

DISSERTAÇÃO DE MESTRADO Nº 1111

**ONLINE NEUROFUZZY CONTROLLER: APLICAÇÃO, ANÁLISE DE
PARÂMETROS E CONTRIBUIÇÕES**

Hugo Rafael Nogueira Gomes

DATA DA DEFESA: 21/02/2019

Universidade Federal de Minas Gerais

Escola de Engenharia

Programa de Pós-Graduação em Engenharia Elétrica

**ONLINE NEUROFUZZY CONTROLLER: APLICAÇÃO, ANÁLISE
DE PARÂMETROS E CONTRIBUIÇÕES**

Hugo Rafael Nogueira Gomes

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Prof. Walmir Matos Caminhas

Belo Horizonte - MG

Fevereiro de 2019

G663o

Gomes, Hugo Rafael Nogueira.

Online Neurofuzzy Controller [manuscrito]: aplicação, análise de parâmetros e contribuições / Hugo Rafael Nogueira Gomes. – 2019. x, 91 f., enc.: il.

Orientador: Walmir Matos Caminhas.

Dissertação (mestrado) Universidade Federal de Minas Gerais, Escola de Engenharia.

Apêndices: f. 63 - 91.

Bibliografia: f. 61 - 62.

1. Engenharia elétrica - Teses. 2. Controle de processo - Teses.
3. Inteligência computacional - Teses. I. Caminhas, Walmir Matos.
II. Universidade Federal de Minas Gerais. Escola de Engenharia.
III. Título.

CDU: 621.3(043)

**"Online Neurofuzzy Controller: Aplicação, Análise de
Parâmetros e Contribuições"**

Hugo Rafael Nogueira Gomes

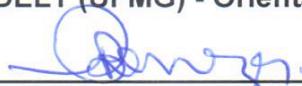
Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 21 de fevereiro de 2019.

Por:



Prof. Dr. Waldir Matos Caminhas
DELT (UFMG) - Orientador



Prof. Dr. Benjamim Rodrigues Menezes
DELT (UFMG)



Prof. Dr. Agnaldo José da Rocha Reis
DECAT (UFOP)

Aos meus filhos, Pedro e Helena.

Agradecimentos

Agradeço a Deus por ter me guiado até aqui e por me fortalecer sempre.

Agradeço à minha família pelo apoio. Em especial, à minha esposa, Quênia, que viveu comigo as frustrações, angústias e vitórias de cada etapa deste trabalho. Aos meus pais, meu irmão, Joberto e Edna, tia Rita e Silvânia que tanto ajudaram nas várias vezes que precisei estar ausente para estudar e trabalhar.

Agradeço ao Professor Walmir pelas oportunidades e orientações. Agradeço ao Professor Agnaldo pelo apoio. Aos professores e colegas do PPGEE, pelos ensinamentos ao longo dos anos.

Agradeço aos amigos que sempre queriam que eu concluísse essa etapa e mandaram tantas energias positivas. Colegas da Chemtech, da Vale, do IFMG, entre tantos outros. Deixo um agradecimento especial aos amigos André, Aquino, Luiz Rogério e Tamires.

E por fim, essa conquista definitivamente tem um gosto muito especial por poder dedicar aos meus amados filhos: Pedro e Helena! A alegria dos dois é o melhor incentivo para vencer qualquer desafio.

*"(...) Não é sobre chegar no topo do mundo
E saber que venceu
É sobre escalar e sentir
Que o caminho te fortaleceu (...)"*

Ana Vilela

Resumo

A utilização de técnicas de inteligência computacional em problemas de controle de processos tem sido cada vez mais frequente. O presente trabalho faz um estudo do *Online Neurofuzzy Controller* (ONFC), um controlador nebuloso adaptativo com baixo custo computacional e poucos parâmetros de ajuste. Uma revisão dos controladores já desenvolvidos é realizada, com simulações computacionais das versões encontradas na literatura. É realizada uma análise dos parâmetros do controlador: a taxa de aprendizagem, parâmetro α , e o erro máximo admissível ou faixa de excursão do erro, parâmetro EM . É realizada a discussão e aplicação do ajuste dinâmico da taxa de aprendizagem, sendo proposto um novo cálculo para a taxa de aprendizagem baseada no modelo do processo. É apresentada uma metodologia de ajuste dinâmico da faixa de excursão do erro, denominada *Adaptação de Contexto*, e é criado o controlador ONFC_{DwDe}, uma nova abordagem para a ação derivativa no ONFC. Os controladores estudados são aplicados em uma planta com equipamentos industriais para controle de vazão de água, no qual são realizados experimentos de servomecanismo e rejeição de distúrbios. Os resultados são comparados entre as versões do controlador e também com o controlador PI usado na planta. Nos resultados, é evidenciada a contribuição da *Taxa de Aprendizagem Dinâmica* e da *Adaptação de Contexto* para melhoria no desempenho do controlador.

Palavras-chaves: Controlador NeuroFuzzy, ONFC, *Taxa de Aprendizagem Dinâmica*

Abstract

The usage of computational intelligence in process controllers has significantly increased. This work studies the OnLine Neurofuzzy Controller (ONFC), an adaptive fuzzy controller with low computational cost and few parameters. A review of all ONFC versions is made, with computational simulations for the studied controllers. The ONFC learning rate (α) and the error range (EM) are studied. The *Dynamic Learning Rate* is discussed and a new approach for the learning rate calculation is proposed, based on the process model. A dynamic adjustment for the EM is presented, called *Context Adaptation*, and a new approach for the derivative action for the ONFC is proposed, the ONFC_{DwDe} controller. The controllers are applied in a didactic control system, with industrial equipments, to control water flow, in tracking setpoints and disturbance rejection experiments. All controller versions have their performance compared with the PI controller used in the plant. The results highlight how the *Dynamic Learning Rate* and the *Context Adaptation* improved the controller performance.

Keywords: NeuroFuzzy Controller, ONFC, Dynamic Learning Rate

Sumário

Sumário	i
Lista de Figuras	iii
Abreviaturas	ix
1 Introdução	1
1.1 Motivação	4
1.2 Objetivos	4
1.3 Estrutura do texto	5
2 Revisitando o ONFC	7
2.1 ONFC original	7
2.1.1 Simulação do ONFC	11
2.1.2 Comparativo com Controlador PI	12
2.1.3 O Aumento na Diferença dos Pesos	13
2.2 ONFC _{Dw}	16
2.2.1 Simulação do ONFC _{Dw}	16
2.3 ONFC _{DwD}	18
2.4 Conclusões Parciais	19
3 Parâmetros do ONFC e Contribuições	21
3.1 Taxa de Aprendizagem (α)	21
3.1.1 Taxa de Aprendizagem Dinâmica	22
3.1.2 Taxa de Aprendizagem Dinâmica baseada no Modelo do Processo	23
3.1.3 Simulação da Taxa de Aprendizagem Dinâmica baseada no Modelo do Processo	25
3.2 Faixa de Excursão do Erro (EM)	29
3.2.1 Adaptação de Contexto	30
3.2.2 Simulação da Adaptação de Contexto	31
3.3 Ação Derivativa no Controlador ONFC	32
3.3.1 Análise Matemática	33
3.4 Conclusões Parciais	35

4	Metodologia	37
4.1	Descrição do Processo	37
4.2	Definição dos Experimentos	38
4.3	Definição dos Controladores	40
4.4	Conclusões Parciais	41
5	Resultados	43
5.1	Análise geral	43
5.2	Análise da <i>Taxa de Aprendizagem Dinâmica</i>	44
5.3	Análise da <i>Adaptação de Contexto</i>	49
5.4	Análise do $ONFC_{DwDe}$	54
5.5	Conclusões Parciais	55
6	Considerações Finais	57
6.1	Conclusões	57
6.2	Propostas de Trabalhos Futuros	59
6.3	Trabalho Publicados	60
	Bibliografia	61
A	Resultados dos Experimentos	63
A.1	$ONFC_{Dw}$ com α fixo	64
A.2	$ONFC_{Dw}$ com <i>Taxa de Aprendizagem Dinâmica</i>	70
A.3	$ONFC_{Dw}$ com <i>Adaptação de Contexto</i>	76
A.4	$ONFC_{DwDe}$	82
A.5	Controlador PI	88

Lista de Figuras

1.1	Diagrama de blocos de um controle adaptativo - Fonte: adaptado de Åström e Wittenmark (2013).	1
2.1	Diagrama de blocos de uma malha de controle com o ONFC - Fonte: adaptado de Pires (2007).	7
2.2	Funções de pertinência usadas no ONFC - Fonte: adaptado de Pires (2007).	8
2.3	Diagrama de blocos do ONFC - Fonte: (Pires, 2007).	9
2.4	Sistema com ONFC após mudança de <i>setpoint</i> em degrau.	11
2.5	Saída do controlador ONFC.	11
2.6	Valores dos pesos w_1 , w_2 e diferença $w_2 - w_1$	12
2.7	Utilização do ONFC com presença de ruído branco na variável controlada.	13
2.8	Valores dos pesos w_1 e w_2 - Simulação com ruído branco.	14
2.9	Tendência à instabilidade no controle devido ao aumento nos pesos.	14
2.10	Aumento da diferença dos pesos.	15
2.11	Comportamento do controlador ONFC _{Dw}	17
2.12	Comportamento do controlador ONFC _{Dw} - Simulação por 10 minutos.	17
2.13	Ajuste dos pesos w_1 e w_2 para o controlador ONFC _{Dw}	18
3.1	Resposta do ONFC com Adaptação Dinâmica baseada no Modelo do Processo.	26
3.2	Valores de α com Adaptação Dinâmica baseada no Modelo do Processo.	26
3.3	Resposta do ONFC com Adaptação Dinâmica baseada no Modelo do Processo.	27
3.4	Valores de α com Adaptação Dinâmica baseada no Modelo do Processo.	27
3.5	Resposta do ONFC com Adaptação Dinâmica baseada no Modelo do Processo.	28
3.6	Simulação com Modelo de Referência em Rampa: (a) Valores de α (b) Valores dos pesos w_1 e w_2	28
3.7	Resposta do ONFC com Adaptação Dinâmica baseada no Modelo do Processo.	29
3.8	Resposta do ONFC _{Dw} com Adaptação de Contexto a uma mudança de <i>setpoint</i> em degrau.	31
3.9	Valores de EM gerados pela Adaptação de Contexto.	32

3.10	Estrutura do ONFC _{DwDe} : (a) Diagrama de Blocos (b) Funções de Pertinência	33
4.1	Foto da planta de controle de processos onde foram realizados os experimentos.	37
4.2	Arquitetura dos equipamentos envolvidos no experimento - Fonte: elaborado pelo autor.	38
5.1	Valores de y (em vermelho) e y_d em (azul) em l/h para o Experimento 3: (a) ONFC _{Dw} com α fixo (b) ONFC _{Dw} com <i>Taxa de Aprendizagem Dinâmica</i>	44
5.2	Valores de α assumidos ao longo do Experimento 3.	45
5.3	Valores de y em l/h para Experimento 4 - ONFC _{Dw} com α fixo	45
5.4	Valores de y em l/h para Experimento 4 - ONFC _{Dw} com α Dinâmico	46
5.5	Posição real da válvula durante o Experimento 4: (a) ONFC _{Dw} com α fixo (b) ONFC _{Dw} com <i>Taxa de Aprendizagem Dinâmica</i>	46
5.6	Valores de α assumidos ao longo do Experimento 4.	47
5.7	Valores de y (em vermelho) e y_d em (azul) em l/h para o Experimento 6: (a) ONFC _{Dw} com α fixo (b) ONFC _{Dw} com <i>Taxa de Aprendizagem Dinâmica</i>	47
5.8	Valores de α assumidos ao longo do Experimento 6.	48
5.9	Valores dos pesos w_1 (em azul) e w_2 (em vermelho) ao longo do Experimento 6: (a) ONFC _{Dw} com α fixo (b) ONFC _{Dw} com <i>Taxa de Aprendizagem Dinâmica</i>	48
5.10	Valores de y (em vermelho) e y_d em (azul) em l/h para o Experimento 1: (a) ONFC _{Dw} sem <i>Adaptação de Contexto</i> (b) ONFC _{Dw} com <i>Adaptação de Contexto</i>	49
5.11	Valores de EM assumidos ao longo do Experimento 1.	50
5.12	Valores dos pesos w_1 (em azul) e w_2 (em vermelho) ao longo do Experimento 1: (a) sem <i>Adaptação de Contexto</i> (b) com <i>Adaptação de Contexto</i>	50
5.13	Valores de y (em vermelho) e y_d em (azul) em l/h para o Experimento 2: ONFC _{Dw} sem <i>Adaptação de Contexto</i>	51
5.14	Valores de y (em vermelho) e y_d em (azul) em l/h para o Experimento 2: ONFC _{Dw} com <i>Adaptação de Contexto</i>	51
5.15	Controlador com <i>Adaptação de Contexto</i> para o Experimento 2. (a) Na parte superior, vazão e <i>setpoint</i> (l/h) e na parte inferior, a saída do controlador (b) Abertura da válvula.	51
5.16	Valores de y (em vermelho) e y_d em (azul) em l/h para Experimento 6: (a) ONFC _{Dw} sem <i>Adaptação de Contexto</i> (b) ONFC _{Dw} com <i>Adaptação de Contexto</i>	52
5.17	Valores de EM assumidos ao longo do Experimento 6.	52

5.18	Valores de y em l/h para Experimento 5: (a) ONFC _{Dw} sem <i>Adaptação de Contexto</i> (b) ONFC _{Dw} com <i>Adaptação de Contexto</i>	53
5.19	Na parte superior, vazão (azul) e <i>setpoint</i> (vermelho) em l/h e na parte inferior, a saída do controlador ONFC _{DwDe}	54
A.1	Experimento 1 - ONFC _{Dw} com α fixo - Valores de y_d , y e u	64
A.2	Experimento 1 - ONFC _{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	64
A.3	Experimento 2 - ONFC _{Dw} com α fixo - Valores de y_d , y e u	65
A.4	Experimento 2 - ONFC _{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	65
A.5	Experimento 3 - ONFC _{Dw} com α fixo - Valores de y_d , y e u	66
A.6	Experimento 3 - ONFC _{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	66
A.7	Experimento 4 - ONFC _{Dw} com α fixo - Valores de y_d , y e u	67
A.8	Experimento 4 - ONFC _{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	67
A.9	Experimento 5 - ONFC _{Dw} com α fixo - Valores de y_d , y e u	68
A.10	Experimento 5 - ONFC _{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	68
A.11	Experimento 6 - ONFC _{Dw} com α fixo - Valores de y_d , y e u	69
A.12	Experimento 6 - ONFC _{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	69
A.13	Experimento 1 - ONFC _{Dw} com α dinâmico - Valores de y_d , y e u	70
A.14	Experimento 1 - ONFC _{Dw} com α dinâmico - Valores de α	70
A.15	Experimento 1 - ONFC _{Dw} com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	70
A.16	Experimento 2 - ONFC _{Dw} com α dinâmico - Valores de y_d , y e u	71
A.17	Experimento 2 - ONFC _{Dw} com α dinâmico - Valores de α	71
A.18	Experimento 2 - ONFC _{Dw} com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	71
A.19	Experimento 3 - ONFC _{Dw} com α dinâmico - Valores de y_d , y e u	72
A.20	Experimento 3 - ONFC _{Dw} com α dinâmico - Valores de α	72
A.21	Experimento 3 - ONFC _{Dw} com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	72
A.22	Experimento 4 - ONFC _{Dw} com α dinâmico - Valores de y_d , y e u	73
A.23	Experimento 4 - ONFC _{Dw} com α dinâmico - Valores de α	73

A.24 Experimento 4 - ONFC $_{Dw}$ com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	73
A.25 Experimento 5 - ONFC $_{Dw}$ com α dinâmico - Valores de y_d , y e u	74
A.26 Experimento 5 - ONFC $_{Dw}$ com α dinâmico - Valores de α	74
A.27 Experimento 5 - ONFC $_{Dw}$ com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	74
A.28 Experimento 6 - ONFC $_{Dw}$ com α dinâmico - Valores de y_d , y e u	75
A.29 Experimento 6 - ONFC $_{Dw}$ com α dinâmico - Valores de α	75
A.30 Experimento 6 - ONFC $_{Dw}$ com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	75
A.31 Experimento 1 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - Valores de y_d , y e u	76
A.32 Experimento 1 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - (a) Valores de α . (b) Valores de <i>EM</i>	76
A.33 Experimento 1 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	76
A.34 Experimento 2 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - Valores de y_d , y e u	77
A.35 Experimento 2 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - (a) Valores de α . (b) Valores de <i>EM</i>	77
A.36 Experimento 2 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	77
A.37 Experimento 3 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - Valores de y_d , y e u	78
A.38 Experimento 3 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - (a) Valores de α . (b) Valores de <i>EM</i>	78
A.39 Experimento 3 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	78
A.40 Experimento 4 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - Valores de y_d , y e u	79
A.41 Experimento 4 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - (a) Valores de α . (b) Valores de <i>EM</i>	79
A.42 Experimento 4 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	79
A.43 Experimento52 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - Valores de y_d , y e u	80
A.44 Experimento 5 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - (a) Valores de α . (b) Valores de <i>EM</i>	80
A.45 Experimento 5 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	80
A.46 Experimento 6 - ONFC $_{Dw}$ com <i>Adaptação de Contexto</i> - Valores de y_d , y e u	81

A.47 Experimento 6 - ONFC _{Dw} com <i>Adaptação de Contexto</i> - (a) Valores de α . (b) Valores de EM	81
A.48 Experimento 6 - ONFC _{Dw} com <i>Adaptação de Contexto</i> - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	81
A.49 Experimento 1 - ONFC _{DwDe} - Valores de y_d , y e u	82
A.50 Experimento 1 - ONFC _{DwDe} - Valores de α	82
A.51 Experimento 1 - ONFC _{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	82
A.52 Experimento 2 - ONFC _{DwDe} - Valores de y_d , y e u	83
A.53 Experimento 2 - ONFC _{DwDe} - Valores de α	83
A.54 Experimento 2 - ONFC _{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	83
A.55 Experimento 3 - ONFC _{DwDe} - Valores de y_d , y e u	84
A.56 Experimento 3 - ONFC _{DwDe} - Valores de α	84
A.57 Experimento 3 - ONFC _{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	84
A.58 Experimento 4 - ONFC _{DwDe} - Valores de y_d , y e u	85
A.59 Experimento 4 - ONFC _{DwDe} - Valores de α	85
A.60 Experimento 4 - ONFC _{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	85
A.61 Experimento 5 - ONFC _{DwDe} - Valores de y_d , y e u	86
A.62 Experimento 5 - ONFC _{DwDe} - Valores de α	86
A.63 Experimento 5 - ONFC _{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	86
A.64 Experimento 6 - ONFC _{DwDe} - Valores de y_d , y e u	87
A.65 Experimento 6 - ONFC _{DwDe} - Valores de α	87
A.66 Experimento 6 - ONFC _{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.	87
A.67 Experimento 1 - Controlador PI - Valores de y_d , y e u	88
A.68 Experimento 2 - Controlador PI - Valores de y_d , y e u	88
A.69 Experimento 3 - Controlador PI - Valores de y_d , y e u	89
A.70 Experimento 4 - Controlador PI - Valores de y_d , y e u	89
A.71 Experimento 5 - Controlador PI - Valores de y_d , y e u	90
A.72 Experimento 6 - Controlador PI - Valores de y_d , y e u	90

Abreviaturas

CLP	Controlador Lógico Programável.
EM	Erro máximo admissível ou faixa de excursão do erro.
IAE	Integral do erro absoluto.
IFMG	Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais.
ITSE	Integral do erro quadrático multiplicado pelo tempo.
MIMO	<i>Multiple Input and Multiple Output.</i>
MPC	<i>Model Predictive Control.</i>
NFN	<i>Neo Fuzzy Neuron.</i>
ONFC	OnLine Neurofuzzy Controller.
ONFC_{Dw}	OnLine Neurofuzzy Controller modificado, com inclusão da ponderação da diferença dos pesos das funções de pertinência.
ONFC_{DwD}	Controlador que inclui uma ação derivativa no controlador ONFC _{Dw} adicionando mais um neurônio.
ONFC_{DwDe}	Controlador que inclui uma ação derivativa no controlador ONFC _{Dw} alterando a entrada do neurônio.
OLE	<i>Object Linking and Embedding.</i>
OPC	<i>OLE for Process Control.</i>
PI	Algoritmo de controle com ação Proporcional e Integral.
PID	Algoritmo de controle com ação Proporcional, Integral e Derivativo.
RNA	Redes Neurais Artificiais.
SISO	<i>Single Input and Single Output.</i>

CAPÍTULO 1

Introdução

O controlador Proporcional, Integral e Derivativo (PID) ainda é o mais usado nos processos industriais, devido a sua rápida e fácil implementação e poucos parâmetros de ajuste (Ogata, 2003), (Vilanova e Visioli, 2012) e (Sato et al., 2018). No entanto, a grande maioria das aplicações de controladores em processos industriais apresenta características não lineares ou parâmetros variantes no tempo (Åström e Kumar, 2014). Essas características fazem com que, frequentemente, os controladores PID apresentem baixo desempenho, exigindo novas sintonias dos parâmetros (Skogestad, 2001).

