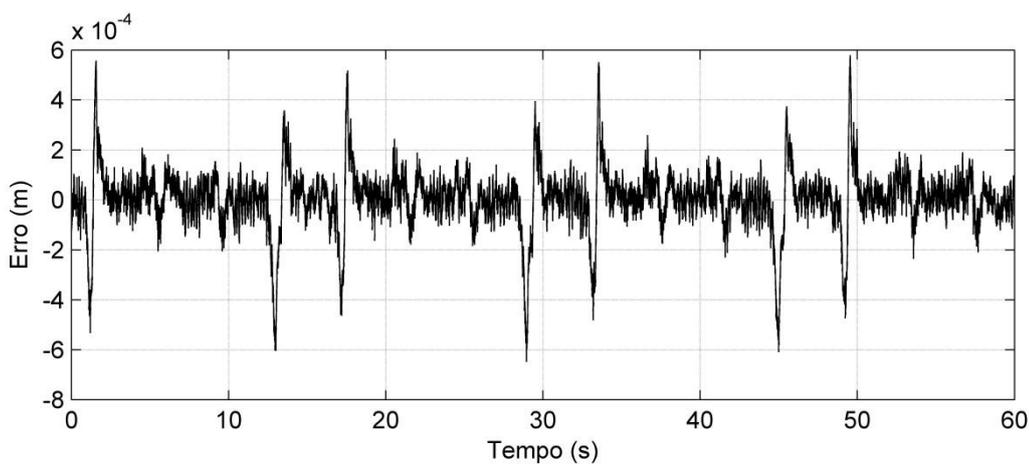


Figura C.14. Erro de posição no experimento.

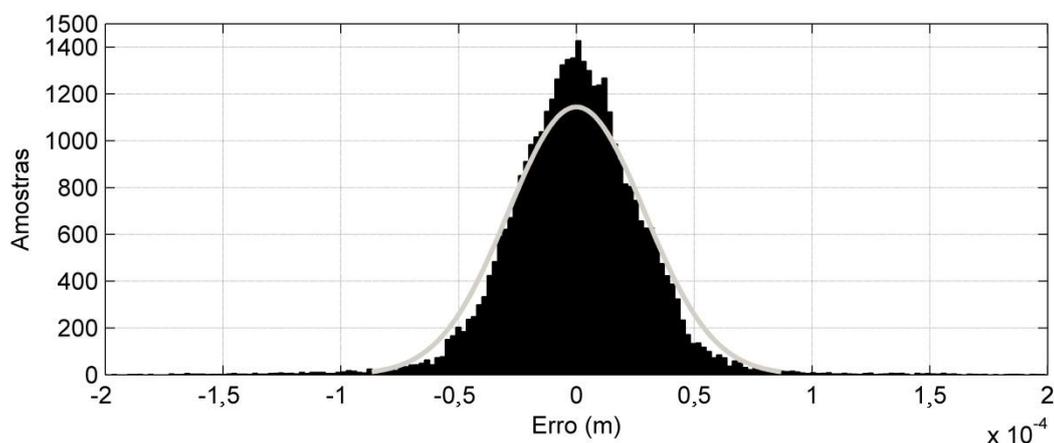


Figura C.15. Distribuição normal dos desvios de erro agrupados no experimento.

O resultado da incerteza do erro de posição é listado na Tabela C.16 para a simulação Monte Carlo e para o erro de posição experimental. Por meio dos resultados pode-se constatar que a simulação apresenta valores próximos aos experimentais. Desta forma, é possível

afirmar que a incerteza da medida do erro de posição do controlador em cascata neural para um determinado instante t é de $\pm 0,064$ mm, com um intervalo de confiança de 95%.

Tabela C.16. Parâmetros estatísticos do erro de posição.

parâmetros	Simulação Monte Carlo (m)	Experimental (m)
Limite superior da média	$0,16 \cdot 10^{-6}$	$0,2930 \cdot 10^{-6}$
Limite inferior da média	$-0,16 \cdot 10^{-6}$	$-0,2930 \cdot 10^{-6}$
Limite superior do desvio padrão	$0,3196 \cdot 10^{-4}$	$0,2875 \cdot 10^{-4}$
Limite inferior do desvio padrão	$0,3222 \cdot 10^{-4}$	$0,2916 \cdot 10^{-4}$

APÊNDICE D. REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais são baseadas no comportamento das redes neurais biológicas do cérebro humano. Elas procuram reproduzir, principalmente, a capacidade de processamento paralelo do cérebro, que é bem distinta da forma sequencial de operação dos circuitos digitais. Segundo Haykin, 2001, uma rede neural é um processador paralelamente distribuído constituído de unidades de processamento simples, que têm propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. A Figura D.1 ilustra um neurônio biológico.

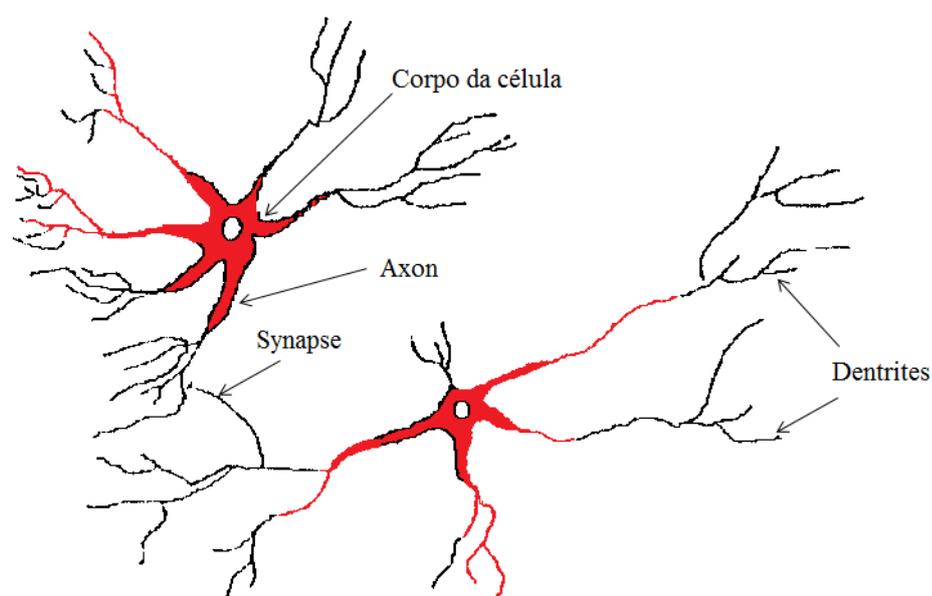


Figura D.1 - Neurônio Biológico [Borges, 1999].