Dessa forma, cada vez mais estudos são realizados com o intuito de desenvolver técnicas de controle mais eficientes do que as técnicas clássicas, objetivando tratar variações de parâmetros, não linearidades e perturbações no processo a ser controlado (Lamnabhi-Lagarrigue et al., 2017). Dentre as técnicas em constante estudo, estão os controles adaptativos.

Um controlador adaptativo é aquele capaz de alterar seu comportamento em resposta a uma mudança na dinâmica do processo que está sendo controlado e/ou variações nas características dos distúrbios aos quais o processo está sujeito. Em outras palavras, o controlador adaptativo é o que possui parâmetros ajustáveis e um mecanismo para ajustá-los, sendo esse mecanismo o que o torna não-linear (Åström e Wittenmark, 2013). Um diagrama de blocos de um típico controle adaptativo é apresentado na Figura 1.1.

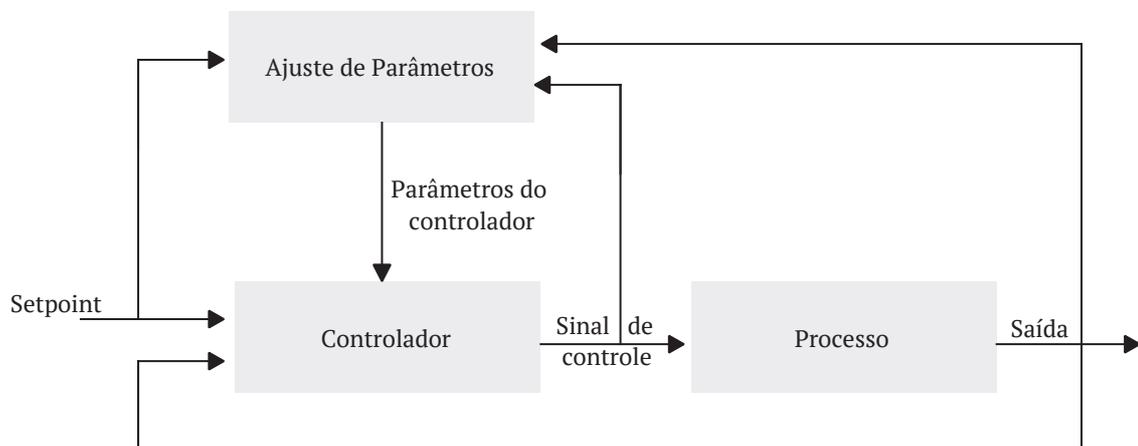


Figura 1.1: Diagrama de blocos de um controle adaptativo - Fonte: adaptado de Åström e Wittenmark (2013).

A análise de um controlador adaptativo pode ser realizada pela interpretação de suas duas malhas, conforme Figura 1.1. A primeira malha é a tradicional, em que o controlador gera a saída para atuar no processo e a saída do processo é usada para realimentar o controlador, que precisa ter parâmetros que possam ser ajustados. A segunda possui o controlador e uma técnica para gerar os novos valores para os parâmetros que serão ajustados. Para as duas malhas de um controle adaptativo podem tanto ser usadas estruturas clássicas como Escalonamento de Ganhos (*Gain Scheduling*), Controle Adaptativo por Modelo de Referência (*Model Reference Adaptive Control*) e Reguladores Auto-Sintonizáveis (*Self-Tuning Regulator*) quanto podem ser empregados sistemas inteligentes baseados em aprendizagem de máquina, como os sistemas nebulosos e as redes neurais artificiais.

Técnicas clássicas para realizar controle adaptativo são frequentemente encontradas na literatura. Aplicando Escalonamento de Ganhos, Narendra e Han (2012) utilizam um esquema de chaveamento entre múltiplos modelos para identificação e controle de processos, em que foram testados tanto em processos invariantes no tempo, mas desconhecidos, quanto em processos conhecidos que possuíam uma rápida variação de seus parâmetros. Ainda com Escalonamento de Ganhos, Nguyen e Tan (2013) utilizam um MPC (*Model Predictive Control*), que faz a otimização do processo, para também ajustar os controladores PID em operação, reduzindo a distância existente entre o módulo de otimização do MPC e os controladores PID do processo. Um trabalho de comparação entre o desempenho de PIDs com e sem Controle Adaptativo por Modelo de Referência é apresentado em Zhang e Wei (2016) e os Reguladores Auto-Sintonizáveis foram analisados em Åström e Wittenmark (1973) e possuem aplicações recentes, como em Suryakala e Rathikarani (2014).

Além das técnicas clássicas, há controladores adaptativos que utilizam inteligência computacional. São técnicas baseadas em aprendizado de máquina que podem apresentar robustez, capacidade de adaptação às mudanças do processo e facilidade de ajuste dos parâmetros (Passino e Yurkovich, 1998). Dentre os controladores baseados em inteligência computacional, estão os que utilizam lógica nebulosa e redes neurais (Jang et al., 1997) e (Babuška e Verbruggen, 1996). Destacam-se dentro dos controladores adaptativos baseados em lógica nebulosa o PID Fuzzy (Carvajal et al., 2000), controles baseados em Modelo Takagi-Sugeno (Takagi e Sugeno, 1985) e os controladores neurofuzzy (Jang e Sun, 1995).

Os controladores utilizando sistemas neurofuzzy vêm sendo empregados nas mais diversas áreas, com aplicações recentes em controle de velocidade de motores (Rashidi, 2017), robótica (dos Santos et al., 2016), drones (de Araújo, 2011), velocidade de trens (Yang et al., 2014), entre outros.

Gouvêa (2005) propôs um controlador denominado OnLine Neurofuzzy Controller (ONFC), que consiste em um controlador baseado na estrutura Neo Fuzzy Neuron (NFN) (Yamakawa et al., 1992), que agrega as importantes características das redes neurais e dos sistemas nebulosos. Esse controlador, que em sua estrutura é similar a um controlador PI (Pires, 2007), apresenta baixo custo computacional, facilidade de ajuste de seus

parâmetros e capacidade de adaptação em uma larga faixa de operação. O ONFC já foi empregado com sucesso em controle de velocidade de motores (Gouvêa, 2005), controle de processos não lineares (Pires, 2007), em controle de processos petroquímicos (Carvalho, 2010), em uma planta de levitação magnética (Oliveira, 2017) e em controle de temperatura de fornos (Ferreira, 2017).

O ONFC realiza o ajuste dos pesos, baseado no método de gradiente descendente. Assim, de acordo com o erro do processo, os pesos são ajustados de forma a adaptar-se ao processo e reduzir ao máximo o erro. Como, na prática, o erro nunca é nulo, devido a ruídos de medição, características do processo, distúrbios, entre outras razões, os pesos são constantemente ajustados, levando-os a valores elevados e até mesmo divergentes. Essa possibilidade de divergência dos pesos é uma limitação de uso do ONFC original, já evidenciada na literatura (Gouvêa, 2005), (Pires, 2007) e (Carvalho, 2010).

Quando Gouvêa (2005) propôs o controlador ONFC, algumas estratégias para contornar o problema foram utilizadas como o não ajuste dos pesos quando o processo apresentava erros inferiores a um limite pré-definido e limites para os valores dos pesos. Uma solução para o problema é apresentada por (Carvalho, 2010) em que é acrescida na função objetivo uma componente referente à minimização da diferença dos pesos.

A taxa de aprendizagem, parâmetro α , é o tamanho do passo do método gradiente descendente utilizado no ONFC e é de fundamental importância para obter um bom desempenho do controlador. Na literatura são realizados estudos que mostram a influência deste parâmetro na estabilidade e ainda, se comparado com um controlador PI, o parâmetro α está relacionado diretamente tanto à ação proporcional quanto à ação integral (Pires, 2007). Carvalho (2010) propõe um método para ajuste da taxa de aprendizagem, baseado em testes computacionais. Ferreira (2017) utiliza um alfa dinâmico para melhorar o desempenho e flexibilizar um pouco o ajuste da taxa de aprendizagem inicial.

Outro parâmetro importante, que interfere no ganho do controlador e que define uma região linear das funções de pertinência, é a faixa de excursão do erro, EM . Na literatura são encontradas abordagens que definem valores fixos para o EM , baseados em conhecimento do processo ou requisitos de controle. (Gouvêa, 2005), (Pires, 2007), (Carvalho, 2010).

Neste trabalho, é realizada uma revisão do controlador ONFC, explorando as melhorias realizadas ao longo dos anos. São discutidos os efeitos dos parâmetros α e EM , destacando o ajuste dinâmico do α para o qual é criada uma nova forma de cálculo da taxa de aprendizagem e é apresentada uma metodologia de ajuste dinâmico também para o EM , denominada *Adaptação de Contexto*. É proposta uma alternativa para inclusão da ação derivativa no controlador. Experimentos em uma planta didática que possui instrumentos industriais são realizados para verificar o desempenho dos controladores.

1.1 Motivação

O ONFC proposto por Gouvêa (2005) é um controlador de baixo custo computacional, de fácil implementação e com bom desempenho para uma ampla faixa do processo. Quando o controlador ONFC_{D_w} é proposto (Carvalho, 2010), o problema de aumento da diferença dos pesos é contornado. No mesmo trabalho, a taxa de aprendizagem, α , é identificada como parâmetro crítico e uma proposta de ajuste do parâmetro é realizada.

A popularidade do uso de uma técnica de controle está diretamente associada ao desempenho do controlador e a facilidade em ajustá-la ao processo em que este será aplicado. Sempre que um estudo propõe uma metodologia para ajuste de um controlador que pode resultar em facilidade na sua utilização e melhora no desempenho, o trabalho está contribuindo para que a teoria desenvolvida seja empregada para controle de processos reais e a técnica de controle seja difundida.

Nesse sentido, o presente trabalho propõe uma pesquisa para realizar uma revisão do ONFC, destacando as soluções propostas para ajustes de seus parâmetros, sendo aprofundando o ajuste adaptativo da taxa de aprendizagem do controlador. Uma nova forma de calcular a taxa de aprendizagem é proposta, baseada no modelo do processo. É introduzida uma forma dinâmica para ajuste da faixa de excursão do erro, outro parâmetro importante do controlador.

Na área de controle de processos, é muito importante que a distância entre a teoria de controle e os problemas práticos seja encurtada, aplicando as novas técnicas desenvolvidas para solução de problemas difíceis (Åström e Kumar, 2014). Na área de controle nebuloso, Boutalis e Christodoulou (2012) apresenta que apesar dos grandes avanços nas abordagens neurofuzzy adaptativas e os diversos casos de aplicações com sucesso dos controladores, ainda há uma lacuna para a utilização destes controladores em sistemas industriais reais. Um dos objetivos do trabalho é utilizar o ONFC com as abordagens para ajuste dos parâmetros em um processo em tempo real, em uma planta didática que possui um controlador lógico programável (CLP), redes industriais e instrumentação compatíveis com indústrias de grande porte. O sucesso dessa aplicação prática visa contribuir para difundir a utilização industrial do ONFC.

1.2 Objetivos

Objetivo Geral

O trabalho tem como objetivo geral realizar uma revisão do controlador ONFC, estudar o ajuste de seus parâmetros, propor melhorias e aplicá-lo em um processo real.

Objetivos Específicos

São objetivos específicos do trabalho:

- Fazer uma revisão bibliográfica sobre o controlador neurofuzzy com aprendizado online.
- Realizar simulações computacionais do controlador neurofuzzy com aprendizado online encontrado na literatura, evidenciando os problemas já encontrados e soluções propostas.
- Trabalhar a abordagem dinâmica de ajuste da taxa de aprendizagem do controlador.
- Propor uma metodologia para ajuste dinâmico da faixa de excursão do erro.
- Utilizar o controlador com as abordagens propostas e estudadas em uma planta didática com equipamentos industriais.

1.3 Estrutura do texto

A partir desta introdução, a dissertação foi organizada da seguinte forma:

- **Capítulo 2:** Revisitando o ONFC, no qual é realizada a revisão bibliográfica do ONFC, sendo apresentadas as versões do controlador encontradas na literatura com as melhorias e contribuições geradas por cada versão.
- **Capítulo 3:** Análise dos parâmetros do controlador e contribuições, no qual são apresentados os estudos dos parâmetros α e EM , é apresentada a nova formulação para a Taxa de Aprendizagem do controlador baseada no Modelo do Processo, a *Adaptação de Contexto* e também a nova abordagem para inclusão da ação derivativa no controlador.
- **Capítulo 4:** Metodologia, no qual é detalhada a metodologia utilizada nos experimentos, descrevendo o processo a ser controlado, os experimentos propostos e quais controladores são utilizados.
- **Capítulo 5:** Resultados, no qual são apresentados e analisados os resultados dos experimentos.
- **Capítulo 6:** Considerações finais, concluindo o trabalho e apresentando propostas de trabalhos futuros.

Revisitando o ONFC

Neste capítulo é apresentada a revisão bibliográfica do OnLine NeuroFuzzy Controller (ONFC) feita, incluindo as formulações matemáticas dos controladores, a motivação para cada nova versão do controlador e as melhorias trazidas com cada versão. Implementações computacionais foram realizadas para evidenciar o comportamento e as características de cada controlador.

2.1 ONFC original

O controlador ONFC foi proposto por Gouvêa (2005) baseado na ideia da rede Neo Fuzzy Neuron (NFN) (Yamakawa et al., 1992). Trata-se de um controlador de estrutura simples, com poucos parâmetros, que agrega interessantes características dos sistemas nebulosos e das redes neurais artificiais e que consegue ser adaptativo às condições do processo a ser controlado.

O controlador empregado em sistemas com uma entrada e uma saída é equivalente ao mecanismo de inferência *Takagi Sugeno* de ordem zero (Takagi e Sugeno, 1985), com duas regras fuzzy conforme apresentado a seguir, sendo A_1 e A_2 dois conjuntos nebulosos representados pelas funções de pertinência triangulares e complementares $\mu_1(e)$ e $\mu_2(e)$ e u o valor da ação na saída do controlador.

- Se erro (e) é A_1 então a ação u é $u_1 = w_1$;
- Se erro (e) é A_2 então a ação u é $u_2 = w_2$,

É apresentado, na Figura 2.1, o diagrama de blocos de um processo controlado com o ONFC.

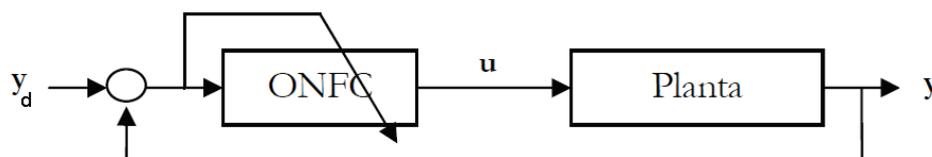


Figura 2.1: Diagrama de blocos de uma malha de controle com o ONFC - Fonte: adaptado de Pires (2007).

Assim como a maioria dos controladores convencionais, o ONFC calcula o valor da sua saída de acordo com o sinal de erro (e), que é calculado como a diferença entre o valor desejado e o valor real da variável controlada, conforme Equação 2.1. No caso do ONFC, o erro é usado tanto para cálculo da saída quanto para ajuste do controlador, tornando-o adaptativo.

A simplicidade do ONFC também é visualizada em suas funções de pertinência, pois a rede é composta por duas funções triangulares e complementares, apresentadas na Figura 2.2.

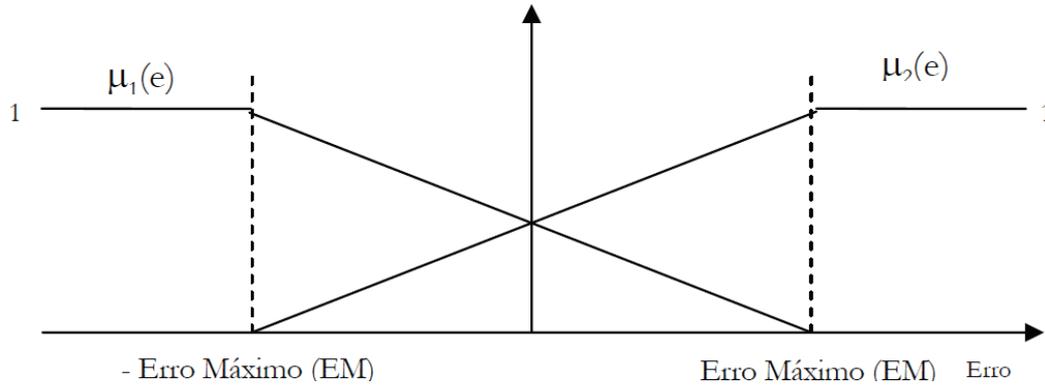


Figura 2.2: Funções de pertinência usadas no ONFC - Fonte: adaptado de Pires (2007).

Os valores das funções de pertinência, μ_1 e μ_2 , são dados pelas Equações 2.2 e 2.3, respectivamente.

$$e = y_d - y \quad (2.1)$$

$$\mu_1(e) = \begin{cases} 1, & \text{se } e \leq -EM \\ \frac{EM-e}{2EM}, & \text{se } -EM < e < EM \\ 0, & \text{se } e \geq EM \end{cases} \quad (2.2)$$

$$\mu_2(e) = \begin{cases} 0, & \text{se } e \leq -EM \\ \frac{EM+e}{2EM}, & \text{se } -EM < e < EM \\ 1, & \text{se } e \geq EM \end{cases} \quad (2.3)$$

Como as funções de pertinência $\mu_1(e)$ e $\mu_2(e)$ são complementares, uma pode ser calculada em função da outra, conforme Equação 2.4.

$$\mu_2(e) = 1 - \mu_1(e) \quad (2.4)$$

O termo EM aparece nas Equações 2.2 e 2.3, sendo definido como o erro máximo admissível, o universo de discurso das funções de pertinência ou a faixa de excursão do erro. Para o controlador ONFC, não é interessante que este parâmetro defina todos os possíveis valores para o erro, mas apenas a faixa na qual o erro é aceitável. A Equação 2.5 define o termo EM em função dos erros máximos admitidos em ambos os sentidos, quando o erro é positivo e quando o erro é negativo, admitindo valores diferentes para os dois casos. No capítulo 3, a influência desse parâmetro no desempenho do controlador será discutida, bem como explicitada uma metodologia utilizada para ajustá-lo.

$$EM = \frac{e_{max} - e_{min}}{2} \quad (2.5)$$

A saída de controle gerada pelo ONFC é calculada de acordo com a Equação 2.6, sendo uma soma das funções de pertinência ponderadas pelos respectivos pesos.

$$u = \frac{\mu_1(e)u_1 + \mu_2(e)u_2}{\mu_1(e) + \mu_2(e)} \therefore u = \mu_1(e)w_1 + \mu_2(e)w_2 \quad (2.6)$$

A Figura 2.3 apresenta um diagrama de blocos da estrutura interna do ONFC. Conforme já discutido, as funções de pertinência são calculadas a partir do erro e a saída é gerada a partir de uma soma dos pesos ponderada pelas funções de pertinência. O diagrama de blocos enfatiza ainda que o sinal de erro é usado também para ajustar o valor dos pesos.

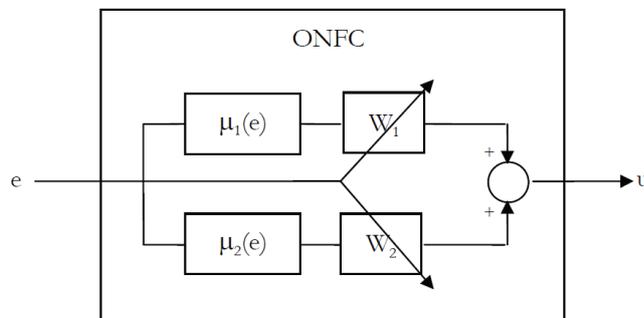


Figura 2.3: Diagrama de blocos do ONFC - Fonte: (Pires, 2007).

O ajuste dos pesos é feito, minimizando uma função custo, que é definida em função do erro quadrático, dada pela Equação 2.7.

$$J = \frac{1}{2}(e)^2 \quad (2.7)$$

Derivando a Equação 2.7 em relação a w_1 e w_2 , e aplicando a regra da cadeia, são obtidas as Equações 2.8 e 2.9, respectivamente.

$$\frac{\partial J}{\partial w_1} = \frac{\partial J}{\partial e} \frac{\partial e}{\partial y} \frac{\partial y}{\partial u} \frac{\partial u}{\partial w_1} \quad (2.8)$$

$$\frac{\partial J}{\partial w_2} = \frac{\partial J}{\partial e} \frac{\partial e}{\partial y} \frac{\partial y}{\partial u} \frac{\partial u}{\partial w_2} \quad (2.9)$$

A partir do cálculo de cada parcela das Equações 2.8 e 2.9, é possível chegar na expressão que fornece o passo do gradiente descendente que minimiza a função custo, ou seja, por meio dela é possível ajustar os pesos das funções de pertinência de forma a minimizar o erro (para simplificação da notação, de agora em diante, é adotado que $\mu_1(e) = \mu_1$ e $\mu_2(e) = \mu_2$). Primeiramente para w_1 :

$$\frac{\partial J}{\partial e} = 2 \frac{1}{2}(e) = e \quad (2.10)$$

$$\frac{\partial e}{\partial y} = \frac{(\partial y_d - y)}{\partial y} = -1 \quad (2.11)$$

$$\frac{\partial u}{\partial w_1} = \frac{\partial(\mu_1 w_1 + \mu_2 w_2)}{\partial w_1} = \mu_1 \quad (2.12)$$

O termo $\frac{\partial y}{\partial u}$ expressa a variação de y em relação à saída do controlador. Como esse termo em princípio não é conhecido, essa parcela é usada para determinar o sinal da taxa de aprendizagem do controlador. Para determinar o sinal, quando o aumento da saída do controlador promove aumento da variável de processo, define-se o ganho positivo e a taxa de aprendizagem também é positiva. Quando acontece o contrário, em que o aumento da saída do controlador reduz a variável de processo, define-se o ganho negativo e taxa de aprendizagem passa a ser também negativa.

Dessa forma, substituindo os valores das Equações 2.10, 2.11 e 2.12 na Equação 2.8 obtém-se a expressão que determina o ajuste de w_1 pelo método do gradiente descendente, conforme Equações 2.13.

$$w_{1k} = w_{1(k-1)} - \alpha \mu_1 (-1)e \quad \therefore \quad w_{1k} = w_{1(k-1)} + \alpha \mu_1 e \quad (2.13)$$

Para w_2 , a única parcela diferente é a da Equação 2.12, que para w_2 é definida na Equação 2.14. Substituindo em 2.9, obtém-se a Equação 2.15, que ajusta o peso w_2 pelo método do gradiente descendente.

$$\frac{\partial u}{\partial w_2} = \frac{\partial(\mu_1 w_1 + \mu_2 w_2)}{\partial w_2} = \mu_2 \quad (2.14)$$

$$w_{2k} = w_{2(k-1)} - \alpha \mu_2 (-1)e \quad \therefore \quad w_{2k} = w_{2(k-1)} + \alpha \mu_2 e \quad (2.15)$$

O termo α presente nas equações de ajuste dos pesos é a taxa de aprendizagem do controlador ou o passo do gradiente descendente.

Conforme apresentado, o ONFC possui equações simples e de rápida implementação. Em termos de ajustes, existem apenas dois parâmetros: a taxa de aprendizagem (α) e a faixa de excursão do erro (EM), cujas metodologias de ajuste serão discutidas no presente trabalho.

2.1.1 Simulação do ONFC

Para ilustrar o comportamento do ONFC original, é apresentada uma simulação em que o controlador é empregado em um processo, cuja dinâmica pode ser descrita por um sistema de primeira ordem com atraso, conforme descrito na Equação 2.16.

$$G(s) = \frac{3e^{-1s}}{2s + 1} \quad (2.16)$$

É apresentada, na Figura 2.4, a resposta da variável de processo quando aplicada uma mudança de *setpoint* em degrau.

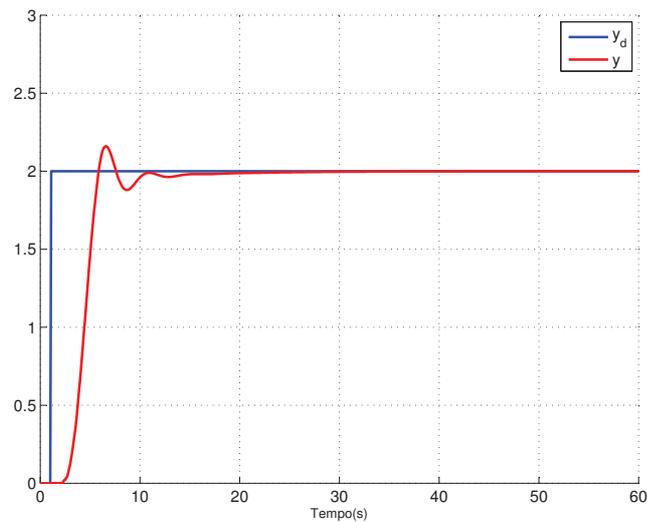


Figura 2.4: Sistema com ONFC após mudança de *setpoint* em degrau.

Na Figura 2.5, é apresentado o gráfico com a saída do controlador.

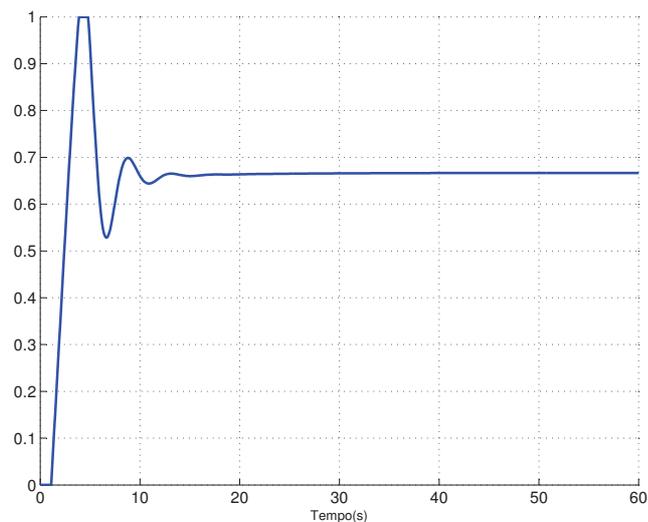


Figura 2.5: Saída do controlador ONFC.

Ao analisar os gráficos da Figura 2.4, é possível perceber a boa capacidade do controlador em rapidamente responder à mudança de *setpoint* e zerar o erro em regime permanente. Há um

pequeno *overshoot*, que é resultante do ajuste feito para a taxa de aprendizagem e para a faixa de excursão do erro, que serão discutidos no próximo capítulo.

Para obter a resposta apresentada, ocorreu o ajuste dos pesos das funções de pertinência, conforme apresentado na Figura 2.6. Em azul, está a curva com valores para o peso w_1 e, em preto, para o peso w_2 . A curva em vermelho é a diferença aritmética entre os dois pesos, $w_2 - w_1$.

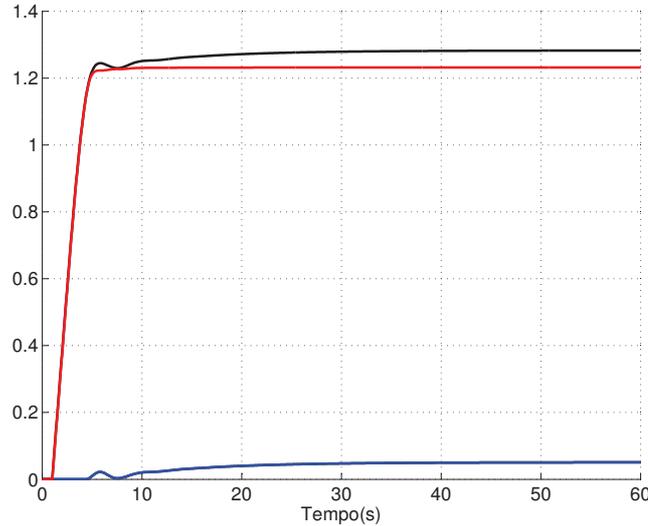


Figura 2.6: Valores dos pesos w_1 , w_2 e diferença $w_2 - w_1$.

Analisando a saída do controlador, é possível ver em um primeiro momento um comportamento mais agressivo quando o erro é maior e em um segundo momento um crescimento da saída de controle até que o erro em regime permanente seja zerado. Esse comportamento é muito similar ao de um controlador PI, assunto que será discutido na próxima seção.

2.1.2 Comparativo com Controlador PI

Pires (2007) realiza uma análise matemática para melhor compreender o funcionamento do ONFC. Assim, considerando que o erro não ultrapassa os limites do universo de discurso (faixa de excursão do erro), definidos quando ocorre a seleção do parâmetro EM , são realizadas substituições na equação da saída do controlador, permitindo escrever a Equação 2.6 na forma da Equação 2.17:

$$u_k = \frac{\alpha \cdot \sum_{i=1}^k e_i^2}{2EM^2} \cdot e_k + \frac{\alpha}{2} \cdot \sum_{i=1}^k e_i \quad (2.17)$$

Analisando a Equação 2.17, Pires (2007) faz uma comparação do ONFC com um controlador PI adaptativo. É possível observar que há duas parcelas, uma relacionada ao erro no instante k e outra parcela relacionada ao somatório do erro. As Equações 2.18 e 2.19 apresentam as equivalências às constantes proporcional e integral, respectivamente.

$$K_p = \frac{\alpha \cdot \sum_{i=1}^k e_i^2}{2EM^2} \quad (2.18)$$

$$K_i = \frac{\alpha}{2} \quad (2.19)$$

A Equação 2.18 apresenta uma constante proporcional adaptativa, que começa com valor zero e vai aumentando de acordo com o erro quadrático. A ação proporcional é ponderada pelo parâmetro α e também inversamente proporcional ao parâmetro EM . A Equação 2.19 apresenta uma constante integral fixa, não adaptativa, que depende única e exclusivamente do parâmetro α . Percebe-se então que os parâmetros α e EM influenciam diretamente no desempenho do controlador e na sua estabilidade.

Outra observação importante decorrente dessa análise é que a constante proporcional vai aumentando com o somatório do erro. Em processos reais o erro nunca é nulo devido à fatores como ruídos de medição, incerteza do medidor, variabilidade do processo, entre outros. Como consequência, a constante proporcional está sempre aumentando, podendo chegar a valores muito elevados. Essa questão será melhor descrita na próxima secção.

2.1.3 O Aumento na Diferença dos Pesos

Conforme foi apresentado na última secção e evidenciando nas Equações 2.13 e 2.15, o ONFC realiza o ajuste dos pesos sempre que houver erro. Em processos reais, a variável de processo nunca é exatamente igual ao valor desejado, ainda que de forma mínima, existe sempre um erro ocasionado pelas mais diversas fontes, que resultam em um constante ajuste dos pesos do controlador. Esse constante ajuste faz com que os pesos cresçam em direções opostas, aumentando a diferença entre eles. O problema tem particular importância uma vez que pesos muito altos aumentam a possibilidade de instabilidade no controle do processo.

Para ilustrar esse comportamento, uma nova simulação é apresentada, na qual para o mesmo processo apresentado na Equação 2.16 é introduzido um ruído branco na variável controlada, de forma que não é mais possível obter o erro nulo. Esse ruído branco simula, por exemplo, o ruído de medição presente em qualquer variável que está sendo controlada em um processo real. Na Figura 2.7, é apresentada a resposta do controlador para o mesmo sistema apresentado anteriormente, com a mesma mudança de *setpoint*, porém acrescido de um ruído de média nula.

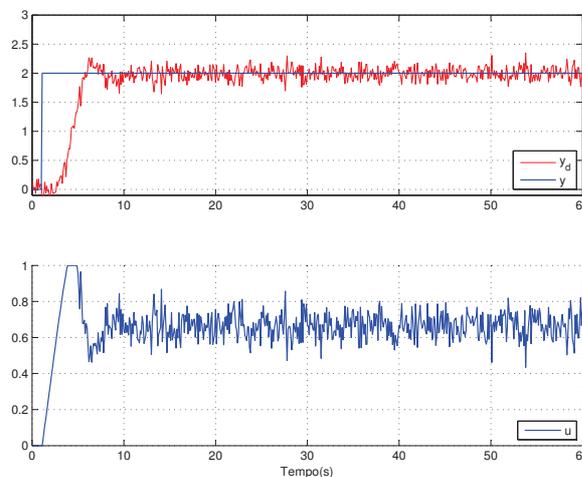


Figura 2.7: Utilização do ONFC com presença de ruído branco na variável controlada.

Em um primeiro momento, a resposta do controlador continua dentro dos padrões desejados. No entanto, como o erro não é nulo, há um constante ajuste dos pesos, conforme é apresentado na Figura 2.8. Ao contrário da Figura 2.6, em que a diferença dos pesos mantinha-se constante em regime permanente, a linha preta, que representa a diferença entre os pesos, cresce de forma contínua. Esse comportamento é indesejado, já que os pesos ficam cada vez maiores, podendo acarretar problemas de instabilidade do controlador por pesos muito elevados.

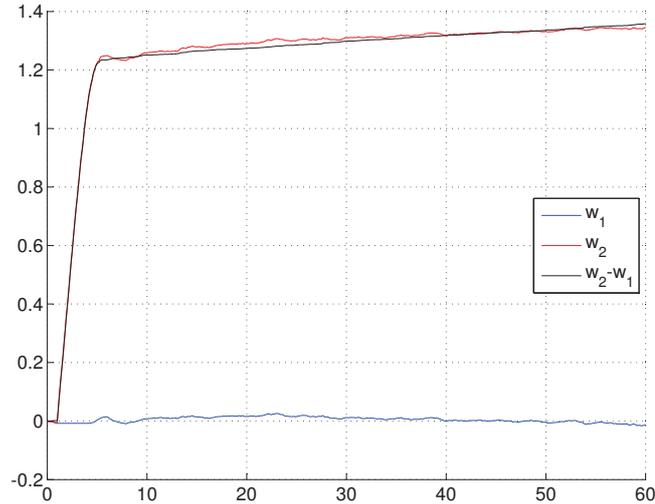


Figura 2.8: Valores dos pesos w_1 e w_2 - Simulação com ruído branco.

As simulações apresentadas nas Figuras 2.7 e 2.6 tem duração de 1 minuto. Se deixarmos uma simulação por um tempo mais longo, como por exemplo 10 minutos, já é possível perceber que o sistema apresenta sinais de instabilidade (Figura 2.9), à medida que a diferença dos pesos cresce (Figura 2.10). Na Figura 2.9, o primeiro gráfico, em vermelho, é o comportamento da variável controlada com o ruído, o segundo gráfico é a saída de controle, que ao final da simulação já possui oscilações de amplitude mais elevada.

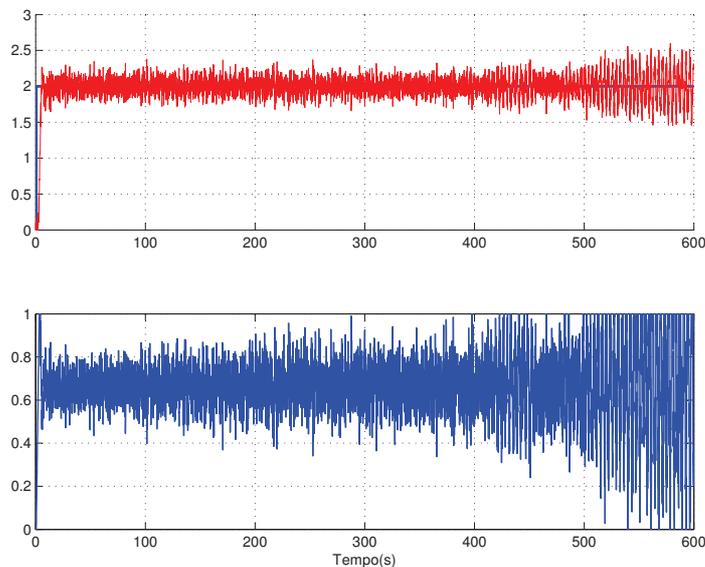


Figura 2.9: Tendência à instabilidade no controle devido ao aumento nos pesos.

Na Figura 2.10, é apresentada a diferença dos pesos, que cresce de forma cada vez mais acentuada devido à presença do ruído e consequentemente presença constante de erro.

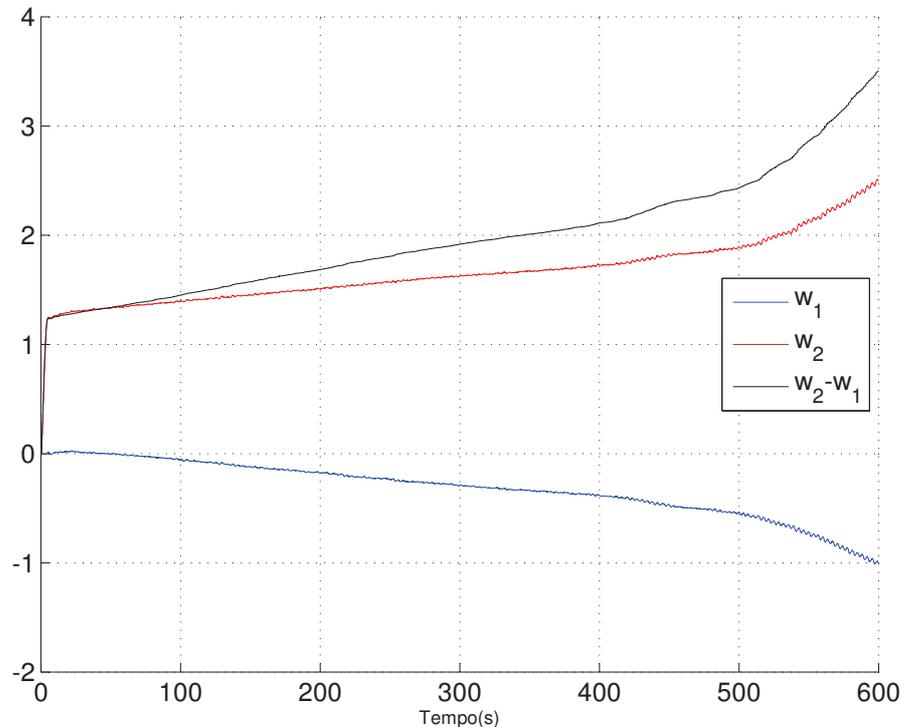


Figura 2.10: Aumento da diferença dos pesos.

O problema de aumento dos pesos já foi reportado por (Gouvêa, 2005) quando na formulação do controlador, em que duas estratégias são apresentadas para contornar o problema. Na primeira estratégia, denominada *Bloqueio por Zona Morta*, o controlador define uma faixa de erro para a qual os pesos do ONFC não são mais atualizados. A atualização só acontece quando o erro ultrapassa um limite pré-definido. Foi observado que essa estratégia gerou um oscilação de baixa frequência na variável controlada.

Uma segunda estratégia é proposta no mesmo trabalho, denominada *Correção por Limite*. Como a saída do controlador é uma combinação linear dos pesos e das funções de pertinência, a estratégia baseia-se na ideia de arbitrar o valor de um dos pesos e recalculá-lo em função do primeiro. Assim, sempre que um dos pesos atinge um valor pré-determinado, este é imediatamente reduzido; enquanto o outro peso é recalculado para que a saída do controlador não seja alterada. Nessa estratégia, não são observadas oscilações na variável controlada.

Uma terceira estratégia, proposta por Carvalho (2010) altera o processo de ajuste dos pesos, introduzindo na função custo uma parcela referente a diferença dos pesos. A etapa de otimização do gradiente descendente passa então a considerar, além da minimização do erro, também a redução da diferença entre os pesos. Essa nova formulação deu origem ao controlador $ONFC_{Dw}$, que será melhor discutido na próxima seção.