Elementos denominados *dendritos* (ou *dendrites*) prolongam-se do corpo do neurônio para outros neurônios, onde recebem sinais ponderados previamente da saída (axônio) dos mesmos, num ponto de conexão chamado sinapse. Da sinapse, essas entradas são conduzidas para o corpo do neurônio, onde são somadas. Algumas entradas tendem a excitar o neurônio, outras tendem a inibir o seu disparo. Quando a excitação acumulada excede um limite, o neurônio dispara enviando um sinal através do axônio para outros neurônios.

O *Perceptron* é um modelo de neurônio artificial. Um conjunto de entradas, normalmente limitadas entre 0 e 1 ou entre -1 e 1, é aplicado, cada uma produzindo uma saída para outro neurônio. Cada entrada é multiplicada por um peso sináptico, que é um peso de ponderação que corresponde analogamente a força sináptica, e todas as entradas ponderadas são então somadas para determinar o nível de ativação do neurônio. É adicionado ainda um valor b conhecido por *bias*, dentro dos mesmos limites das entradas. A Figura D.2 mostra a representação de um neurônio artificial Perceptron.

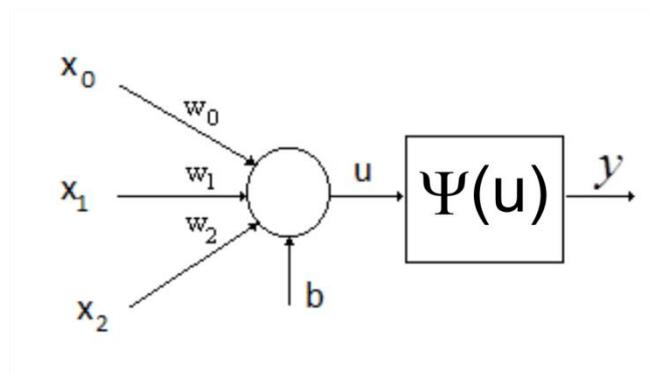


Figura D.2 - Neurônio Artificial Perceptron.

Como formalização matemática de um neurônio Perceptron, pode ser usada a seguinte representação vetorial:

$$\mathbf{x} = \mathbf{W}^T \mathbf{u} + \mathbf{b}, \quad (\text{D.1})$$

onde, \mathbf{x} é a combinação linear do vetor das entradas e do vetor de pesos somada ao bias; \mathbf{u} é o vetor de entrada; \mathbf{W} é o vetor de pesos e \mathbf{b} é a bias.

O sinal u é processado por uma função de ativação, que restringe o intervalo de saída do neurônio a um valor finito $y = \Psi(u)$.

As Redes Neurais Artificiais podem ser definidas como sistemas lógicos celulares que podem adquirir, armazenar e utilizar conhecimento extraído da experiência por meio de algoritmos de aprendizagem. O conhecimento está na forma de estados estáveis ou mapeamentos incorporados em uma rede de processadores simples (neurônios artificiais) interligados por elos que possuem parâmetros ajustáveis, os pesos sinápticos, que controlam a intensidade das conexões. A computação por RN é realizada por uma malha densa de nós processadores e conexões. Conforme já visto, seu elemento processador básico é o neurônio artificial.

As RN possuem propriedades e características importantes, as quais motivam a sua aplicação em diversas áreas do conhecimento:

- Constituem um sistema de processamento paralelo distribuído. O elemento de processamento básico de uma RN tem uma estrutura muito simples que, em conjunto com uma implementação em paralelo, resulta em grande rapidez de processamento, mesmo em processos complexos.

- Possuem aprendizado e adaptação. As RN são treinadas através de exemplos colhidos do sistema em estudo. Uma RN convenientemente treinada é capaz de generalizar os resultados para situações que não fazem parte do conjunto de treinamento. As RN também podem apresentar adaptação *on-line*.

- São sistemas multivariáveis. As RN podem processar muitas entradas e possuem muitas saídas. Elas são, portanto, prontamente aplicáveis a sistemas multivariáveis.

- Tem a habilidade de trabalhar com sistemas não lineares. As RN possuem propriedades que possibilitam o aprendizado de mapeamentos não lineares. Podem ser, portanto, uma boa alternativa aos complexos métodos convencionais de controle de sistemas não lineares.

Os problemas aos quais as RN são aplicadas podem ser agrupados quanto à sua dependência temporal:

- Problema estático (paralelo): só depende dos valores instantâneos das variáveis envolvidas. Exemplos de mapeamentos estáticos são sistemas lógicos combinacionais, classificadores (mapeamentos discretos), além de regressores (mapeamentos contínuos).

- Problema dinâmico (sequencial): além dos valores instantâneos, depende da sequência histórica das variáveis envolvidas. Exemplos de mapeamentos dinâmicos são sistemas lógicos sequenciais, modelos de sistemas dinâmicos e regressores dinâmicos.

D.1. Rede Neural de perceptrons de múltiplas camadas alimentada adiante.

As descrições que seguem foram organizadas com base nos trabalhos de Master, 1993, Borges, 1999 e Haykin, 2001.

A Arquitetura de Rede neural com perceptrons de múltiplas camadas alimentada adiante (*feedforward multi-layer perceptrons*) (tradução de Haykin, 2001), conhecida como MLP, é a arquitetura de RN utilizada no presente trabalho. Como exemplo de uma MLP, tem-

se a rede apresentada na Figura D.3, a qual trata de uma rede simples de três camadas. É importante destacar que a rede MLP é capaz de representar somente mapeamentos estáticos.

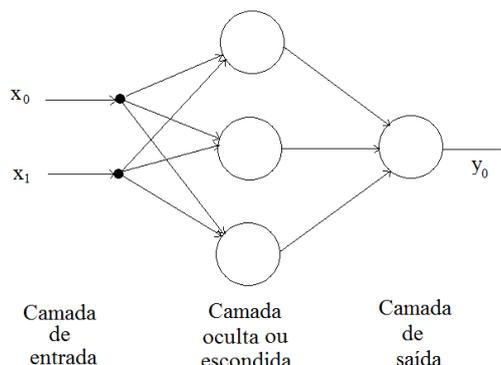


Figura D.3 - RN MLP

A rede do tipo MLP divide-se em três camadas com funções distintas:

A **camada de entrada** tem a função de receber os sinais provenientes do ambiente externo e distribuí-los para os neurônios da camada escondida. Portanto, os neurônios da camada de entrada são considerados inativos, pois não realizam processamento dos dados. O número de neurônios nessa camada é sempre igual ao número de entradas da rede (considerando um atraso, caso exista, como entrada).

A **camada escondida ou oculta**, a qual pode ser mais de uma, tem a função de processar os dados recebidos da camada de entrada. Os neurônios dessa camada são aqueles apresentados na Figura D.3. Atribui-se às camadas internas o mapeamento não linear entre as entradas e as saídas da rede e a supressão dos padrões de ruído que porventura possam existir.