2.2 ONFC_{Dw}

A partir do ONFC, Carvalho (2010) formula o ONFC_{Dw} que é o On-Line Neurofuzzy Controller modificado, com a inclusão da ponderação da diferença dos pesos das funções de pertinência (Dw), para solucionar o problema do aumento da diferença dos pesos descrito na última secção.

Enquanto o ONFC original considera na função custo apenas uma parcela referente ao erro quadrático, a formulação proposta no ONFC_{Dw} parte da ideia de que o erro possui duas parcelas, uma referente ao próprio processo, nos casos de mudança de *setpoint* e/ou distúrbios do processo, para a qual o controlador é projetado e outra parcela de erro referente ao efeito do ruído da ação de controle. Particularmente no caso do ONFC, a redução do ruído gerado pela ação de controle passa pela redução dos pesos associados às funções de pertinência, ou da diferença entre eles (Dw), que é então incluída na função custo do processo de otimização do ajuste dos pesos das funções de pertinência do controlador ONFC, gerando a Equação 2.20.

$$J = \frac{1}{2}e_p^2 + \frac{1}{2}(K_r(w_1 - w_2)\sigma_{ruído})^2 \quad (2.20)$$

O termo $K_r(w_1 - w_2)\sigma_{ruído}$ diz respeito ao sinal do ruído, multiplicado pela diferença dos pesos e um ganho do próprio processo. Após derivar a equação e repetir o procedimento realizado para a Equação 2.7, Carvalho (2010) estabelece a forma de atualização dos pesos do ONFC_{Dw}, apresentada nas Equações 2.21 e 2.22.

$$w_1(k+1) = w_1(k) - \alpha\beta\mu_1e + \alpha(1-\beta)(w_2 - w_1) \quad (2.21)$$

$$w_2(k+1) = w_2(k) - \alpha\beta\mu_2e + \alpha(1-\beta)(w_2 - w_1) \quad (2.22)$$

A atualização dos pesos acontece de forma parecida com o controlador ONFC, porém há uma parcela referente à minimização da diferença dos pesos. O ONFC_{Dw} cria o parâmetro β que pondera os dois objetivos inseridos na função custo do controlador. O parâmetro β pode assumir valores entre 0 e 1, sendo que, quando está próximo de 1, o controlador está dando prioridade a redução do erro e está mais próximo da formulação do ONFC original. Quanto mais próximo de 0, mais está sendo priorizada a redução da diferença dos pesos. Observa-se em Carvalho (2010) que o valor de β deve ser próximo da relação sinal/ruído da variável controlada. Caso ainda assim esteja ocorrendo divergência no valor dos pesos, levando ao aumento da diferença Dw , deve-se reduzir o valor de beta de forma gradativa. Assim, essa metodologia será adotada no presente trabalho.

Com essa formulação, o efeito de aumento da diferença dos pesos, que poderia gerar a instabilidade no controlador é minimizada, como pode ser observado na simulação apresentada na próxima secção.

2.2.1 Simulação do ONFC_{Dw}

É apresentada a simulação usando o ONFC_{Dw} para o mesmo sistema utilizado nas simulações anteriores, acrescido do ruído branco. A resposta do sistema é apresentada na Figura 2.11 com o *setpoint* em degrau e a resposta do sistema no gráfico superior e a saída de controle no gráfico inferior.

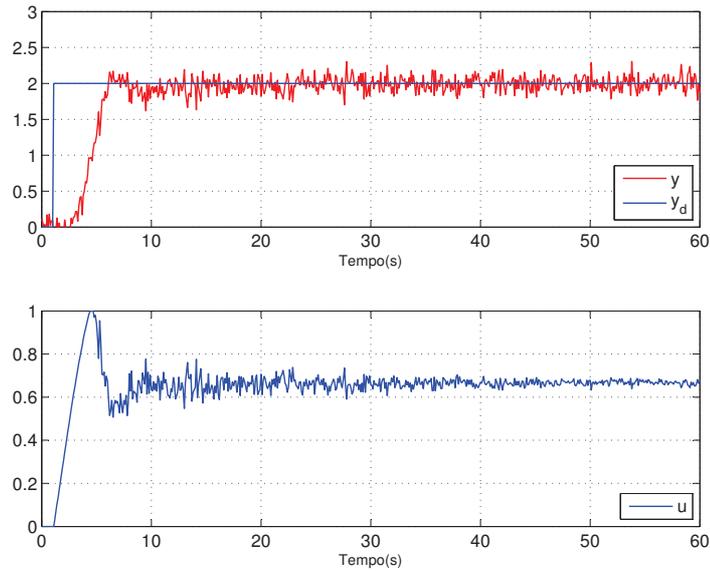


Figura 2.11: Comportamento do controlador ONFC_{Dw}.

Pode-se observar que a resposta do sistema ao degrau foi rápida, não há erro em regime permanente, não há oscilação e nenhum sinal de instabilidade. Se for aumentado o tempo de simulação é possível observar que a resposta do sistema permanece a mesma, sem sinais de instabilidade, conforme apresentado na Figura 2.12.

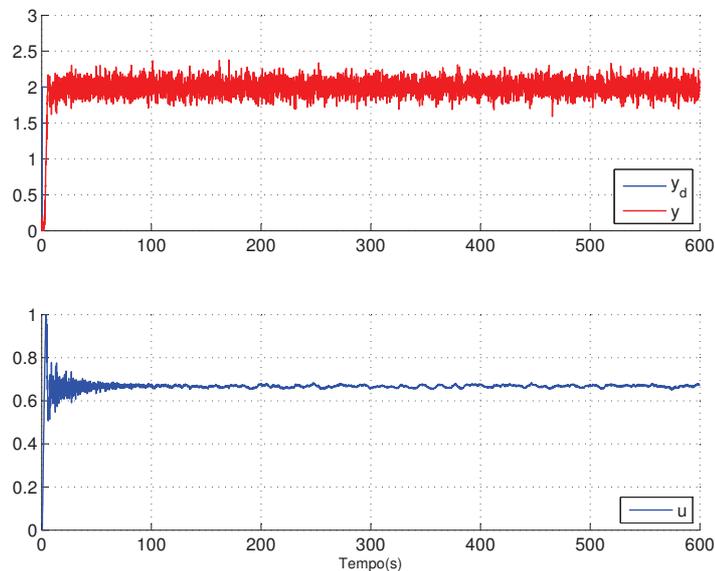


Figura 2.12: Comportamento do controlador ONFC_{Dw} - Simulação por 10 minutos.

A Figura 2.13 apresenta o comportamento dos pesos das funções de pertinência e a diferença entre os pesos na simulação com duração de 10 minutos. Ao contrário do ONFC, não há aumento da diferença dos pesos. Pelo contrário, a diferença dos pesos aumenta durante o regime transitório do controlador provocado pela mudança do *setpoint* em degrau e depois disso, quando o controlador entra em regime permanente, ocorre a redução dos pesos do controlador com convergência para valores mais baixos do que os atingidos durante o regime transitório. É possível

observar ainda que o sistema não "esqueceu" completamente os pesos e que conforme apresentado na Figura 2.12, a redução da Dw não acarretou em queda no desempenho do controlador. Uma análise visual sobre o sinal de controle, presente na parte inferior da Figura 2.12, aponta para uma redução na amplitude do sinal quando há ganhos menores. Isso acontece porque o erro referente ao ruído gerado pela ação de controle, formulado como $K_r(w_1 - w_2)\sigma_{ruído}$ está sendo reduzido, à medida que a diferença dos pesos é reduzida.

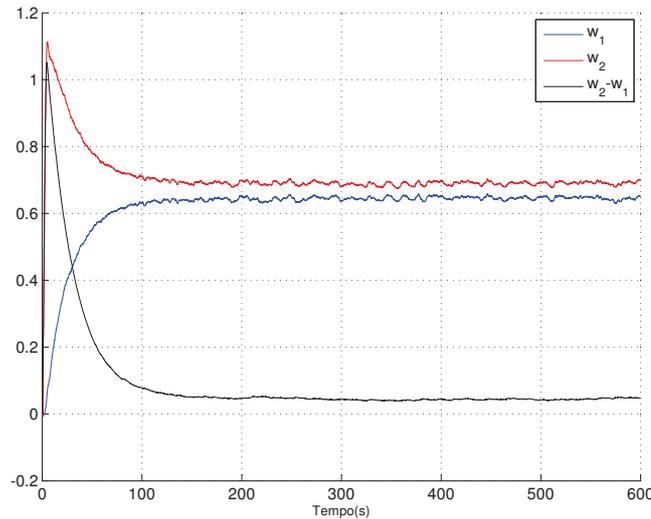


Figura 2.13: Ajuste dos pesos w_1 e w_2 para o controlador ONFC_{Dw} .

Assim, a simulação mostra que o problema de aumento da diferença dos pesos é contornado de forma satisfatória com a utilização do controlador ONFC_{Dw} .

2.3 ONFC_{DwD}

Partindo do controlador ONFC_{Dw} , Oliveira (2017) propõe a inclusão de uma ação derivativa ao controlador. A inclusão da ação derivativa permite que o controlador ONFC, já matematicamente comparado com um controlador PI, possua uma ação de controle com caráter também antecipatório e comportamento mais próximo de um controlador PID.

A estrutura do ONFC_{Dw} é mantida, sendo acrescida de um novo neurônio NFN, que tem como entrada a variação temporal da variável de processo, sendo aceitável a utilização da variação temporal do erro (não recomendada para evitar o *derivative kick* que ocorre quando há mudanças de *setpoint* e o cálculo da derivada do erro, repentinamente, sofre um salto). A saída desse novo neurônio é somada à saída do neurônio do ONFC_{Dw} . A formulação da entrada do neurônio é feita, assumindo que o valor desejado, referência ou *setpoint* é mantido constante e descrito conforme Equação 2.23, em que T é o período de amostragem do controlador.

$$\frac{de}{dt} = \frac{d(y_d - y)}{dt} = -\frac{dy}{dt} \approx -\frac{\Delta y_k}{T} = \frac{-(y_k - y_{(k-1)})}{T} \quad (2.23)$$

Assim, é desenvolvida a mesma metodologia para o cálculo do neurônio NFN adicional, que resulta nas equações de ajuste dos pesos dos dois neurônios. Para o neurônio original, já presente no ONFC_{Dw}, são usadas as Equações 2.24 e 2.25. Para o neurônio adicional, referente a ação derivativa, são apresentadas as Equações 2.26 e 2.27, em que q_1 e q_2 são os pesos para o neurônio que trabalha com a taxa de variação da variável y .

$$w_{1k} = w_{1(k-1)} + \alpha(1 - \beta)e_k \frac{\partial y}{\partial u} \mu_1(e_k) + \alpha\beta(w_{2(k-1)} - w_{1(k-1)} - f_w \Delta w_0) \quad (2.24)$$

$$w_{2k} = w_{2(k-1)} + \alpha(1 - \beta)e_k \frac{\partial y}{\partial u} \mu_2(e_k) + \alpha\beta(w_{2(k-1)} - w_{1(k-1)} - f_w \Delta w_0) \quad (2.25)$$

$$q_{1k} = q_{1(k-1)} + \sigma(1 - \phi)e_k \frac{\partial y}{\partial \Delta u} \mu_1\left(\frac{-\Delta y_k}{T}\right) + \sigma\phi(q_{2(k-1)} - q_{1(k-1)} - f_q \Delta q_0) \quad (2.26)$$

$$q_{2k} = q_{2(k-1)} + \sigma(1 - \phi)e_k \frac{\partial y}{\partial \Delta u} \mu_2\left(\frac{-\Delta y_k}{T}\right) + \sigma\phi(q_{2(k-1)} - q_{1(k-1)} - f_q \Delta q_0) \quad (2.27)$$

Nessa formulação é acrescida uma parcela na equação de ajuste dos pesos que visa limitar o “esquecimento” do aprendizado obtido. Assim, a minimização da diferença dos pesos acontecerá até certo ponto, balizado pelos termos $f_w \Delta w_0$ e $f_q \Delta q_0$, que aparecem nas Equações 2.24 a 2.27.

O ONFC_{DwD} acrescentou sete novos parâmetros para a inclusão da ação derivativa e também para limitar a taxa de “esquecimento” do controlador. Como a metodologia de ajustes dos parâmetros ainda está em estudo, deve-se avaliar a necessidade da ação derivativa para a escolha entre a utilização do ONFC_{Dw} ou ONFC_{DwD}.

2.4 Conclusões Parciais

Foi realizada a revisão bibliográfica do ONFC. Trata-se de um controlador de baixo custo computacional e poucos parâmetros, que é capaz de adaptar-se as condições de processo. Testes computacionais foram apresentados para verificar o comportamento do controlador. Através de análise matemática, é possível aproximar o comportamento do ONFC a um controlador PI adaptativo.

Um problema que o controlador original apresentou é o aumento dos pesos na presença de erro. Como o sinal do erro em um processo real nunca é nulo, o controlador tende a sempre ajustar os pesos, de forma que a distância entre os mesmos vai aumentando, tornando o controlador instável.

O controlador ONFC_{Dw} apresenta uma solução para o problema de aumento na diferença dos pesos, na qual é introduzida na função custo do método gradiente para ajuste dos pesos uma parcela para minimização da diferença entre os pesos.

O controlador ONFC_{DwD} apresenta mais um neurônio NFN em sua estrutura, com o objetivo de incluir no controlador uma ação derivativa. O controlador ONFC_{DwD} apresenta uma ação antecipatória, referente à ação derivativa introduzida, no entanto o número de parâmetros de ajuste aumentou consideravelmente e a metodologia para ajuste dos parâmetros ainda está sendo desenvolvida, de forma que a análise sobre a necessidade da ação derivativa na aplicação de controle deve sempre ser avaliada.

Neste trabalho, foi utilizado o controlador ONFC_{Dw} para controle de um processo real. No próximo capítulo serão melhor avaliados os parâmetros do controlador ONFC, as metodologias de ajuste encontradas na literatura para cada um deles, bem como apresentadas as novas contribuições para ajuste dos parâmetros e para a ação derivativa do controlador.

Parâmetros do ONFC e Contribuições

Neste capítulo é realizada uma análise dos parâmetros do controlador ONFC: a taxa de aprendizagem (α) e a faixa de excursão do erro (EM). A influência dos parâmetros no controlador e as estratégias de ajuste encontradas na literatura são analisadas. Na discussão do parâmetro α , um maior foco é dado à *Adaptação Dinâmica da Taxa de Aprendizagem*, no qual uma nova proposta é apresentada para ajuste do parâmetro. Para o parâmetro EM , é apresentado o conceito da *Adaptação de Contexto*, que propõe um ajuste dinâmico do parâmetro. É apresentada ainda uma nova abordagem para inclusão da ação derivativa no controlador.

3.1 Taxa de Aprendizagem (α)

Na formulação original do ONFC (Gouvêa, 2005), é definida a taxa de aprendizagem do controlador, parâmetro α , que faz o ajuste do tamanho do passo do método gradiente descendente usado na adaptação dos pesos w_1 e w_2 . Além disso, conforme apresentado nas equações 2.18 e 2.19, o parâmetro α afeta tanto a ação de controle proporcional quanto a ação integral, o que destaca a importância do ajuste desse parâmetro para o bom desempenho do controlador em malha fechada.

A partir de simulações do comportamento de sistemas de primeira ordem para diferentes valores de α , Carvalho (2010) apresenta uma proposta para encontrar um alfa-ótimo. Foi definido um conjunto de sistemas de controle de primeira ordem com diversos valores de constante de tempo, tempo morto e ganhos que foram simulados com vários valores de α . Para avaliar o desempenho do controlador foi definida uma função objetivo que incorpora a integral do quadrado do erro (ITSE), a variância do erro e a variância da saída do controlador. Assim, os vários sistemas de primeira ordem foram simulados, variando o valor de α e medindo o desempenho para cada um deles. Após realizar a simulação de cada processo, era definido como α ótimo aquele que forneceu o melhor valor para a função objetivo. Ao final das simulações, criou-se uma base de dados composta por sistemas de primeira ordem, com seus respectivos valores de constante de tempo, ganho, tempo morto e o valor do melhor α encontrado na simulação. Essa base de dados foi utilizada para treinamento de uma rede neural artificial (RNA) que tem como entrada os parâmetros do processo e como saída o valor de α que deve ser utilizado no ONFC para controlar o processo apresentado à rede.

Assim, para utilização da referida RNA, é necessário conhecer os parâmetros do sistema e é importante também que eles estejam dentro da faixa de valores utilizados nas simulações que geraram a base de dados para a rede. Isso porque o desempenho de uma rede neural está intimamente relacionado à qualidade dos dados a ela apresentados durante o treinamento, sendo que o desempenho de uma RNA pode ser comprometido para dados de entrada fora dos limites

dos valores apresentados durante o treinamento (Haykin, 2007). Além disso, caso não seja conhecido o modelo do sistema a ser controlado ou caso o processo não possa ser representado por um modelo de primeira ordem, a RNA proposta não pode ser utilizada.

Outros trabalhos fazem o ajuste do parâmetro empiricamente, baseado na tentativa e erro. Sabido que o α assume valores entre 0 e 1, inicia-se com valores baixos de α que são acrescidos à medida que seja demandado um controlador com maior ganho.

Uma metodologia denominada *Taxa de Aprendizagem Dinâmica* é proposta em Ferreira (2017) e aplicada em Gomes et al. (2018) e é descrita a seguir.

3.1.1 Taxa de Aprendizagem Dinâmica

Uma estrutura do tipo NFN semelhante a do ONFC, porém aplicada a problemas de identificação de sistema dinâmicos não-lineares, foi apresentada por Caminhas et al. (1996). Nesse trabalho, é formulada uma taxa de aprendizagem da rede que permite que o método gradiente descendente alcance um erro de aproximação nulo em apenas um passo. O resultado foi empregado com sucesso para treinamento em tempo real. Nessa formulação, o α para a iteração k é calculado conforme Equação 3.1.

$$\alpha_k = \frac{1}{(\mu_{1k})^2 + (\mu_{2k})^2} \quad (3.1)$$

Problemas de identificação de sistemas dinâmicos podem ser entendidos como mapeamento de um espaço de entrada para um espaço de saída, de tal forma que o valor da saída da rede NFN é exatamente o valor do parâmetro do processo a ser estimado pela rede, y_k , conceito usado na demonstração da Equação 3.1 (Caminhas et al., 1998). Por mais que o ONFC tenha uma estrutura de rede similar à estrutura utilizada na identificação de sistemas, não é possível obter o mesmo resultado para problemas de controle de processos, porque a saída do controlador, u_k , sofre os efeitos da dinâmica do processo para então ser obtido o valor da variável a ser controlada, y_k .

Em outras palavras, a saída do controlador ONFC é aplicada na planta a ser controlada, que apresenta uma dinâmica, que impede que o processo tenha um erro nulo em apenas uma iteração. Mesmo que o controlador forneça um sinal de controle ótimo, do ponto de vista de minimização do erro, é necessário aguardar a dinâmica da planta para verificar a resposta do processo.

Para contornar a diferença apresentada, Ferreira (2017) utilizou a equação 3.1 no ONFC_{Dw}, substituindo o numerador por um parâmetro α_0 , criando então a *Taxa de Aprendizagem Dinâmica* do ONFC, conforme Equação 3.2. O propósito do α_0 é permitir um ajuste da taxa de aprendizagem de acordo com o processo a ser controlado.

$$\alpha_k = \frac{\alpha_0}{(\mu_{1k})^2 + (\mu_{2k})^2} \quad (3.2)$$

Assumindo a definição da Equação 3.2, em termos práticos, a *Taxa de Aprendizagem Dinâmica* define uma faixa de valores (Equação 3.3) que vão de um valor mínimo que seria equivalente

ao α_0 , quando o módulo do erro for maior do que EM , chegando a um valor máximo de $2\alpha_0$, quando o erro é próximo de zero.

$$(quando |e| \geq EM) \quad \alpha_0 \leq \alpha_k \leq 2\alpha_0 \quad (quando e \approx 0) \quad (3.3)$$

Ou seja, a *Taxa de Aprendizagem Dinâmica* reduz a velocidade de aprendizagem do controlador quando o erro está elevado e quando o erro é pequeno, a velocidade de aprendizagem é aumentada.

Em Ferreira (2017) e em Gomes et al. (2018) o valor de α_0 foi determinado empiricamente. É utilizado o valor de α_0 como metade do valor do α fixo, para que o maior valor para a taxa de aprendizagem seja o valor usado quando o controlador trabalhava com a taxa de aprendizagem fixa. Da mesma forma, o valor da taxa de aprendizagem poderá chegar a metade do valor do alfa fixo quando o erro estiver acima do EM definido para o controlador. Assim como na taxa de aprendizagem fixa, valores muito elevados de α_0 levarão o sistema à instabilidade.

A seguir, é apresentada uma nova proposta para formulação da *Taxa de Aprendizagem Dinâmica* que leva em consideração a dinâmica do processo e elimina o parâmetro α_0 .

3.1.2 Taxa de Aprendizagem Dinâmica baseada no Modelo do Processo

Conforme já apresentado, após uma alteração de *setpoint* em degrau, é impossível que um controlador anule o sinal de erro em apenas uma iteração devido à existência da dinâmica do processo. Quando a *Taxa de Aprendizagem Dinâmica* é formulada, ocorre a inclusão do parâmetro α_0 , em uma tentativa de incorporar a dinâmica do processo no ajuste da taxa de aprendizagem do controlador. No presente trabalho, propõe-se um novo método para ajuste da taxa de aprendizagem baseado no modelo do processo a ser controlado, de forma que o parâmetro α_0 da *Taxa de Adaptação Dinâmica* seja calculado em função dos parâmetros do modelo.

Considera-se um sistema linear, invariante no tempo, representado no espaço de estados conforme Equação 3.4, em que $x(t)$ é o vetor de estados, $u(t)$ é o vetor de entrada e $y(t)$ é o vetor de saída. A, B, C e D são matrizes constantes, uma vez que o sistema considerado é invariante no tempo.

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) \\ y(t) = Cx(t) + Du(t) \end{cases} \quad (3.4)$$

Para simplificar a análise inicial, serão considerados sistemas de primeira ordem. Considerando ainda o sistema discreto, o modelo em espaço de estados apresentado na Equação 3.4 pode ser simplificado conforme Equação 3.5, em que a_1, b_1, c_1 e d_1 são constantes que definem o modelo do sistema a ser representado.

$$\begin{cases} x_{k+1} = a_1x_k + b_1u_k \\ y_k = c_1x_k + d_1u_k \end{cases} \quad (3.5)$$

Considera-se ainda que o valor desejado obedecerá a dinâmica de um modelo de referência, dado por y_d , que define além de um valor final um comportamento desejado para a variável controlada. Define-se então o valor do sinal de erro no instante k , dado pela Equação 3.6.

$$e_k = y_{dk} - y_k \quad (3.6)$$

Seguindo o mesmo procedimento demonstrado em Caminhas et al. (1998) para problemas de identificação, deseja-se obter o valor de α que vai anular o erro em uma iteração, fazendo $e_{k+1} = 0$. Para sistemas de controle, significa calcular qual o α_k que será utilizado para gerar a nova saída u_k , tal que y_{k+1} seja igual ao valor de y_{dk} . Em termos práticos, essa imposição coloca o sistema de controle sempre uma iteração em atraso, de tal forma que o erro somente será nulo quando o modelo de referência estiver em regime permanente, no qual $y_{dk} = y_{dk+1}$. Posto isso, se existe um α que faça $e_{k+1} = 0$, então a Equação 3.7 pode ser escrita:

$$y_{k+1} = y_{dk} \quad (3.7)$$

Usando o modelo de estados discreto (Equação 3.5) e considerando que o sistema é causal ($d_1 = 0$), y_{k+1} pode ser escrito:

$$y_{k+1} = c_1 x_{k+1} = a_1 y_k + c_1 b_1 u_k \quad (3.8)$$

Voltando na Equação 3.7:

$$a_1 y_k + c_1 b_1 u_k = y_{dk} \quad (3.9)$$

Para o ONFC, a saída do controlador u_k é escrita conforme Equação 3.10.

$$u_k = \mu_{1k} w_{1k} + \mu_{2k} w_{2k} \quad (3.10)$$

Pode-se reescrever a Equação 3.9:

$$a_1 y_k + c_1 b_1 (\mu_{1k} w_{1k} + \mu_{2k} w_{2k}) = y_{dk} \quad (3.11)$$

O ajuste dos pesos são realizados conforme Equações 3.12 e 3.13.

$$w_{1k} = w_{1(k-1)} + \alpha_k \mu_{1k} e_k \quad (3.12)$$

$$w_{2k} = w_{2(k-1)} + \alpha_k \mu_{2k} e_k \quad (3.13)$$

Substituindo os valores de w_{1k} e w_{2k} na Equação 3.11:

$$a_1 y_k + c_1 b_1 (\mu_{1k} (w_{1(k-1)} + \alpha_k \mu_{1k} e_k) + \mu_{2k} (w_{2(k-1)} + \alpha_k \mu_{2k} e_k)) = y_{dk} \quad (3.14)$$

Reagrupando os termos:

$$a_1 y_k + c_1 b_1 (\mu_{1k} w_{1(k-1)} + \mu_{2k} w_{2(k-1)}) + c_1 b_1 (\mu_{1k}^2 \alpha_k e_k + \mu_{2k}^2 \alpha_k e_k) = y_{dk} \quad (3.15)$$

$$a_1 y_k + c_1 b_1 (\mu_{1k} w_{1(k-1)} + \mu_{2k} w_{2(k-1)}) + \alpha_k e_k c_1 b_1 (\mu_{1k}^2 + \mu_{2k}^2) = y_{dk} \quad (3.16)$$

Isolando o termo α_k , obtém-se a Equação 3.17 que determina o valor de α_k que anula o erro em uma iteração em relação ao modelo de referência y_d .

$$\alpha_k = \frac{y_{dk} - a_1 y_k - c_1 b_1 (\mu_{1k} w_{1(k-1)} + \mu_{2k} w_{2(k-1)})}{c_1 b_1 e_k (\mu_{1k}^2 + \mu_{2k}^2)} \quad (3.17)$$

Duas condições ainda precisam ser garantidas para a expressão da Equação 3.17:

- O sinal de α_k precisa ser mantido, pois alterar o sinal da taxa de aprendizagem significa transformar um controlador de ação direta em ação reversa, ou vice-versa. O cálculo da expressão permite essa mudança, de forma que a proposta é que, caso ocorra a mudança de sinal, α_k assuma o valor zero.
- se $e_k = 0$, então o $\alpha_k = \alpha_{(k-1)}$. Essa condição impede uma divisão por zero e conserva o valor de α_k quando foi possível anular o erro.

Analisando a expressão da Equação 3.17, pode-se ver uma expressão parecida com a *Taxa de Adaptação Dinâmica*, em que o parâmetro α_0 é dado por:

$$\alpha_0 = \frac{y_{dk} - a_1 y_k - c_1 b_1 (\mu_{1k} w_{1(k-1)} + \mu_{1k} w_{2(k-1)})}{c_1 b_1 e_k} \quad (3.18)$$

O numerador da expressão da Equação 3.18 equivale ao erro no instante k calculado com os pesos do instante $k - 1$. O denominador possui o e_k , calculado com os pesos atualizados. Assim, pode-se interpretar que a expressão 3.18 pondera o sucesso do último ajuste de α_k , pois caso o erro no instante k seja maior que o erro calculado com os pesos do instante anterior, α_0 terá seu valor reduzido. Caso contrário, e_k é menor que o erro calculado com os pesos do instante anterior e, portanto, α_0 terá valor aumentado.

O cálculo de α_k utiliza as constantes a_1 , b_1 e c_1 , provenientes do modelo de estados do sistema de primeira ordem. Dessa forma os parâmetros do modelo são usados no ajuste dos pesos, evidenciando a importância da qualidade do modelo para o bom desempenho do controlador. No presente trabalho, o α_k está sendo calculado de forma ótima para seguir um modelo de referência, considerando apenas sistemas de primeira ordem.

Assim, a metodologia de ajuste da taxa de aprendizagem proposta consegue estimar um α_k ótimo, mas cria a dependência de conhecer o modelo do processo que se deseja controlar. Para os casos em que o modelo é conhecido, a taxa de aprendizagem passa a ser calculada de forma ótima e sem parâmetros de ajuste.

Em seguida, é realizada uma simulação de um controle usando o método proposto para a *Taxa de Aprendizagem Dinâmica* baseada no modelo do processo.

3.1.3 Simulação da Taxa de Aprendizagem Dinâmica baseada no Modelo do Processo

Para essa simulação, é usado um processo de primeira ordem, sem atraso, cuja função de transferência é apresentada na Equação 3.19.

$$G(s) = \frac{3}{2s + 1} \quad (3.19)$$

O mesmo sistema pode ser apresentado por um modelo discreto em espaço de estados, com período de amostragem de $0,1s$.

$$\begin{cases} x_{k+1} = 0,9512x_k + 0,0975u_k \\ y_k = 1,5x_k \end{cases} \quad (3.20)$$

Na Figura 3.1, é apresentada a resposta do sistema para um *setpoint* que possui valor final 2 e constante de tempo igual à do sistema.

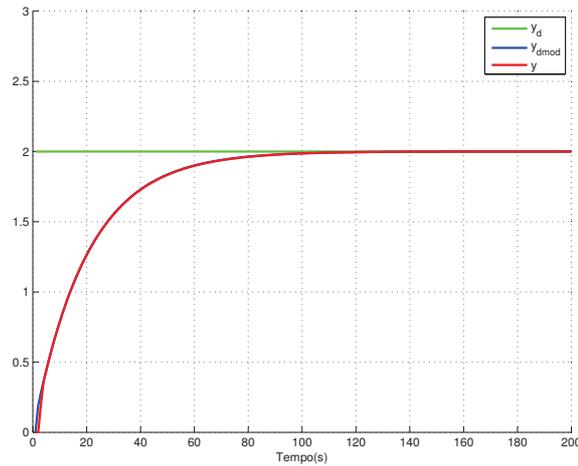


Figura 3.1: Resposta do ONFC com Adaptação Dinâmica baseada no Modelo do Processo.

A linha em verde apresenta o valor final desejado, a linha em azul é o modelo de referência aplicado ao *setpoint* e, em vermelho, é apresentado o valor da variável controlada, y . Observa-se a boa capacidade do sistema em acompanhar o modelo de referência. Percebe-se a presença de pequena diferença entre a linha azul e a linha vermelha, devido ao atraso já esperado de uma iteração. Quando em regime permanente, o erro é anulado e as linhas ficam sobrepostas. Na Figura 3.2, são apresentados os valores de α durante a simulação. Percebe-se que o α começa com valores elevados e também com grandes variações, no momento em que é necessário que os pesos sejam rapidamente ajustados. Em seguida, há um período com valores nulos, que pode ser explicado por cálculo de valores negativos de α que não são permitidos. Em seguida, o cálculo converge para o valor final, que é mantido quando o erro é nulo.

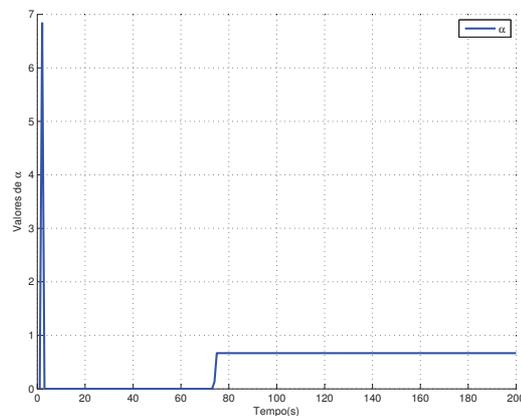


Figura 3.2: Valores de α com Adaptação Dinâmica baseada no Modelo do Processo.

Uma nova simulação para o mesmo processo é apresentada, alterando os valores finais e constante de tempo do modelo de referência para o *setpoint*. Nesta segunda simulação, o valor final é alterado para 2.5 e a constante de tempo é igual 4 segundos, duas vezes mais lenta que a constante de tempo do sistema. Na Figura 3.3, são apresentados os valores de y e y_d . O comportamento é bem similar à primeira simulação, também com boa capacidade do sistema de acompanhar o modelo de referência.

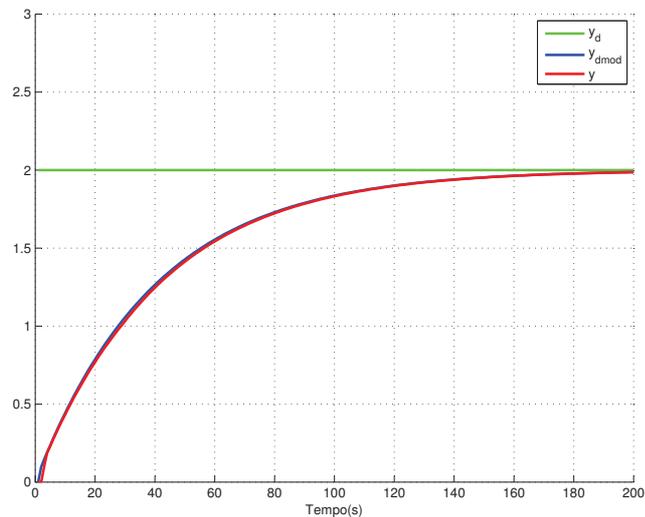


Figura 3.3: Resposta do ONFC com Adaptação Dinâmica baseada no Modelo do Processo.

São apresentados, na Figura 3.4, além dos valores de α em azul, os valores da saída do controlador u , em vermelho. Se comparada com a primeira simulação, o que percebe-se é que o α volta a assumir valores diferentes de zero em um menor intervalo de tempo, indicando quando os pesos voltaram a ser ajustados.

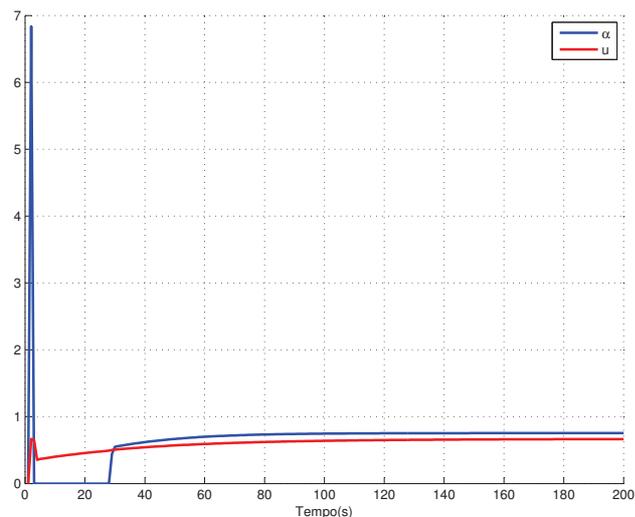


Figura 3.4: Valores de α com Adaptação Dinâmica baseada no Modelo do Processo.

Uma terceira simulação é apresentada na Figura 3.5, com um modelo de referência em rampa. Nesta simulação, é perceptível como y , reta em vermelho, consegue acompanhar o modelo de referência, estando sempre uma iteração em atraso, paralelo ao modelo de referência em azul.

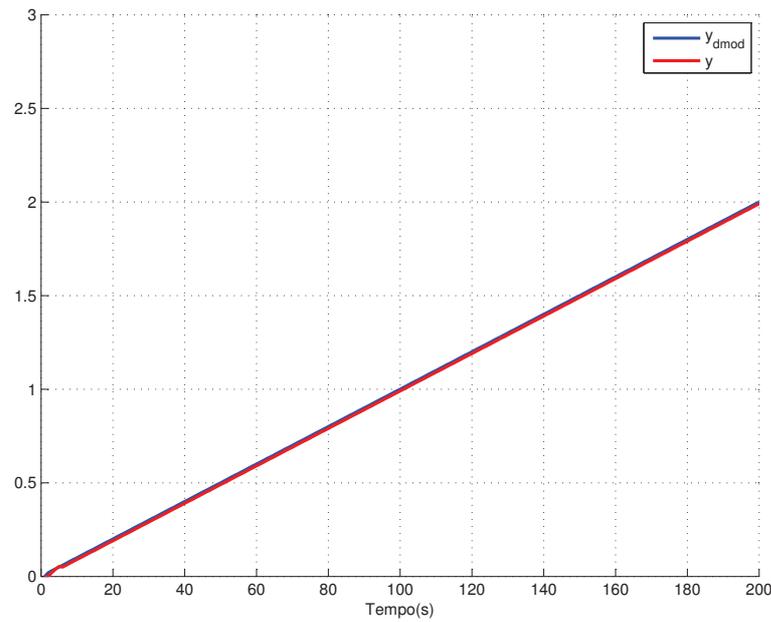


Figura 3.5: Resposta do ONFC com Adaptação Dinâmica baseada no Modelo do Processo.

Os valores de α para a terceira simulação são apresentados na Figura 3.6a. Para esse caso, α assumiu valores mais elevados e estabilizou sem que ficasse um período em zero, o que significa, que os pesos foram ajustados continuamente, de forma mais agressiva no início e, posteriormente, de forma constante, conforme apresentado na Figura 3.6b.

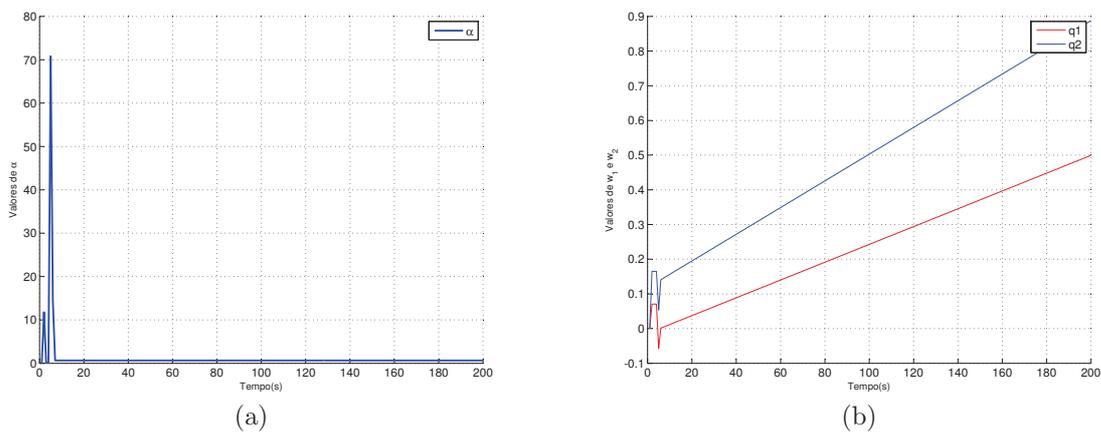


Figura 3.6: Simulação com Modelo de Referência em Rampa: (a) Valores de α (b) Valores dos pesos w_1 e w_2 .

Por fim, é apresentada a simulação para um *setpoint* que obedece um modelo de segunda ordem com atraso. O modelo de referência foi definido com $\omega_n = 1$, $\zeta = 0,25$ e atraso de 1 segundo. Na Figura 3.7 são apresentados os valores de y e y_d .

Também para um sistema de segunda ordem com atraso, é possível ver como o valor ajustado para α consegue garantir o desempenho esperado para a formulação.

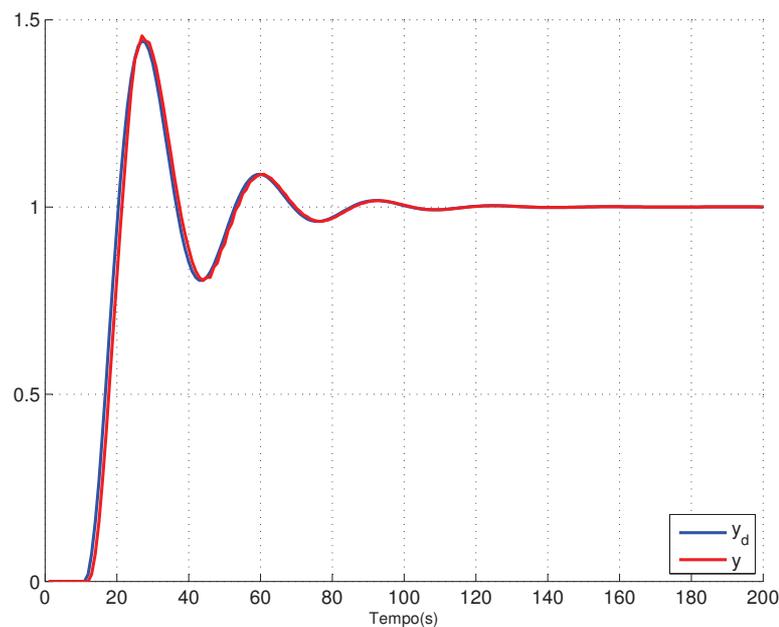


Figura 3.7: Resposta do ONFC com Adaptação Dinâmica baseada no Modelo do Processo.