A **camada de saída** possui neurônios idênticos aos da camada escondida, embora possa contar com uma função de ativação distinta, e realiza o processamento final, oferecendo os resultados ao ambiente externo. O número de neurônios dessa camada é sempre igual ao número de saídas da rede.

Considerando uma representação matricial para o equacionamento de uma MLP, tem-se a saída da rede representada pela Equação (D.2), cuja notação segue a da Equação (D.1) do modelo Perceptron:

$$\mathbf{y} = \Psi \left[\mathbf{W}_n^T \Psi \left[\mathbf{W}_{n-1}^T \dots \Psi \left[\mathbf{W}_1^T \mathbf{u} + \mathbf{b}_1 \right] + \dots + \mathbf{b}_{n-1} \right] + \mathbf{b}_n \right], \quad (\text{D.2})$$

onde \mathbf{W} é a matriz ou vetor de pesos e Ψ é a função de ativação.

A função Ψ é a chamada **função de ativação**. Em geral a maioria dos autores utiliza como função de ativação a função sigmoidal, que pode ser a função tangente hiperbólica ou a função logística, descrita pela Equação (D.3) e pela Figura D.4, que é não linear, diferenciável e monótona. É necessário para o treinamento que essa função seja contínua e diferenciável e a função logística, além de cumprir esses pré-requisitos, possui uma derivada fácil de ser obtida, descrita pela Equação (D.4):

$$\Psi(x) = \frac{1}{1 + e^{-\theta x}}, \quad (\text{D. 3})$$

$$\frac{d\Psi(x)}{dx} = \Psi(x)(1 - \Psi(x)). \quad (\text{D.4})$$

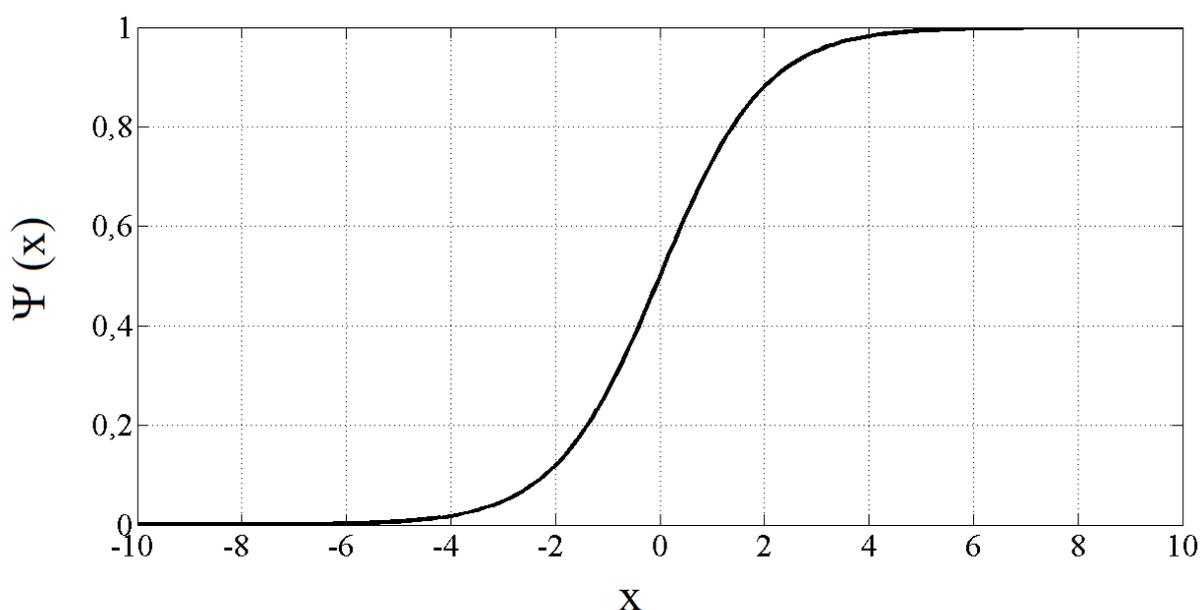


Figura D.4 - Função logística sigmoidal.

O expoente θ determina a inclinação da curva da Figura D.4. Afirma-se em Master, 1993, que esse ganho, apesar de não ter influência decisiva sobre o desempenho da rede, influi na velocidade de treinamento. Segundo Haykin, 2001 é comum adotar-se o valor padrão $\theta = 1$, que é também adotado no presente trabalho.

Algumas outras funções são utilizadas, principalmente com o intuito de aumentar a velocidade de treinamento da RN, entre elas a função tangente hiperbólica e a função arco tangente [Haykin, 2001]. É usual que todos os neurônios da rede tenham a mesma função de ativação, sendo essa a situação predominante na literatura. No presente trabalho adota-se a função logística para todas as camadas da rede, inclusive para a camada de saída (situação não adaptativa). A adoção da função logística para a camada de saída difere do que Haykin, 2001, apresenta como configuração normalmente utilizada de uma MLP que efetua uma regressão, que seria uma configuração utilizando uma função linear para a camada de saída. A utilização da função logística na camada de saída, entretanto, garante uma maior imunidade ao ruído para a rede neural [Master, 1993] e, por isso, foi adotada no presente trabalho em algumas situações.

Uma característica importante da função logística é a de mapear a saída de cada neurônio com valores compreendidos entre 0 e 1. Uma heurística normalmente utilizada, que proporciona uma menor possibilidade de que variáveis que são muito maiores em dimensão influenciem de forma significativa o mapeamento da rede neural [Masters, 1993, Borges, 1999], é uma função de normalização, que condiciona uma variação máxima e mínima do meio externo a uma variação entre 0 e 1. A função descrita pela Equação (D.5) é capaz de realizar essa tarefa, entretanto, deve-se observar que a função sigmoideal dada pela Equação (D.3) atinge os limites 0 e 1 para valores de entrada infinitamente grandes, positivos ou negativos. Isso significa que os limites de normalização dificilmente serão atingidos. A Equação (D.5) pode ser substituída pela Equação (D.6), a fim de restringir a sua faixa de atuação entre 0,1 e 0,9 e contornar esse problema. A Equação (D.7) mostra a função de reconstrução da escala.

$$N(x) = \frac{x - X_{\min}}{X_{\max} - X_{\min}}, \quad (D.5)$$

$$N(x) = \frac{0,9 - 0,1}{X_{\max} - X_{\min}}(x - X_{\min}) + 0,1, \quad (D.6)$$

$$D(y) = \frac{y - 0,1}{0,9 - 0,1}(X_{\max} - X_{\min}) + X_{\min}, \quad (D.7)$$

onde X_{\max} é o limite superior para a normalização e X_{\min} é o limite inferior para a normalização.