As simulações apresentadas mostram um bom ajuste do controlador ONFC usando a *Taxa de Adaptação Dinâmica* baseada no modelo do processo. Para essa simulação, não houve parâmetro α para ser ajustado, já que a proposta apresentada possui um cálculo dinâmico e sem parâmetros de ajuste. No entanto, criou-se a dependência dos parâmetros do modelo do sistema a ser controlado para obtenção do valor do α ótimo.

3.2 Faixa de Excursão do Erro (EM)

A faixa de excursão do erro, parâmetro EM , conceituado desde o ONFC original, também pode ser interpretado como o erro máximo do universo de discurso das funções de pertinência. Em Pires (2007), o autor pontua que EM não deve ser definido para toda a faixa de valores possíveis de erro, mas sim uma faixa de valores aceitável para o erro.

Avaliando os trabalhos mais recentes com o ONFC, em Carvalho (2010) é sugerido que o parâmetro EM seja definido em função do desvio padrão da variável erro. Em Oliveira (2017), o EM é igual à faixa de medição da variável controlada. Já Ferreira (2017) define duas formas distintas para ajuste do controlador, no qual quando o controlador tem a função de rejeitar distúrbios, o parâmetro EM é definido como sendo a faixa de valores da variável controlada. Para problemas de servomecanismo, são admitidos valores menores de EM para que, baseado nas equações de equivalência de ganhos do controlador PI, 2.18 e 2.19, o ganho proporcional não fique demasiadamente pequeno.

O comparativo com o controlador PI apresentado por Pires (2007) mostra que o ganho proporcional do controlador é inversamente proporcional ao quadrado do parâmetro EM . Ou seja, valores pequenos de EM podem deixar o sistema instável, enquanto que valores elevados, deixarão o sistema lento. Porém, essa definição só é válida quando o módulo do erro possui valores

menores que EM , pois, para valores maiores, a saída do controlador assumirá os valores w_1 ou w_2 e a comparação com o controlador PI deixa de ser válida.

Para que o desempenho do controlador não dependa tanto do ajuste inicial do parâmetro EM , é proposta uma metodologia de ajuste dinâmico, denominada *Adaptação de Contexto*, que será apresentada a seguir.

3.2.1 Adaptação de Contexto

A proposta da *Adaptação de Contexto* é realizar o ajuste dinâmico do EM , alterando o parâmetro nas situações de início de operação ou mudanças de ponto de operação do controlador. Conforme já apresentado, o ONFC define sua saída baseada no erro, escrito como a diferença entre a variável controlada (y) e o *setpoint* ou valor desejado (y_d). Quando há mudanças no ponto de operação do controlador, ou seja, alterações no valor de y_d , pode ocorrer do módulo do erro ser maior do que EM e, conseqüentemente, o controlador deixar de assumir o comportamento descrito na equação 2.17, tornando a saída do controlador igual a w_1 ou w_2 somente. Para que isso não ocorra, uma solução seria definir um alto valor de EM , tipicamente próximo de todos os valores possíveis para a variável controlada, porém isso exigiria que o controlador tivesse também altos valores de α para que a ação proporcional não ficasse pequena. No entanto, a ação integral não depende de EM , sendo somente proporcional ao α , que quando elevado, poderia resultar em um controlador com K_i também muito elevado, tornando o controlador instável.

Assim, a Adaptação de Contexto é definida como uma mudança no valor de EM quando ocorrem mudanças nos pontos de operação. Em termos práticos, sempre que há mudança no *setpoint*, o EM é então reajustado para o módulo da diferença entre o novo valor desejado, y_d , e o valor corrente da variável controlada, y . É importante definir um valor mínimo para EM , caso contrário, pequenas mudanças de *setpoint* gerariam valores muito pequenos de EM , o que levaria o controlador à instabilidade. O pseudo-código da Adaptação de Contexto é apresentado a seguir.

Algoritmo 1: ADAPTAÇÃO DE CONTEXTO

Entrada: $y, y_d^k, y_d^{k-1}, EM^{k-1}, EM_{min}$

Saída: EM^k

```

1 início
2   if  $y_d^k \neq y_d^{k-1}$  then
3      $e = y_d - y$ ;
4     if  $e \geq EM_{min}$  then
5        $EM^k = e$ ;
6     else
7        $EM^k = EM_{min}$ 
8     end
9   else
10     $EM^k = EM^{k-1}$ ;
11  end
12 fim
13 retorna  $EM^k$ 

```

Dessa forma, o parâmetro do controlador deixa de ser o EM e passa a ser o EM_{min} , que define qual é o menor valor aceitável para o erro, aquele no qual o ganho proporcional do contro-

lador será máximo. Esse parâmetro pode ser obtido empiricamente, uma vez que se o controlador apresentar sinais de instabilidade para determinada faixa, esse parâmetro pode ser aumentado, reduzindo o ganho do controlador. Com a Adaptação de Contexto, o valor de EM passa a ser definido automaticamente, a partir do valor definido para o *setpoint*.

Será apresentada a seguir uma simulação do funcionamento da *Adaptação de Contexto*.

3.2.2 Simulação da Adaptação de Contexto

Para exemplificar o funcionamento da *Adaptação de Contexto*, é apresentada uma simulação em que o controlador $ONFC_{Dw}$ é empregado para controle de um processo cuja dinâmica da resposta pode ser descrita por um sistema de primeira ordem com atraso, conforme Equação 3.21.

$$G(s) = \frac{700e^{-1s}}{3s + 1} \quad (3.21)$$

Nessa simulação, a variável de processo pode assumir valores entre 0 e 700 e a variável manipulada valores entre 0 e 1. O parâmetro α está sendo ajustado com adaptação dinâmica, sendo o α_0 definido como 0,1, valor adotado como padrão inicialmente durante todos os experimentos. É apresentada na Figura 3.8 a resposta da variável de processo quando uma sequência de mudanças de *setpoints* em degrau é aplicada. Na parte inferior da figura, é apresentado o gráfico com a saída do controlador.

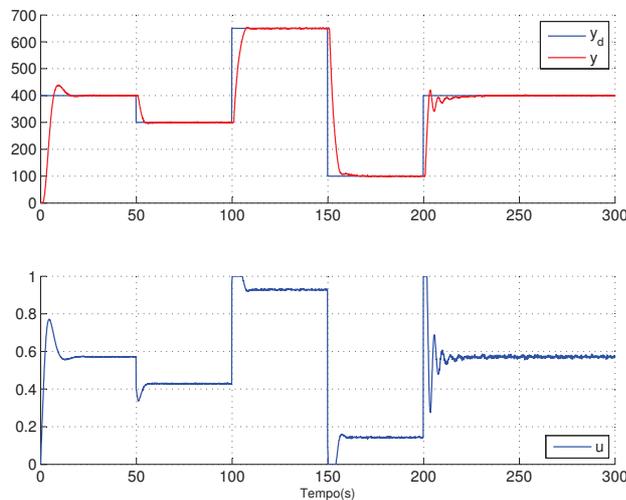


Figura 3.8: Resposta do $ONFC_{Dw}$ com Adaptação de Contexto a uma mudança de *setpoint* em degrau.

O controlador apresentou boa resposta às mudanças de *setpoint* que foram gerados de forma aleatória para que em alguns casos fosse necessária a adaptação para o valor de EM_{min} e em outras fosse realizada de acordo com o erro calculado para o novo *setpoint*. Os valores do parâmetro EM são apresentados na Figura 3.9.

O parâmetro EM_{min} foi definido em 300. Já no início da operação, o primeiro valor de y_d é 400, logo o EM assume esse valor. Em seguida, o valor de y_d é passado para 300, como o erro é

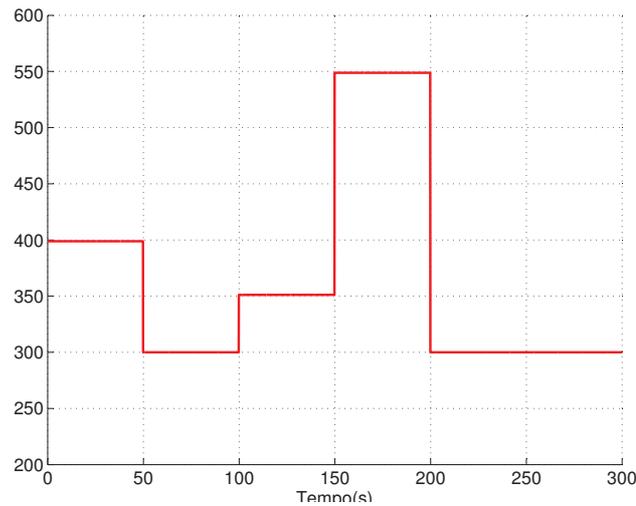


Figura 3.9: Valores de EM gerados pela Adaptação de Contexto.

menor que EM_{min} , o EM assume o valor mínimo. Em seguida são geradas duas mudanças de y_d que exigem novas adaptações de contexto para valores maiores do que EM_{min} , aproximadamente 350 e 550, e por último uma nova adaptação em que o valor do erro é bem próximo do valor de EM_{min} . É possível observar que nessa última adaptação, o controlador já apresenta pequenas oscilações, indicando que valores menores de EM , que resultariam em ganhos maiores ao controlador, poderiam gerar instabilidade no controle.

Assim, foram realizados experimentos do $ONFC_{Dw}$ com e sem *Adaptação de Contexto* em um controle de um processo real, para verificar o funcionamento da metodologia de ajuste do parâmetro EM proposta.

3.3 Ação Derivativa no Controlador ONFC

Conforme já apresentado, o controlador $ONFC_{Dw}$ utilizado possui uma ação de controle equivalente a um controlador PI adaptativo. Se comparado com o controlador PID, largamente utilizado na indústria, o $ONFC_{Dw}$ não apresenta a ação derivativa.

A ação de controle derivativa tem uma vantagem sobre as demais porque trabalha sobre a taxa de variação do erro e não sobre o erro simplesmente, o que pode produzir uma correção antes que o valor do erro se torne elevado (Ogata, 2003). Pode-se dizer que a ação derivativa usa a tendência da variável erro, o que pode aumentar a estabilidade do sistema.

Em Oliveira (2017), é proposta a inclusão de uma ação derivativa ao $ONFC_{Dw}$ por meio do acréscimo de um neurônio NFN à rede. No entanto, o número de parâmetros do controlador aumentou consideravelmente, exigindo mais estudos para a definição da metodologia para ajuste de todos os seus parâmetros.

Quando Pires (2007) descreve o controlador ONFC como um controlador PI, é mencionada uma possibilidade de utilizar a derivada do erro como entrada para o ONFC, ao invés da uti-

lização do erro, para sintetizar a ação de um controlador PID. Partindo disso, é proposta uma alteração no controlador ONFC_{Dw} , substituindo o erro pela derivada do erro, para verificar se de fato a ação derivativa será incluída no controlador, qual será a ação de controle resultante e qual o seu desempenho para controle de um processo real. A fim de facilitar o entendimento, esse novo controlador será referenciado por ONFC_{DwDe} .

Define-se a derivada do erro conforme a Equação 3.22, em que e_k é o erro no instante k , e_{k-1} é o erro no instante $k - 1$ e T é a taxa de amostragem.

$$\frac{de}{dt} \approx \frac{\Delta e}{T} = \frac{e_k - e_{(k-1)}}{T} \quad (3.22)$$

Assim, conforme apresentado na Figura 3.10b, a entrada das funções de pertinência passa a ser a taxa de variação temporal do erro. O parâmetro EM deixa de ser utilizado como uma faixa de excursão do erro e passa a ser a faixa de excursão da derivada do erro, representado por Δ_{EM} . Na Figura 3.10a, é mostrada a estrutura do controlador ONFC_{DwDe} , de forma que é possível verificar que para o ajuste dos pesos ainda é usado o erro, sendo mantida a função custo do processo de otimização de ajustes dos pesos do ONFC_{Dw} , expressa na equação 2.20, que minimiza o erro e a diferença entre os pesos.

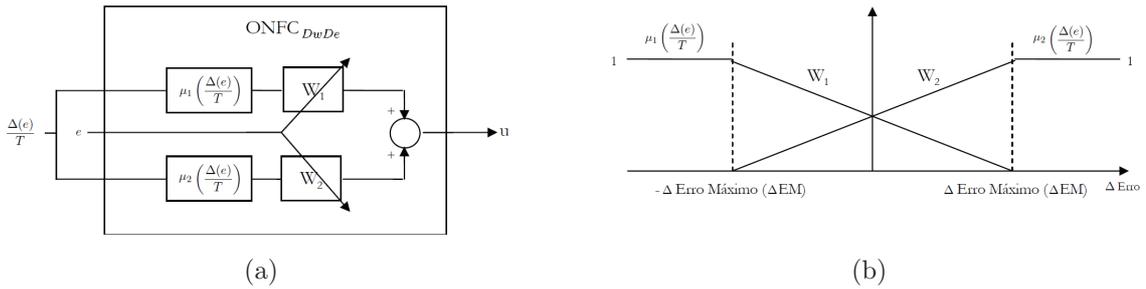


Figura 3.10: Estrutura do ONFC_{DwDe} : (a) Diagrama de Blocos (b) Funções de Pertinência

Definido o controlador ONFC_{DwDe} , é realizada agora a análise matemática do comportamento do controlador com a alteração da entrada da rede NFN do controlador ONFC_{Dw} .

3.3.1 Análise Matemática

Com a alteração das funções de pertinência em função da substituição do erro pela variação temporal do erro, apresentadas na Figura 3.10b, as equações das funções de pertinência 2.2 e 2.3 também são alteradas, definindo as Equações 3.23 e 3.24, para μ_1 e μ_2 , respectivamente:

$$\mu_1(e_k) = \begin{cases} 1, & \text{se } \Delta e_k \leq -\Delta_{EM} \\ \frac{\Delta_{EM} - \Delta e_k}{2\Delta_{EM}}, & \text{se } -\Delta_{EM} < \Delta e_k < \Delta_{EM} \\ 0, & \text{se } \Delta e_k \geq \Delta_{EM} \end{cases} \quad (3.23)$$

$$\mu_2(e_k) = \begin{cases} 0, & \text{se } \Delta e_k \leq -\Delta_{EM} \\ \frac{\Delta_{EM} + \Delta e_k}{2\Delta_{EM}}, & \text{se } -\Delta_{EM} < \Delta e_k < \Delta_{EM} \\ 1, & \text{se } \Delta e_k \geq \Delta_{EM} \end{cases} \quad (3.24)$$

De forma análoga ao ONFC_{Dw} , enquanto $-\Delta_{EM} < \Delta e_k < \Delta_{EM}$ a saída do controlador u_k pode ser escrita como uma soma dos pesos ponderada pelas funções de pertinência, que continuam sendo complementares. Usando as equações 3.23 e 3.24, pode-se reescrever a equação da saída do controlador:

$$u_k = \frac{\Delta_{EM} - \Delta e_k}{2\Delta_{EM}} \cdot w_{1k} + \frac{\Delta_{EM} + \Delta e_k}{2\Delta_{EM}} \cdot w_{2k} \quad (3.25)$$

A equação 3.25 pode ser reescrita da seguinte forma:

$$u_k = \frac{(w_{2k} - w_{1k})}{2\Delta_{EM}} \cdot \Delta e_k + \frac{w_{1k} + w_{2k}}{2} \quad (3.26)$$

Como a função custo foi mantida, as Equações 2.21 e 2.22 que definem o w_{1k} e w_{2k} para o ONFC_{Dw} podem ser utilizadas, desde que respeitadas as seguintes duas simplificações (que já são consideradas também no ONFC_{Dw}):

- Considerar $\frac{\partial y}{\partial u}$ uma constante incluída no parâmetro α ;
- Inicializar os pesos w_1 e w_2 com o mesmo valor para garantir que $(w_{20} - w_{10}) = 0$;

Assim, u_k pode novamente ser reescrita:

$$u_k = \frac{\sum_{i=1}^k \alpha_i e_i (\mu_2 - \mu_1)}{2\Delta_{EM}} \cdot \Delta e_k + \frac{\sum_{i=1}^k \alpha_i e_i (\mu_2 + \mu_1)}{2} \quad (3.27)$$

Como $(\mu_2 - \mu_1) = \frac{\Delta e_k}{\Delta_{EM}}$ e $(\mu_2 + \mu_1) = 1$:

$$u_k = \frac{\sum_{i=1}^k \alpha_i e_i}{2\Delta_{EM}^2} \cdot \Delta e_k^2 + \frac{\sum_{i=1}^k \alpha_i e_i}{2} \quad (3.28)$$

A equação 3.28 utiliza o termo α_i para que a expressão também seja válida quando for utilizada a *Taxa de Aprendizagem Dinâmica*. Caso seja utilizado o α fixo, $\alpha_i = \alpha_0$, sendo constante e podendo simplificar o somatório da expressão.

Ao analisar a saída u_k do controlador ONFC_{DwDe} , é possível observar duas parcelas, uma proporcional ao quadrado da taxa de variação temporal do erro e outra proporcional ao somatório do erro, levando a um controlador que possui ação de controle integral e também ação de controle derivativa. O termo que multiplica a taxa de variação do erro apresenta o termo e_i no somatório, mas não há na expressão da saída do controlador um termo referente à ação proporcional.

A ação derivativa é ponderada por um parâmetro que é proporcional ao parâmetro α e inversamente proporcional ao quadrado do parâmetro Δ_{EM} , tal qual a ação proporcional no controlador ONFC_{Dw} . A ação integral possui a mesma característica da ação integral do controlador ONFC_{Dw} .

Ao contrário do que era esperado em Pires (2007), a ação de um controlador PID não foi sintetizada. A ação proporcional foi substituída pela ação derivativa, o que compromete o desempenho do controlador. A falta da ação proporcional acarreta em lentidão do controlador para

correção do erro entre a variável controlada e o valor desejado. Serão realizados experimentos práticos para evidenciar o comportamento do controlador ONFC_{DwDe} .

3.4 Conclusões Parciais

Foram apresentadas as discussões dos parâmetros taxa de aprendizagem (α) e faixa de excursão do erro (EM) do controlador ONFC_{Dw} . A importância dos parâmetros para o desempenho do controlador foram evidenciadas e apresentadas as metodologias encontradas na literatura para cada parâmetro.

Para o parâmetro α foi dado destaque para a *Taxa de Aprendizagem Dinâmica*, que é utilizada nesse trabalho para consolidação da metodologia aplicando-a em mais um processo real. O controlador ONFC_{Dw} é utilizado para controlar um processo real tanto com taxa de aprendizagem fixa quanto com a taxa de aprendizagem dinâmica para comparação de desempenho.

Uma nova forma de calcular o α para a *Taxa de Aprendizagem Dinâmica* é apresentada, baseando-se na dinâmica do processo a ser controlado. É apresentado o cálculo matemático da expressão de α_k , que com uma iteração em atraso, faz com que o valor da variável controlada seja igual à um modelo de referência com uma iteração em atraso. O valor do α passa a ser dinâmico e dependente do modelo do sistema, sem necessidade de ajuste. Simulações foram realizadas e o resultado esperado foi comprovado para o controlador ONFC usando a *Taxa de Aprendizagem Dinâmica* baseada no modelo do processo. Para simplificar a análise, foi adotado um sistema de primeira ordem, mas o estudo pode ser ampliado para sistemas de ordem maior.

Para o parâmetro EM foi apresentada a *Adaptação de Contexto*, metodologia que propõe uma forma de tornar o ajuste deste parâmetro dinâmico. São realizados experimentos com e sem *Adaptação de Contexto* em um processo real para verificação da aplicabilidade do método.

Foi proposta uma nova abordagem para inclusão da ação derivativa no controlador ONFC , que utiliza a taxa de variação temporal do erro como entrada para o cálculo das funções de pertinência do controlador, definindo o controlador ONFC_{DwDe} . Foi realizada a análise matemática do controlador e verificou-se que, se comparado ao controlador ONFC_{Dw} , a ação integral do controlador foi mantida com as mesmas características e a ação proporcional foi substituída por uma ação com característica derivativa. Se comparados ao controlador PID, o ONFC_{Dw} seria equivalente a um controlador com ações proporcional e integral e o controlador ONFC_{DwDe} seria equivalente a um controlador com ações integral e derivativa. Esse controlador também é aplicado em processos reais para verificar se a ausência da ação proporcional impossibilitaria o uso do controlador e quais os efeitos da ação derivativa inserida com a mudança.

No próximo capítulo será apresentada a metodologia dos experimentos realizados em um processo real para verificar o comportamento dos controladores estudados.

Metodologia

Neste capítulo, é apresentada a metodologia de trabalho aplicada na realização dos experimentos de controle de um processo real. O processo a ser controlado é apresentado, juntamente com a descrição e o propósito de cada um dos experimentos. São definidos os controladores que foram utilizados durante os experimentos e o ajuste dos parâmetros realizado.

4.1 Descrição do Processo

Os experimentos foram realizados em uma planta para práticas de controle de processos do IFMG, campus Ouro Preto, cuja foto é apresentada na Figura 4.1. O processo onde o controlador foi utilizado é composto por dois tanques, no qual é realizado o controle da vazão de água que abastece o tanque superior, vinda do tanque inferior. No tanque inferior, há uma bomba com motor trifásico cuja velocidade é controlada com um inversor de frequência modelo ABB ACS355. A vazão de água que alimenta o tanque superior é medida com um transmissor de vazão eletromagnético, modelo Siemens Sitrans FM Magflo, instalado em um trecho da tubulação posterior à bomba de água. Há também uma válvula pneumática de controle após a bomba, com posicionador modelo Siemens Sipart PS2, que será utilizada em alguns experimentos como perturbação para o controle. A água retorna do tanque superior para o tanque inferior por gravidade.



Figura 4.1: Foto da planta de controle de processos onde foram realizados os experimentos.

A arquitetura dos equipamentos envolvidos nos experimentos é apresentada na Figura 4.2. A planta didática possui um controlador lógico programável, modelo ABB AC700F, que centraliza os dados da instrumentação da planta, sendo que os dados do medidor de vazão, da válvula de controle e do inversor de frequência chegam até o CLP da planta didática por uma rede Profibus existente. Os controladores foram executados em tempo real em um computador com software Matlab® e pacote Simulink®, que faz a comunicação com o CLP por protocolo OPC. Assim, a cada ciclo de execução, realizado a cada 1 segundo, a vazão é lida do CLP, o controlador é executado no computador, que gera novos valores para a válvula e para o inversor de frequência, que são enviados para o CLP.

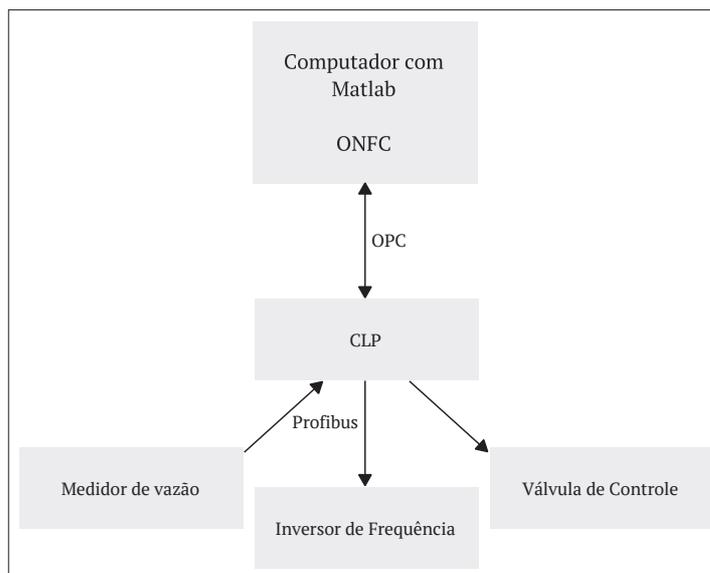


Figura 4.2: Arquitetura dos equipamentos envolvidos no experimento - Fonte: elaborado pelo autor.

4.2 Definição dos Experimentos

Os controladores foram submetidos a dois tipos de experimentos: servomecanismo e rejeição de distúrbios. Nos experimentos de servomecanismo, o objetivo é verificar a capacidade do controlador de se adaptar a novos pontos de operação do processo, fazendo com que a vazão de água alcance o novo valor desejado o mais rápido possível e minimizando o *overshoot* gerado. Foram realizados 3 experimentos de servomecanismo, nos quais eram gerados novos *setpoints* no próprio Matlab® a cada 2 minutos. Os experimentos tiveram duração de 10 minutos, ou seja, o controlador foi testado em 5 pontos de operação, passando por boa parte da faixa de trabalho da variável controlada, sempre realizando a partida da bomba com o *setpoint* mais baixo, seguido de duas elevações consecutivas de *setpoint* e posteriormente duas reduções. Durante os experimentos, a válvula de controle não foi alterada, mas cada experimento trabalhou com uma abertura diferente da válvula, gerando ganhos diferentes no processo. O valor da abertura da válvula para o primeiro experimento é tal que caracterize uma válvula aberta, a segunda caracteriza uma válvula parcialmente aberta e a última é tal que a válvula está bastante restringida. Os valores configurados para cada experimento são apresentados na Tabela 4.1.

Tabela 4.1: Configuração dos experimentos de servomecanismo.

	Abertura da válvula	Primeiro e Quinto <i>setpoint</i>	Segundo e Quarto <i>setpoint</i>	Terceiro <i>setpoint</i>
Experimento 1	90%	400 l/h	550 l/h	700 l/h
Experimento 2	20%	300 l/h	450 l/h	600 l/h
Experimento 3	30%	350 l/h	500 l/h	650 l/h

Os valores de abertura da válvula apresentados na Tabela 4.1 e também na Tabela 4.2 são valores desejados de abertura. O valor é gerado no Matlab® e enviado ao CLP, que por sua vez envia o comando de abertura ou fechamento para a válvula. Trata-se de uma válvula pneumática, que admite pequenos erros de posição em relação ao valor desejado de abertura. Sempre que o erro de posição está acima de um valor limite, o atuador faz a correção na posição da válvula. Dessa forma, durante os experimentos, pode ocorrer de o atuador da válvula perder um pouco da pressão de ar e com isso o erro de posição aumentar, gerando a necessidade de correção no posicionamento. Ainda que essas pequenas correções sejam pouco frequentes e muito rápidas, podem gerar algum distúrbio na variável controlada, que também serão tratadas como distúrbios para os controladores e serão monitoradas por meio do registro da real posição da válvula durante todos os experimentos. Os dados da real posição da válvula podem ajudar a explicar, por exemplo, algum comportamento anormal da variável controlada durante um experimento.

Para os experimentos de rejeição de distúrbios, foi fixada a vazão e foram alterados os valores de abertura da válvula. As configurações dos experimentos são apresentadas na Tabela 4.2. No Experimento 4, a bomba é ligada com um *setpoint* de 400 l/h e a válvula está aberta. Após 2 minutos, a válvula é então restringida, gerando a primeira perturbação para o controlador. Passados mais 2 minutos, há uma nova alteração no posicionamento da válvula, gerando o segundo distúrbio, agora abrindo novamente a válvula. A válvula fica mais 2 minutos nessa posição, quando o experimento é encerrado totalizando um experimento de 6 minutos. O experimento número 5 é análogo, mudando apenas o valor desejado da vazão que é 300 l/h e a válvula começa restringida, é aberta no primeiro distúrbio e no segundo distúrbio é fechada novamente. Nos experimentos 4 e 5, o objetivo é que o controlador, após ligar a bomba e colocar a vazão no valor desejado, seja capaz de rejeitar as perturbações o mais rápido possível, sem deixar que a abertura ou fechamento na válvula provoquem grandes alterações na variável controlada.

Tabela 4.2: Configuração dos experimentos de rejeição de distúrbios.

	<i>Setpoint</i>	Abertura Inicial	Distúrbio 1	Distúrbio 2
Experimento 4	400 l/h	90%	15%	90%
Experimento 5	300 l/h	15%	90%	15%

Um sexto e último experimento é realizado, sendo uma combinação dos experimentos de servomecanismo e rejeição de distúrbios. Neste experimento, o controlador é testado tanto para acompanhar mudanças de *setpoint* quanto para rejeitar perturbações. Além disso, para que os testes com a *Adaptação de Contexto* fossem mais representativos, as mudanças de *setpoint* são realizadas em amplitudes diversificadas, permitindo avaliar o comportamento do controlador para pequenas e grandes mudanças. O sexto experimento possui 8 mudanças e tem duração de 16 minutos. A sequência do sexto experimento é descrita na Tabela 4.3.

Tabela 4.3: Configuração do Experimento 6.

Instante de tempo (min.)	Evento
0:00	Bomba é ligada com válvula em 90% e <i>setpoint</i> em 400 l/h.
2:00	<i>Setpoint</i> alterado para 700 l/h.
4:00	<i>Setpoint</i> alterado para 250 l/h.
6:00	<i>Setpoint</i> alterado para 600 l/h.
8:00	<i>Setpoint</i> alterado para 500 l/h.
10:00	<i>Setpoint</i> alterado para 350 l/h.
12:00	<i>Setpoint</i> da válvula alterada para 20%.
14:00	<i>Setpoint</i> da válvula alterada para 90%
16:00	Término do experimento

Para todos os experimentos é calculada a integral do erro absoluto (IAE) da variável de processo. São gerados os gráficos da variável de processo, *setpoints*, variável manipulada (% da velocidade do motor), abertura da válvula e dos pesos w_1 e w_2 .

4.3 Definição dos Controladores

São listados abaixo os controladores utilizados nos experimentos com os respectivos ajustes de parâmetros. Com exceção do controlador PID, em que já era usado o algoritmo presente no CLP, todos foram implementados no pacote computacional Simulink® do *software* Matlab®. Para todos os controladores ONFC $_{Dw}$, foi utilizado um $\beta = 0,9$, levando em consideração a pior relação sinal/ruído já registrada para o processo a ser controlado.

a) Controlador ONFC $_{Dw}$

Utilizado o controlador proposto em Carvalho (2010), com os parâmetros taxa de aprendizagem e faixa de excursão do erro definidos como $\alpha = 0,1$ e $EM = 250$. O valor de α seguiu o valor de ajuste inicial e o valor de EM foi tal que não provocasse oscilações durante as maiores mudanças de *setpoint*, quando o erro é elevado.

b) Controlador ONFC $_{Dw}$ com α dinâmico.

Utilizado o controlador proposto em Carvalho (2010) com a taxa de aprendizagem dinâmica apresentada em Ferreira (2017). Foi definido que $\alpha_0 = 0,75 \cdot \alpha$, de forma a permitir valores de $1,5 \cdot \alpha$ para os casos de baixo sinal de erro. Para o experimento 6, foram realizados os experimentos com $\alpha_0 = 0,75 \cdot \alpha$ e $\alpha_0 = 0,5 \cdot \alpha$. O parâmetro EM foi mantido em 250. Para esse controlador, serão registrados também os valores de α .

c) Controlador ONFC $_{Dw}$ com α dinâmico e *Adaptação de Contexto*.

A adaptação de Contexto foi utilizada com o controlador com taxa de aprendizagem dinâmica. Para fins de comparação, o controlador obedeceu a mesma parametrização, sendo o $EM_{min} = 250$, ou seja, nos casos de pequenas mudanças de *setpoint*, o valor de EM fica o mesmo do controlador sem *Adaptação de Contexto*. Para esse controlador, serão registrados também os valores de α e de EM .

d) Controlador ONFC $_{DwDe}$

A ação derivativa foi inserida no controlador ONFC $_{Dw}$ com α dinâmico, sem *Adaptação de Contexto*. A *Adaptação de Contexto* não foi utilizada para que a análise do ONFC $_{DwDe}$ pudesse ser realizada sem outras interferências. Os parâmetros foram definidos empiricamente,

sendo: $\alpha_0 = 0,04$, $\Delta_{EM} = 10$. Para esse controlador, serão registrados também os valores de α .

e) Controlador PI usado na planta.

A planta é controlada com um bloco PID interno do CLP do fabricante ABB, modelo AC700F. Foi utilizado um controlador PI com uma sintonia que objetiva a redução do *overshoot* para os casos de mudança de *setpoint*. O modelo usado na sintonia é o modelo da planta quando já está em funcionamento, sendo diferente do modelo durante a partida da bomba. O ajuste do controlador foi mantido e não será ponto de estudo do presente trabalho, sendo usado apenas como referência para comparação dos resultados dos controladores ONFC estudados.

4.4 Conclusões Parciais

Foi apresentado um processo real controlado por um CLP industrial onde os controladores estudados serão aplicados. Trata-se de um controle de vazão de água por meio da variação da velocidade de uma bomba de água que possui inversor de frequência. Há uma válvula de controle que é usada, principalmente, para gerar perturbações durante os experimentos.

Foram propostos um total de seis experimentos, sendo os três primeiros de servomecanismo, dois de rejeição de distúrbios e o último um experimento combinado, com mudanças de *setpoint* com magnitude diversificadas para melhor explorar a *Adaptação de Contexto* proposta.

Um total de cinco controladores são utilizados, sendo: o ONFC_{Dw}, o ONFC_{Dw} com α dinâmico, o ONFC_{Dw} com α dinâmico e *Adaptação de Contexto*, o ONFC_{DwDe} e o controlador PI em uso no processo. Os parâmetros de cada controlador foram definidos, sendo apresentados os resultados no próximo capítulo.

CAPÍTULO 5

Resultados

Neste capítulo, são apresentados os resultados dos experimentos propostos. Inicialmente, uma análise geral é feita, comparando a integral do erro absoluto de todos os experimentos. Posteriormente, é realizada uma análise comparativa evidenciando os efeitos da *Taxa de Aprendizagem Dinâmica*, da *Adaptação de Contexto* e da ação derivativa inserida no ONFC_{DwDe}. Ao longo deste capítulo, serão selecionados alguns experimentos e desses apresentados alguns gráficos. A seleção de qual experimento é utilizado para análise é tal que permite que todos os experimentos sejam utilizados, sem deixar de analisar resultados que apresentam comportamentos diferentes. A coleção de gráficos de todos os resultados dos experimentos realizados neste trabalho está disponível no Apêndice A.

5.1 Análise geral

Para cada experimento realizado, foi calculada a IAE (integral do erro absoluto). Os valores são apresentados na Tabela 5.1, destacando em negrito aquele controlador que teve o melhor resultado naquele experimento (menor valor). São realizadas análises iniciais baseadas apenas nos valores de IAE que posteriormente são avaliadas com os gráficos dos experimentos.

Tabela 5.1: Integral do erro absoluto por experimento por controlador

	ONFC _{Dw} α fixo	ONFC _{Dw} α Dinâmico	ONFC _{Dw} <i>Adaptação</i> <i>Contexto</i>	ONFC _{DwDe}	PI
Experimento 1	28334	25484	25134	39966	27059
Experimento 2	31053	24670	27347	45441	26726
Experimento 3	30580	25228	24373	41341	26885
Experimento 4	14648	11458	14850	20071	16332
Experimento 5	11170	9458	11001	12074	12843
Experimento 6	149500	67523	66004	92602	56446

Analisando os controladores neurofuzzy, ou seja, descartando o controlador PI, há um desempenho significativamente superior dos controladores ONFC_{Dw} com α dinâmico e o ONFC_{Dw} com *Adaptação de Contexto*. Em todos os experimentos, é possível observar uma grande diferença nos valores de IAE para os demais controladores, o que em primeira análise já aponta para um ganho de desempenho do controlador ONFC_{Dw} quando é empregada a *Taxa de Aprendizagem Dinâmica*.

O controlador com *Adaptação de Contexto* foi superior nos experimentos 1 e 3, que são de servomecanismo e também no Experimento 6, que é majoritariamente de servomecanismo. Já o controlador ONFC_{Dw} com α dinâmico obteve melhor desempenho nos experimentos 4 e 5, que

são de rejeição de distúrbios, e também no Experimento 2, que é de servomecanismo. Para os experimentos de rejeição de distúrbios, o controlador com *Adaptação de Contexto* teve desempenho muito próximo ao ONFC_{Dw} com α fixo. Outra análise inicial aponta para um melhor desempenho da *Adaptação de Contexto* nos experimentos de servomecanismo, sendo que o Experimento 2 precisa ser investigado, e a implementação do ajuste dinâmico de EM não trouxe melhora nos resultados nos experimentos de rejeição de distúrbios.

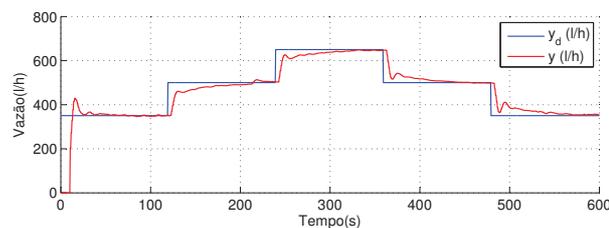
O controlador ONFC_{DwDe} apresentou desempenho significativamente inferior aos controladores ONFC_{Dw} , conforme já esperado. Uma análise mais criteriosa é realizada para verificar o baixo desempenho.

O controlador PI apresentou desempenho sempre similar ao melhor controlador ONFC_{Dw} , validando a utilização dos controladores neurofuzzy para esse processo. No Experimento 6, em que há mais tempo de execução e o controlador é exposto a um desafio maior, o controlador PI foi muito superior. Nos demais experimentos, o baixo desempenho do controlador PI pode ser explicado pelo fato de na partida da bomba a dinâmica ser diferente para o momento em que o controlador é sintonizado, gerando um elevado *overshoot*, que impacta no cálculo do IAE.

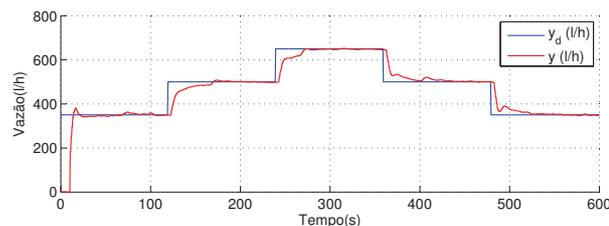
Serão analisados com mais detalhes os resultados para a utilização da *Taxa de Aprendizagem Dinâmica*, da *Adaptação de Contexto* e do controlador ONFC_{DwDe} .

5.2 Análise da *Taxa de Aprendizagem Dinâmica*

Para avaliação da *Taxa de Aprendizagem Dinâmica* são apresentados nas Figuras 5.1a e 5.1b os valores da vazão, y , e do *setpoint*, y_d , em l/h, para o Experimento 3, empregando os controladores ONFC_{Dw} com α fixo e ONFC_{Dw} com *Taxa de Aprendizagem Dinâmica*, respectivamente. O Experimento 3 foi utilizado como exemplo de experimento de servomecanismo, sendo que o mesmo comportamento pode ser observado nos Experimentos 1 e 2.



(a)



(b)

Figura 5.1: Valores de y (em vermelho) e y_d em (azul) em l/h para o Experimento 3: (a) ONFC_{Dw} com α fixo (b) ONFC_{Dw} com *Taxa de Aprendizagem Dinâmica*.

É possível observar que a *Taxa de Aprendizagem Dinâmica* reduziu tanto o *overshoot* quanto o tempo de estabilização da vazão, resultando em um menor IAE para o experimento em questão, sendo esta análise válida também para os Experimentos 1 e 2. Os valores apresentados por α ao longo dos 600s de experimento são apresentados na Figura 5.2.

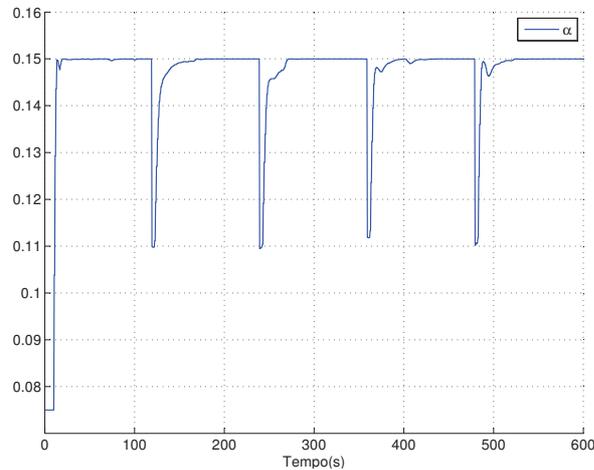


Figura 5.2: Valores de α assumidos ao longo do Experimento 3.