Seja o sistema mostrado na Figura D.5, o qual apresenta como entradas $u = [u_1, u_2, \dots, u_n]^T$ e suas correspondentes saídas $y = [y_1, y_2, \dots, y_n]^T$. É conveniente representar esse sistema pela relação $R : U \rightarrow Y$ que mapeia o espaço de entrada $U: u \in U / u$ é à entrada do sistema no espaço de saída $Y: y(u) \in Y / y$ é à saída do sistema com entrada u . O objetivo do treinamento é que a rede possa aprender a relação R . A saída da RN é denotada como $\hat{y}(u, w)$ e pertence ao espaço de saída Y , parametrizado com pesos $w \in W$ em relação ao espaço de entrada u .

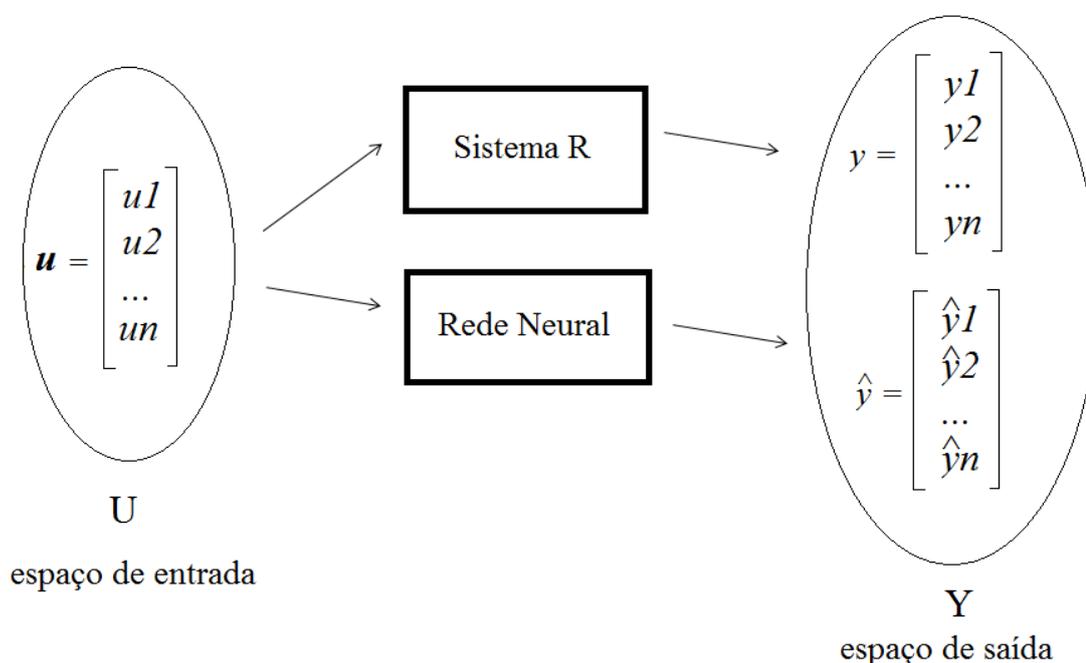


Figura D.5 - Diagrama esquemático da relação entrada e saída de um sistema R e uma RN

O processo de treinamento de uma RN do tipo MLP é chamado de treinamento supervisionado e consiste no ajuste dos parâmetros de ponderação internos da rede (pesos) w , os quais são usados para representar a relação R dentro de uma determinada tolerância. A Equação (D.8) representa matematicamente o processo de treinamento:

$$\min_{w \in W} \|\hat{y}(u, w) - y(u)\| \text{ para todo } u \in U, \quad (\text{D.8})$$

onde $\hat{y}(u, w)$ é a saída da RN e $y(u)$ é a saída do sistema.

A restrição imposta ao treinamento é que a diferença entre a saída da rede $\hat{y}(u, w)$ e a saída do sistema $y(u)$ para a mesma entrada u seja menor do que uma tolerância preestabelecida, isto é, $\|\hat{y}(u, w) - y(u)\| < \varepsilon_a$. Se ε_a é suficientemente pequeno, então \hat{y} representa y .

A Relação contínua exata do sistema $R(u)$ não necessita ser conhecida. A rede é treinada com base em um conjunto de medidas discretas das entradas e saídas (u_1, y_1) ; (u_2, y_2) ; ... ; (u_p, y_p) tomado do sistema aqui denominado de *pares de treinamento*. O processo de treinamento consiste em fazer com que a rede aprenda a relação R baseada nos *pares de treinamento*.

Supondo que existam P padrões de treinamento disponíveis para treinar a RN, sendo u_p o p -ésimo padrão de entrada e y_p o p -ésimo padrão de saída, portanto, (u_p, y_p) é o p -ésimo padrão de treinamento. A Equação (D.9) representa o processo de treinamento como um todo.

$$\min_{w \in W} \|\hat{y}(u_p, w) - y(u_p)\|_2 = \min_{w \in W} \sqrt{\frac{1}{P} \sum_{p=1}^P \frac{1}{2} \sum_{k=1}^M (\hat{y}_k(u_p, w) - y_k(u_p))^2}. \quad (D.9)$$

O erro E_p corresponde ao erro do padrão de treinamento p e é definido pela Equação (D.10), correspondente ao valor instantâneo da energia do erro.

$$E_p = \frac{1}{2} \sum_{k=1}^M \|\hat{y}_k(u_p, w) - y_k(u_p)\| \quad (D.10)$$

onde E_p corresponde ao erro do padrão de treinamento p .

Geralmente se quer minimizar o erro total E_t compreendido pela soma de todos os erros E_p conforme:

$$E_t = \frac{1}{P} \sum_{p=1}^P E_p, \quad (D.11)$$

onde E_t corresponde a soma de todos os erros E_p .

Além de minimizar o erro E_t de acordo com o objetivo ε_a , o treinamento precisa passar por outra fase importante chamada **validação**. A validação consiste em verificar se o treinamento mapeia R sobre determinadas condições de interesse do usuário. O processo mais comum de validação é escolher dois conjuntos distintos de *pares de treinamento* no espaço U ,

um de treinamento e outro de teste. O treinamento é realizado sobre o primeiro conjunto e, quando concluído, a rede é testada mediante a apresentação do segundo. Desta forma, avalia-se a **capacidade de generalização da rede**, que é a capacidade da RN representar satisfatoriamente um mapeamento R dentro de qualquer vetor no espaço U e, portanto, a validade do treinamento. As principais causas do fracasso de um treinamento que atinge E_t mínimo são atribuídas à escolha errada do conjunto de *pares de treinamento* utilizado no treinamento, ou seja, escolheu-se um conjunto pouco representativo dentro do espaço U . Outro problema está associado ao fenômeno do *sobre treinamento* [Masters, 1993], que ocorre quando a rede que aproxima o conjunto de pontos discretos apresenta uma resposta deficiente devido ao excesso de treinamento. A Figura D.6 mostra os gráficos de aproximação típicos de uma rede bem-sucedida e de uma rede sobre treinada.

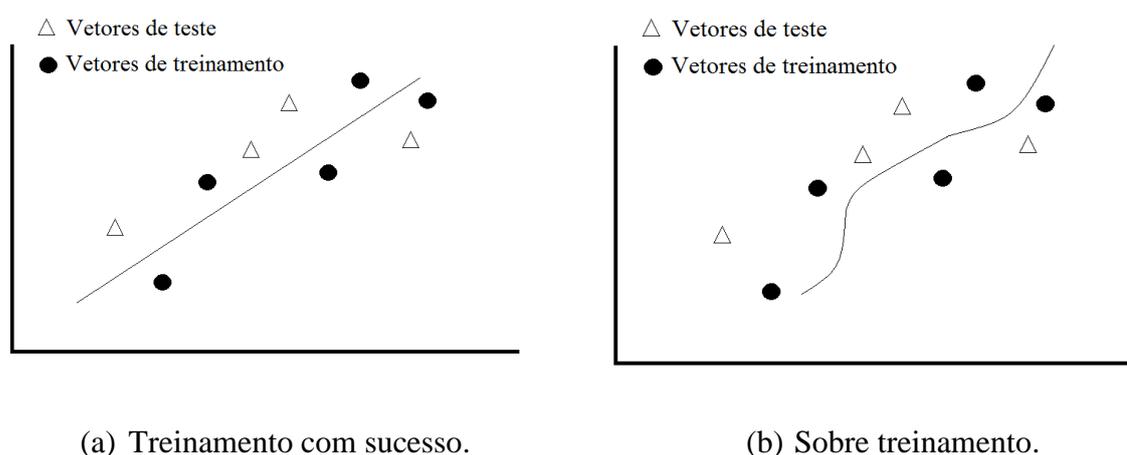


Figura D.6 - Treinamento bem sucedido e sobre treinamento

O processo de validação cruzada [Haykin, 2001] é normalmente utilizado para a prevenção do sobre treinamento. Nesse processo, um terceiro conjunto, descorrelacionado dos demais, chamado conjunto de validação, é utilizado para validar o treinamento. Uma vez validado com erro satisfatório, a rede é então submetida ao conjunto de teste, que realiza a validação final. Existem outras estratégias de validação cruzada, que consistem em divisões maiores do conjunto de treinamento. Para maiores informações, consultar Haykin, 2001.

Vários algoritmos de treinamento para redes MLP têm surgido ao longo dos anos, principalmente depois da publicação de Rumelhart e McClelland, 1988, o qual introduziu o

algoritmo baseado em retro propagação (*Backpropagation*). O presente trabalho detém-se mais detalhadamente nesse algoritmo e em algumas modificações do mesmo, propostas por Fahlman, 1988 visando melhorar seu tempo de treinamento.

O algoritmo *Backpropagation* se tornou o mais popular e difundido método de treinamento em RN, sendo baseado no algoritmo da média dos mínimos quadrados (*Least Square Mean*) [Haykin, 2001], que consiste em minimizar o somatório do quadrado da distância em relação à curva objetivo de cada ponto amostrado. Para tanto, utiliza o método do gradiente descendente, que consiste de, a cada iteração, alterar os elementos de ponderação a fim de dar um passo no sentido contrário ao gradiente da função, minimizando-a, assim, em um total K de passos. A fim de facilitar a descrição matemática do algoritmo, uma notação padrão é adotada. Esta notação é descrita por meio da Tabela D.1.

Tabela D.1 - Notação para descrição do algoritmo *Backpropagation*

Notação	Definição
$\frac{\partial E_p}{\partial w_{ij}}$	derivada parcial do erro E_p com respeito a w_{ij} .
$\frac{\partial E_t}{\partial w_{ij}}$	derivada parcial do erro E_t com respeito a w_{ij}.
$\nabla \mathbf{E}_t = \left(\frac{\partial E_t}{\partial w_1}, \frac{\partial E_t}{\partial w_2}, \dots, \frac{\partial E_t}{\partial w_n} \right)$	Gradiente com respeito ao conjunto completo de treinamento.
$\nabla \mathbf{E}_p = \left(\frac{\partial E_p}{\partial w_1}, \frac{\partial E_p}{\partial w_2}, \dots, \frac{\partial E_p}{\partial w_n} \right)$	Gradiente com respeito ao padrão p .
w_1, w_2, \dots, w_n	Pesos da Rede

O método do gradiente descendente é descrito por meio da Equação (D.13), que aponta a direção Ξ \mathbf{W} para a qual a função tende ao mínimo, considerando (D.12) como a função a ser minimizada.

$$\mathbf{J}(\mathbf{W}) = \frac{1}{P} \sum_P \mathbf{E}_p^T \mathbf{E}_p, \quad (\text{D.12})$$

$$\Xi(\mathbf{W}) = -\nabla \mathbf{J}(\mathbf{W}) = -\frac{1}{P} \sum_P \frac{\partial \mathbf{E}_p(\mathbf{W})}{\partial \mathbf{W}}. \quad (\text{D.13})$$

Aproveitando as propriedades de paralelismo das RN e também a possibilidade de propagação reversa do erro, é possível obter uma forma recursiva de cálculo da Equação (D.13) com facilidade de implementação computacional, o que tornou o *Backpropagation* tão popular no treinamento de RN.

Considerando Δw_{ji} a direção de minimização para um determinado peso w_{ji} pode-se obter essa direção calculando recursivamente a Equação (D.13), por intermédio da derivada do erro na saída y_j em relação ao peso w_{ji} , conforme a Equação (D.14). O parâmetro η é conhecido como **taxa de aprendizagem** e determina o tamanho do passo a ser dado na direção de minimização.

$$\Delta w_{ji} = -\eta \frac{\partial E_p}{\partial w_{ji}}, \quad (\text{D.14})$$

onde η é a taxa de aprendizagem da RN e Δw_{ji} é a direção de minimização.

Definindo o sinal associado a uma camada j como $x_j = \sum_{i=1}^n y_i w_{ji}$, pode-se calcular a derivada da Equação (D.14) aplicando o princípio da regra da cadeia.

$$\Delta w_{ji} = -\eta \frac{\partial E_p}{\partial x_j} \frac{\partial x_j}{\partial w_{ji}}. \quad (\text{D.15})$$

Lembrando que $\frac{\partial x_j}{\partial w_{ji}} = y_i$, também pela regra da cadeia tem-se:

$$\frac{\partial E_p}{\partial x_j} = \delta a_j = \frac{\partial E_p}{\partial e_j} \frac{\partial e_j}{\partial y_j} \frac{\partial y_j}{\partial x_j}. \text{ Definindo o erro em relação ao neurônio } j \text{ como } e_j = d_j - y_j,$$

onde d_j é a saída desejada para o neurônio j , tem-se $\frac{\partial E_p}{\partial e_j} = e_j$; $\frac{\partial e_j}{\partial y_j} = -1$; $\frac{\partial y_j}{\partial x_j} = y_j(1 - y_j)$,

o que resulta na igualdade: $\delta a_j = -e_j y_j (1 - y_j)$, que implica que o Gradiente do peso será então:

$$\Delta w_{ji} = -\eta \cdot \delta a_j \cdot y_i. \quad (\text{D.16})$$

O resultado obtido em (D.16) serve para o cálculo de variações dos pesos conectados aos neurônios da camada de saída. Para os pesos das camadas internas utiliza-se a retropropagação do erro da camada de saída, uma vez que não é possível obtê-lo diretamente como no caso dos neurônios da camada de saída.

O erro retro propagado será, portanto, descrito como: $e_i = \sum_{j=1}^n w_{ji} \cdot \delta a_j$, o que resulta em:

$$\delta a_i = \left(-\sum_{j=1}^n w_{ji} \cdot \delta a_j \right) \cdot y_i (1 - y_i), \quad (\text{D.17})$$

$$\Delta w_{i_{int} j_i} = -\eta \cdot \delta a_i \cdot y_{i_{int}}. \quad (\text{D.18})$$

Os pesos são atualizados após a apresentação completa do conjunto de treinamento através da Regra Delta Generalizada [Rumelhart e McClelland, 1988], conforme a Equação (D.19). O índice k refere-se ao instante de amostragem, logo, $k - 1$ refere-se ao instante anterior. Assim:

$$\mathbf{W}(k) = \mathbf{W}(k-1) + \Delta \mathbf{W}(k-1). \quad (\text{D.19})$$

É importante salientar que os *bias* são tratados como pesos quaisquer do ponto de vista do algoritmo, com a diferença que sua entrada é sempre unitária.

Os seguintes passos, portanto, constituem um treinamento padrão utilizando o algoritmo *Backpropagation* [Borges, 1999]:

- 1) Selecionar o próximo par do conjunto de treinamento, aplicando o vetor de entrada;
- 2) Calcular a saída da rede;
- 3) Calcular o erro entre a saída da rede e a saída desejada (erro E_p);
- 4) Calcular a matriz $\Delta \mathbf{W}_p$ acumulando os resultados de cada vetor de treinamento em uma matriz $\Delta \mathbf{W}$, de modo que $\Delta \mathbf{W} = \Delta \mathbf{W} + \Delta \mathbf{W}_p$, sendo $p=1, \dots, n$ pares de treinamento.
- 5) Repetir do passo 1 até 4 até apresentação completa do conjunto de treinamento;
- 6) Atualizar os pesos da rede utilizando a matriz $\Delta \mathbf{W}$ conforme a Equação (D.19);
- 7) Verificar se o erro total desejado foi alcançado, se não, retornar ao passo 1.

Os passos acima listados referem-se a um treinamento padrão visando minimizar E_t , o que é denominado treinamento por época. Pode-se, no entanto, minimizar E_p , o que implicaria na necessidade de atualização dos pesos após o passo 4.

Para aumentar a velocidade de treinamento sem induzir oscilações, Rumelhart e McClelland, 1988, introduziram uma modificação em (D.19) adicionando um termo α chamado **momento** que torna (D.20) um filtro passa baixas usado para atenuar as oscilações dos pesos em torno da direção mínima típicas no *Backpropagation*.

$$\mathbf{W}(\mathbf{k}) = \mathbf{W}(k-1) + \Delta\mathbf{W}(k-1) + \alpha_m \mathbf{W}(k-2), \quad (\text{D.20})$$

onde α_m é o momentum.

Apesar de sua facilidade de implementação e seu baixo custo computacional, o algoritmo de treinamento *Backpropagation* possui limitações em sua forma original que desencorajam a sua utilização em algumas aplicações e obrigam os pesquisadores a buscar alternativas. As principais limitações do algoritmo são as seguintes:

a) **Tempo de treinamento muito longo** - O tempo de treinamento no algoritmo *Backpropagation* é considerado muito longo para muitas aplicações práticas. Esse tempo de treinamento longo deve-se principalmente ao método do gradiente descendente. O gradiente aponta para um mínimo local e não global do espaço de pesos. Esse comportamento indesejado demanda geralmente muito mais tempo de treinamento do que o caso de uma rota direta de convergência sob uma direção ótima, por exemplo. Em Masters, 1993, é mostrado que o comportamento típico do método gradiente descendente é uma trajetória no espaço dos pesos oscilatória em torno da direção ótima de minimização. A forma que o *Backpropagation* tem de contornar esse problema, segundo Masters, 1993, é através do ajuste da taxa de aprendizado e do momento, que, mesmo corretamente ajustadas, muitas vezes não são capazes de acelerar suficientemente o treinamento.

b) **Ajuste crítico dos parâmetros η e α_m** - Quando se ajusta a taxa de aprendizado η , deve-se prevenir dois aspectos: primeiramente não deixá-la muito alta, pois tal fato acarreta um comportamento oscilatório em relação à variação dos pesos a cada iteração, e, segundo, também não subdimensionar o seu valor, o que implicaria em uma velocidade menor de convergência ao treinamento. Portanto, o ajuste de η não é trivial e, em muitos casos, uma escolha adequada da taxa de aprendizado é inviável.

c) **Mínimos locais** - Os algoritmos do tipo gradiente descendente são sensíveis ao problema dos mínimos locais. Isso pode ser visualizado considerando a função de erro apresentada na Figura D.7, onde o ponto A representa um mínimo local e o ponto B representa o mínimo global da função de erro em relação ao espaço de pesos.

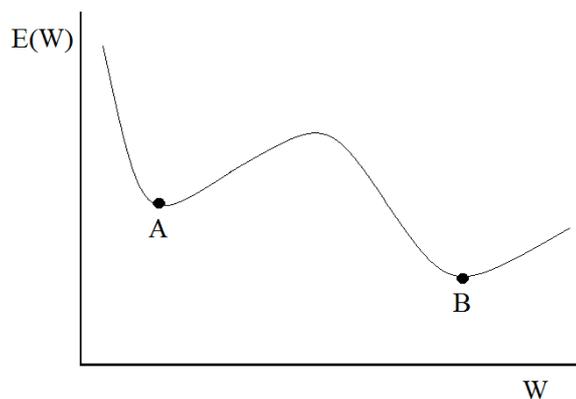


Figura D.7 - Mínimos locais e mínimos globais

O problema dos mínimos locais pode ou não ser crítico para o treinamento de uma RN, pois o objetivo geral do treinamento não é alcançar o mínimo global e sim satisfazer um erro mínimo pré-definido como suficiente para a tarefa desejada. Portanto, soluções que levam a mínimos locais, muitas vezes, são aceitas sem a necessidade de contornar esse problema. Uma observação importante é que, muitas vezes, um mínimo local pode ser confundido com uma região de planície da função de erro, conforme mostrado na Figura D.8.

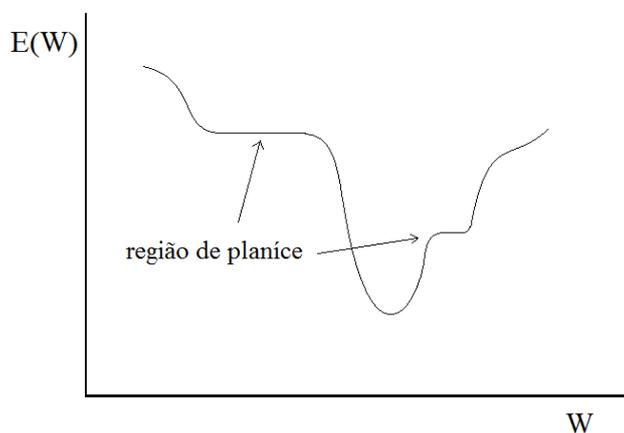


Figura D.8 - Regiões de planície

As regiões de planície tendem, muitas vezes, a tornar lento o treinamento, pois sendo o gradiente descendente local em relação à direção ótima de minimização, ele causa pouca progressão no treinamento quando se encontra nessas regiões. O treinamento pode ser, inclusive, interrompido devido à derivada das funções de ativação tornar-se muito próxima de zero, não retro propagando, portanto, o erro da camada de saída para as camadas escondidas, problema que particularmente foi tratado em Fahlman, 1988 com a proposta de adicionar um *offset* de 0,1 à derivada da função de ativação conforme a Equação (D.21), solução esta que também é adotada no presente trabalho.

$$\frac{d\Psi(x)}{dx} = \Psi(x)(1 - \Psi(x)) + 0,1. \quad (\text{D.21})$$

O algoritmo *Quickprop* foi proposto por Fahlman, 1988 e consiste em uma série de modificações heurísticas feitas no *Backpropagation* original. Em Borges, 1999, esse algoritmo é citado como um dos mais eficientes quando se trata de aumentar a velocidade de treinamento do *Backpropagation*.

O ponto de partida para o *Quickprop* é o método de Newton, o qual utiliza os três primeiros termos da série de Taylor no ponto corrente para descrever o contorno do espaço de pesos e prever a direção do mínimo. A série de Taylor em um ponto corrente do espaço de pesos \mathbf{W} , dado um modelo m_t para o erro E em qualquer nova direção $\mathbf{W} + \mathbf{S}$ é dada por:

$$\mathbf{E}(\mathbf{W} + \mathbf{S}) \approx m_t(\mathbf{W} + \mathbf{S}) = \mathbf{E}(\mathbf{W}) + \nabla \mathbf{E}(\mathbf{W})^T \mathbf{S} + \frac{1}{2} \mathbf{S}^T \nabla^2 \mathbf{E}(\mathbf{W}) \mathbf{S}. \quad (\text{D.22})$$

Resolve-se tal expressão para achar um gradiente zero para algum passo final N , onde \mathbf{S}^N é a direção de Newton :

$$\nabla m_t(\mathbf{W} + \mathbf{S}^N) = 0, \quad (\text{D.23})$$

O sistema linear a ser resolvido também pode ser expresso conforme (D.24).

$$\nabla^2 \mathbf{E}(\mathbf{W}) \mathbf{S}^N = -\nabla \mathbf{E}(\mathbf{W}). \quad (\text{D.24})$$

A matriz $\nabla^2 \mathbf{E}(\mathbf{W})$ é também chamada de Hessiana. Sendo a Hessiana positiva definida, apenas uma iteração, portanto, será necessária para alcançar o mínimo.

O método de Newton não é usado em aplicações práticas devido à dificuldade do cálculo da Hessiana, no entanto a sua ideia básica é ponto de partida para vários outros métodos que buscam aproximar o valor desta Hessiana.

No *Quickprop*, a Hessiana é aproximada recursivamente mediante duas hipóteses simplificadoras:

1. A curva Erro versus Peso para cada valor de peso pode ser representada por uma parábola de inclinação ascendente.

2. As mudanças na derivada de um peso não são dependentes das mudanças dos demais pesos.

O resultado dessa aproximação é a Equação (D.25), o qual é de fácil implementação e usa somente informações locais sobre os pesos que estão sendo atualizados.

$$\Delta w_{ij} = \frac{\frac{\partial \mathcal{E}}{\partial w_{ij}}}{\frac{\partial \mathcal{E}}{\partial w_{ij}}(t-1) - \frac{\partial \mathcal{E}}{\partial w_{ij}}} \cdot \Delta w_{ij}(t-1). \quad (\text{D.25})$$

A aproximação da Hessiana em (D.25) é considerada pouco refinada do ponto de vista matemático, mas, junto com outras heurísticas inseridas por Fahlman, 1988, ela apresenta um comportamento geralmente considerado eficiente do ponto de vista do aumento da velocidade de treinamento. Essas Heurísticas são construídas tomando por base a análise do comportamento descrito por meio de (D.25) em três diferentes situações:

1. **A derivada corrente é menor que a derivada anterior, mas na mesma direção.** A mudança de pesos irá seguir a mesma direção anterior. O passo pode ser grande ou pequeno e dependerá de quanto a derivada foi reduzida pelo passo anterior.

2. **A derivada corrente está em direção oposta a derivada anterior.** Significa que se cruzou um mínimo e se está agora no lado oposto do vale. Nesse caso o próximo passo conduzirá para algum lugar entre a posição anterior e a atual.

3. **A derivada atual tem a mesma direção da anterior, mas é do mesmo tamanho ou maior em magnitude.** Nesse caso, surge um problema. Se (D.25) for rigorosamente aplicada, o passo tenderá ao infinito ou a função de erro tenderá a um máximo local.

A solução encontrada para a situação 3 é a introdução de um fator μ , chamado de máximo fator de crescimento. Determina-se que nenhum passo pode ser maior em magnitude

que μ multiplicado pelo tamanho do passo anterior para o dado peso. Se isso ocorrer, substitui-se o passo atual por μ multiplicado pelo passo anterior. Apesar de introduzir-se mais um fator a ser sintonizado, Fahlman, 1988 afirma que a sintonia de μ , apesar de depender do processo à ser aprendido, não é crítica. O autor sugere o uso do valor de 1,75 e afirma que esse valor funciona bem para a maioria dos processos.

O *Quickprop* é um algoritmo que muda seus pesos baseado no que ocorreu na mudança de pesos anterior. Necessita-se, portanto, de alguma forma de dar início a esse processo, uma vez que no primeiro instante, $w_{ji}(k - 1) = 0$. Além disso, necessita-se também alguma maneira de reiniciar o processo mediante a ocorrência de um passo de tamanho zero.

A maneira mais eficiente de realizar a inicialização é somar a Equação (D.25) com a derivada corrente multiplicada pela taxa de aprendizagem η , à semelhança do *Backpropagation*. Para prevenir o efeito indesejado na vizinhança de um mínimo, utiliza-se (D.25) sozinha mediante a situação 2.

D.2. Rede Neural de funções de base radial

A Rede Neural de Funções de Base Radial (RBF) é ilustrada na Figura D.9. A arquitetura da rede apresenta uma camada de entrada (para distribuir o sinal de entrada), uma camada oculta, composta de nós de funções radiais, e uma camada de saída com um nó linear. A rede RBF, assim como a rede MLP, é utilizada somente para a realização de mapeamentos estáticos.

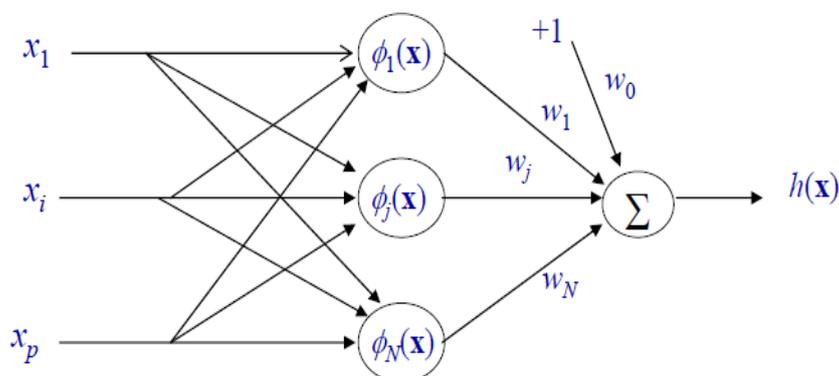


Figura D.9 – Esquema de uma Rede RBF

$$h(x) = \sum_{j=1}^N w_j \phi_{aj}(x), \quad (\text{D.26})$$

onde w_j é o j -ésimo peso da camada de saída, x é o vetor de entrada e $\phi_{aj}(\cdot)$ é a j -ésima função de base radial.

Tipicamente, em uma rede RBF, a forma das funções de base é escolhida a priori, de modo que ela tenha um comportamento adequado ao problema de regressão: a sua resposta deve decrescer (ou crescer) monotonamente com a distância em relação a um ponto central. O problema consiste, então, em definir os centros das funções de base e ajustar os pesos da camada de saída em relação ao conjunto de treinamento. As funções radiais são uma classe especial de funções, sendo a sua característica principal o fato de que sua resposta diminui (ou aumenta) monotonamente com a distância a um ponto central. O centro, a escala de distância e a forma da função radial são parâmetros do modelo. Uma função radial típica é a gaussiana, a qual no caso esférico tem a forma:

$$\phi_{aj}(x) = e^{-\frac{(x-c_j)^2}{2\sigma_j^2}}, \quad (\text{D.27})$$

onde c_j é o j -ésimo centro da função e σ_j é a j -ésima constante de suavização;

Uma rede RBF é geralmente treinada em duas etapas de ajuste:

- Ajuste dos parâmetros das funções de base a partir dos dados de entrada (não supervisionado);
- Ajustes dos pesos da camada de saída por métodos lineares (supervisionado).

Em relação à representação de funções estáticas, essas redes têm as seguintes vantagens em relação à MLP:

- Arquitetura mais simples;
- Treinamento mais veloz, pois somente os pesos da camada de saída recebem treinamento supervisionado.

A rede MLP permite construir aproximações globais de um mapeamento entrada-saída não linear. Por outro lado, as redes RBF que utilizam funções gaussianas permitem construir aproximações locais para os mesmos mapeamentos [Haykin, 2001]. Isto quer dizer que, para um mesmo grau de precisão, a rede RBF requer bem mais parâmetros que a rede MLP. Em sistemas onde o domínio da função a ser aproximada requer um grande número de entradas e saídas, têm-se também um número elevado de neurônios para a rede RBF e um número

também maior de pesos a serem ajustados. Como a capacidade de generalização da rede depende do domínio para o qual ela foi treinada, existirão casos em que um número muito elevado de parâmetros deverá ser utilizado para o treinamento da RBF para a obtenção do mesmo resultado fornecido por uma rede MLP treinada com menos dados. Uma análise desses aspectos é fundamental para a decisão entre uma ou outra rede, uma vez que ambas comportam-se como aproximadores universais.

D.3. Redes Neurais Recorrentes

As Redes Recorrentes são redes neurais com um ou mais laços de realimentação. Enquanto que as demais arquiteturas de RN armazenam informações nos pesos sinápticos, os quais respondem de forma estática a um conjunto de entradas da rede, as RN recorrentes são capazes de adquirir representações do estado do sistema, sendo, portanto, utilizadas para a representação de mapeamentos dinâmicos. Segundo Haykin, 2001, existem dois usos para as redes recorrentes: como memórias associativas ou como mapeamento de entrada-saída. Detalhes sobre o uso como memórias associativas podem ser encontrados em Haykin, 2001. No presente trabalho o interesse maior é o uso como mapeamento entrada-saída.

As redes recorrentes utilizadas para mapeamento entrada-saída têm por base a rede MLP. Atrasos das saídas para as entradas ou da(s) camada(s) oculta(s) para as entradas podem ser propostos. Várias são, portanto, as possibilidades de arquitetura. O caso mais utilizado para a representação de sistemas dinâmicos do tipo SISO é aquele apresentado na Figura D.10, onde a realimentação da saída para a entrada é global. O número de atrasos define a ordem do sistema a ser representado [Naredra, 1996].

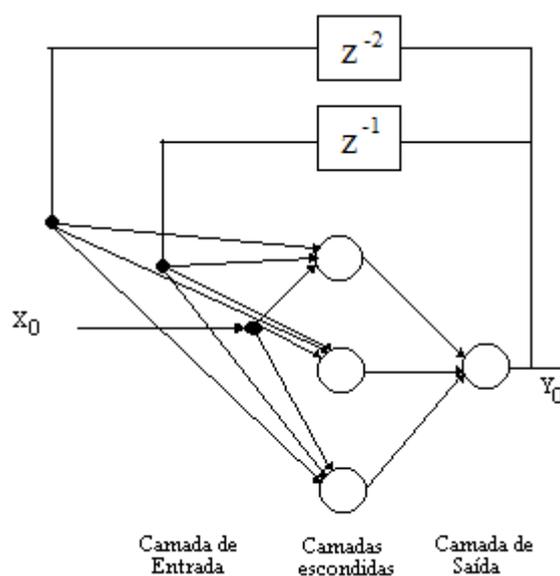


Figura D.10 - Rede neural recorrente

A rede neural recorrente é utilizada no controlador neural com base na dinâmica inversa, proposto por Naredra e Parthasarathy, 1990, onde a rede neural recorrente é capaz de representar a inversa de uma planta somente com informações de entrada e saída da mesma.