A bomba foi ligada com o menor valor de α possível e foi reduzido também nas vezes que houve mudança de *setpoint*, momentos em que o sinal de erro apresenta valor elevado. Como consequência, um menor *overshoot* é gerado. À medida que o erro é reduzido, o valor de α vai aumentando, até que é admitido um α maior que o α_0 da abordagem fixa, acelerando a estabilização da variável. O α só assumiu valores mais elevados quando já havia passado o regime transitório, de forma que não foram gerados sinais de instabilidade na vazão em função de ganhos elevados no controlador.

Para analisar o comportamento da *Taxa de Aprendizagem Dinâmica* em problemas de rejeição de distúrbios, são apresentados os resultados do Experimento 4. São apresentadas nas Figuras 5.3 e 5.4 os valores da vazão, y , em l/h para os controladores ONFC_{Dw} com α fixo e ONFC_{Dw} com *Taxa de Aprendizagem Dinâmica*, respectivamente, para os distúrbios gerados pela abertura e fechamento da válvula. A linha em azul está fixa em 400 l/h, que é o *setpoint* definido para o Experimento 4.

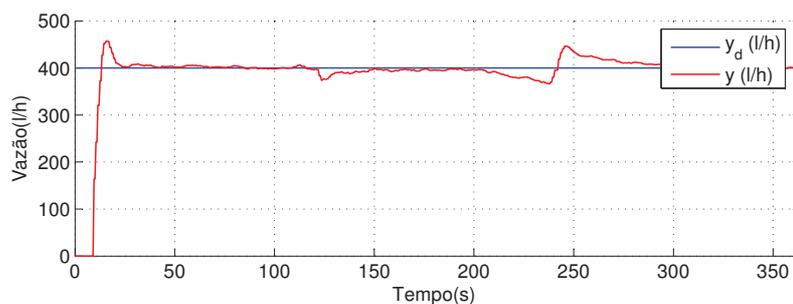


Figura 5.3: Valores de y em l/h para Experimento 4 - ONFC_{Dw} com α fixo

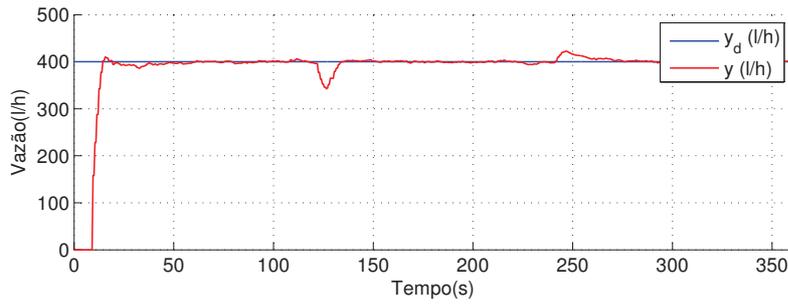


Figura 5.4: Valores de y em l/h para Experimento 4 - ONFC $_{Dw}$ com α Dinâmico

A abertura real da válvula de controle durante o Experimento 4 é apresentada nas Figuras 5.5a e 5.5b para os controladores ONFC $_{Dw}$ com α fixo e ONFC $_{Dw}$ com *Taxa de Aprendizagem Dinâmica*, respectivamente. Conforme já previsto no planejamento do experimento, é possível ver pequenas correções de posicionamento da válvula, como por exemplo próximo ao instante $t=100s$. Ao acaso, a correção ocorreu de forma similar para os dois controladores e em instantes de tempo próximos, de forma que não foi gerada nenhuma discrepância que merecesse ser levada em conta na análise dos resultados. É possível ver também que, ao realizar abertura ou fechamento, ocorreram pequenos *overshoots* na posição da válvula, que também estão sendo desprezados na análise devido ao curto intervalo de tempo da ocorrência.

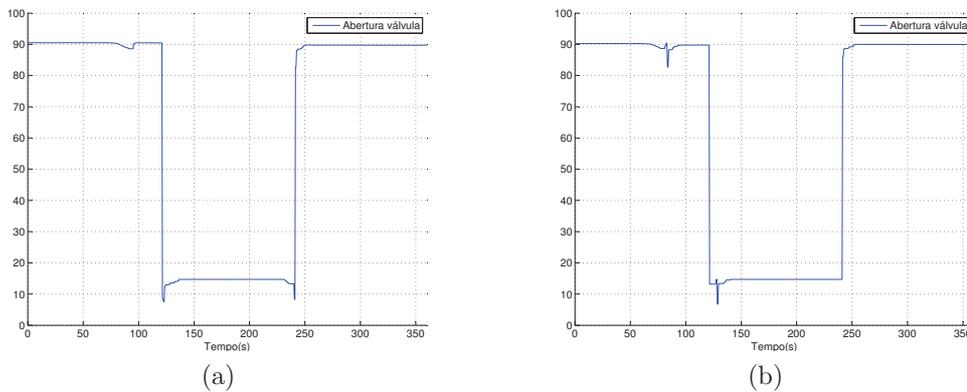


Figura 5.5: Posição real da válvula durante o Experimento 4: (a) ONFC $_{Dw}$ com α fixo (b) ONFC $_{Dw}$ com *Taxa de Aprendizagem Dinâmica*.

Para os experimentos realizados com rejeição de distúrbio, percebe-se pouca diferença de desempenho ao utilizar a *Taxa de Aprendizagem Dinâmica*. A diferença encontrada no IAE dos controladores deve-se, em grande parte, ao período que vai do início da operação da bomba até que a vazão estabilize no *setpoint* definido para o experimento. Quando ocorrem os distúrbios, a diferença de desempenho é pequena e pode ser evidenciada pelos valores de α apresentados durante o experimento que são exibidos na Figura 5.6.

Observa-se que o parâmetro só sofreu grandes alterações durante o início do teste, quando a vazão ainda não havia estabilizado. Durante o distúrbio, o erro introduzido foi pequeno, o que não gerou grandes movimentações de α para promover ganho de desempenho. Contudo, é possível ver também que nenhuma perda de desempenho pela utilização da *Taxa de Aprendizagem Dinâmica* foi trazida, uma vez que ocorreu a rejeição dos distúrbios sem a presença de oscilação ou instabilidade.

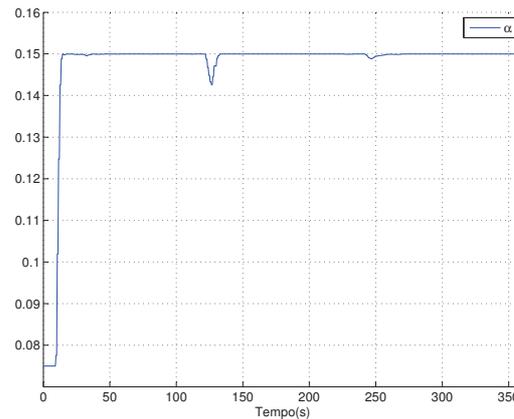
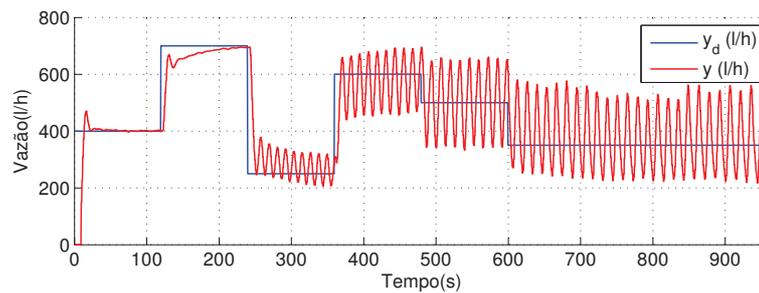
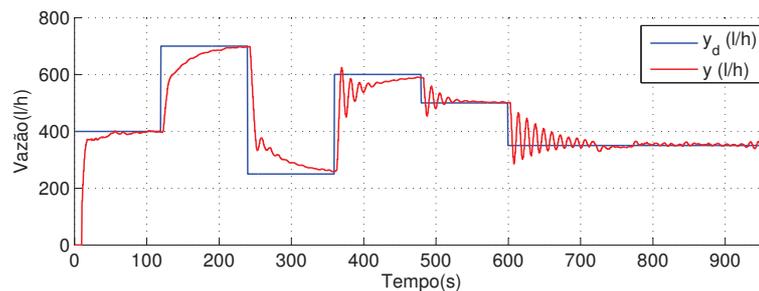


Figura 5.6: Valores de α assumidos ao longo do Experimento 4.

Agora, é feita a análise do Experimento 6, que apresentou maior duração. Esse experimento tem como característica principal uma maior excursão os valores de y_d . Assim, como foi feito no Experimento 3, são apresentados na Figura 5.7a e 5.7b os valores de y e y_d para os controladores ONFC $_{Dw}$ com α fixo e ONFC $_{Dw}$ com *Taxa de Aprendizagem Dinâmica*.



(a)



(b)

Figura 5.7: Valores de y (em vermelho) e y_d em (azul) em l/h para o Experimento 6: (a) ONFC $_{Dw}$ com α fixo (b) ONFC $_{Dw}$ com *Taxa de Aprendizagem Dinâmica*.

Observa-se que o controlador ONFC $_{Dw}$ com $\alpha = 0,1$ não foi capaz de garantir a estabilidade do sistema quando foi realizada uma sequência de mudanças de *setpoint* de maior amplitude. O ONFC $_{Dw}$ com *Taxa de Aprendizagem Dinâmica*, sendo $\alpha_0 = 0,05$, estabilizou o sistema, ainda que com oscilações no final. Os valores da taxa de aprendizagem para esse experimento são apresentados na Figura 5.8. Como nesse caso as mudanças de *setpoint* levaram a valores de erro maiores do que EM , o α_k assumiu o valor de α_0 todas as vezes que isso aconteceu.

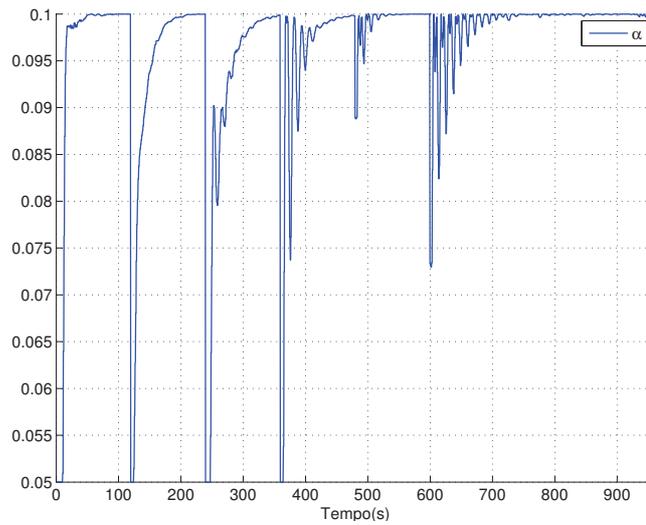


Figura 5.8: Valores de α assumidos ao longo do Experimento 6.

No caso do α fixo, o que ocorreu foi um aumento da magnitude dos pesos, proporcionando um α elevado para erros maiores que EM . Já para a adaptação de contexto, a flexibilidade da taxa de aprendizagem permitiu que os pesos se adaptassem menos durante as mudanças de *setpoint*. Na Figura 5.9a, os pesos do controlador com α fixo divergiram, enquanto na Figura 5.9b a diferença está estável, porém de magnitude elevada devido aos testes submetidos de constantes mudanças de *setpoint* em valores elevados, mas como a *Taxa de Aprendizagem Dinâmica* reduz o valor de α para valores elevados de erro, não ocorreu a divergência dos pesos.

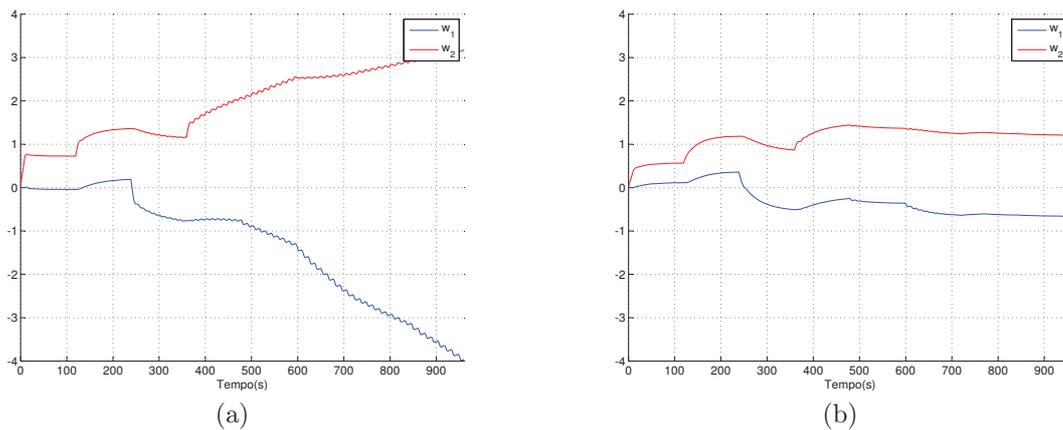


Figura 5.9: Valores dos pesos w_1 (em azul) e w_2 (em vermelho) ao longo do Experimento 6: (a) ONFC_{Dw} com α fixo (b) ONFC_{Dw} com *Taxa de Aprendizagem Dinâmica*.

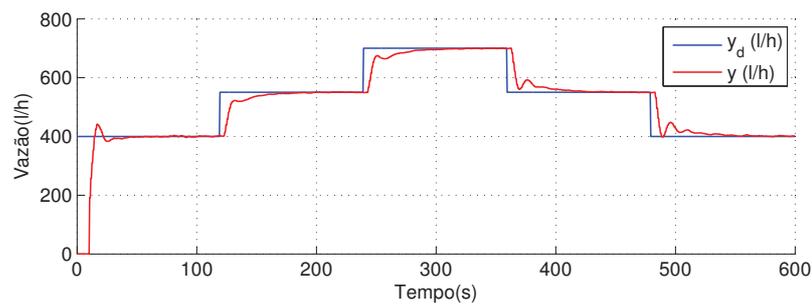
Assim, a análise detalhada dos gráficos dos experimentos corrobora com o resultado apresentado pela IAE dos experimentos, que evidenciam o ganho de desempenho do controlador ONFC_{Dw} com *Taxa de Aprendizagem Dinâmica*. Nos experimentos realizados, a redução do valor de α quando o erro é elevado contribuiu para a redução de *overshoot* e para tornar o controlador mais estável.

5.3 Análise da *Adaptação de Contexto*

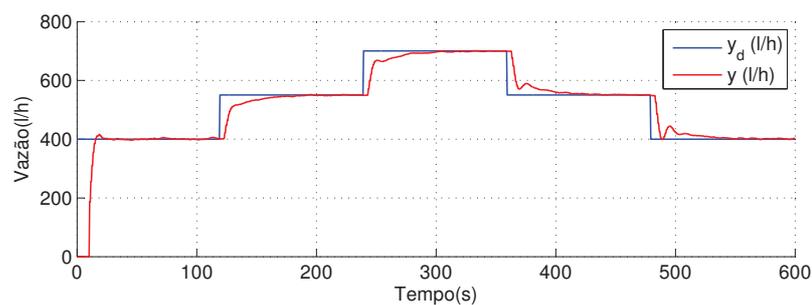
Como o controlador em que foi empregada a *Adaptação de Contexto* utiliza a *Taxa de Aprendizagem Dinâmica*, para analisar a eficiência da técnica, é feita a comparação entre o ONFC_{Dw} com *Taxa de Aprendizagem Dinâmica* e ONFC_{Dw} com *Adaptação de Contexto*, pois a única diferença entre os dois controladores é a forma como o parâmetro *EM* é ajustado.

Primeiramente, analisando os experimentos de servomecanismo, o controlador com *Adaptação de Contexto* teve desempenho superior no Experimento 1 e Experimento 3 e inferior no Experimento 2. Como o Experimento 3 já foi utilizado na análise da secção anterior, é utilizado o Experimento 1 e posteriormente o motivo do desempenho inferior no Experimento 2 é verificado. O desempenho nos experimentos 1 e 3 é muito semelhante.

Nas Figuras 5.10a e 5.10b são apresentados os gráficos da vazão, y , e do *setpoint*, y_d , para os controladores sem e com *Adaptação de Contexto*, respectivamente, para o Experimento 1.



(a)



(b)

Figura 5.10: Valores de y (em vermelho) e y_d em (azul) em l/h para o Experimento 1: (a) ONFC_{Dw} sem *Adaptação de Contexto* (b) ONFC_{Dw} com *Adaptação de Contexto*.

Observa-se que o *overshoot* gerado na partida da bomba é menor, uma vez que o *EM* na partida é ajustado para um valor maior do que o EM_{min} . Para as outras mudanças de *setpoint* a diferença de comportamento do controlador é mínima, uma vez que o *EM* dos dois controladores é igual, conforme apresentado na Figura 5.11.

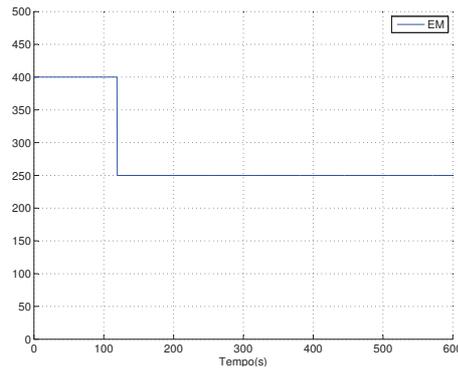


Figura 5.11: Valores de EM assumidos ao longo do Experimento 1.

Analisando ainda as respostas das Figuras 5.10a e 5.10b, mesmo depois que $EM = EM_{min}$, há ligeira diferença entre o comportamento dos controladores. O que explica essa diferença é o ajuste realizado nos pesos durante a fase em que a *Adaptação de Contexto* foi realizada, que carrega também uma mínima diferença para os pesos, como mostrado nas Figuras 5.12a e 5.12b, nas quais é feito um comparativo dos pesos sem e com *Adaptação de Contexto*.

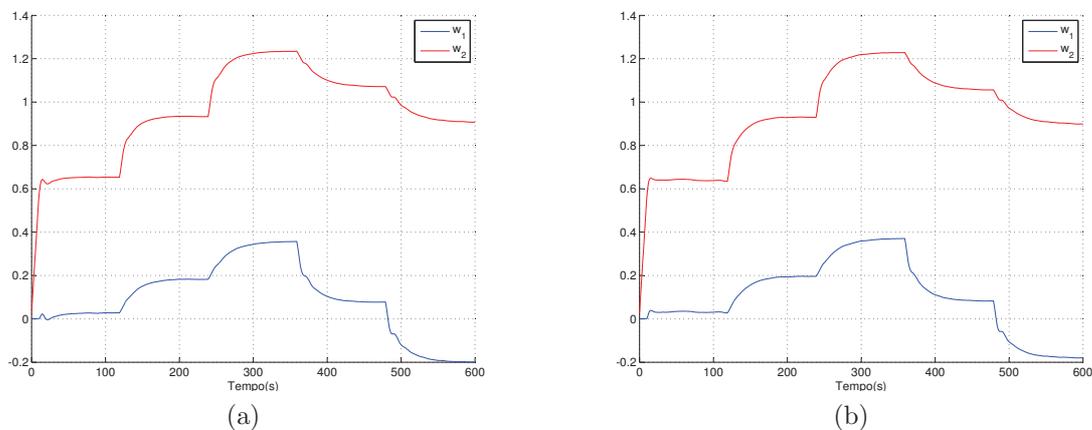


Figura 5.12: Valores dos pesos w_1 (em azul) e w_2 (em vermelho) ao longo do Experimento 1: (a) sem *Adaptação de Contexto* (b) com *Adaptação de Contexto*.

Assim, verifica-se o comportamento semelhante entre os controladores, mas o desempenho do controlador com *Adaptação de Contexto* é superior devido ao menor *overshoot* na partida da bomba. Comportamento similar ocorre no Experimento 3 e uma análise é realizada sobre o Experimento 2, no qual o IAE do controlador com *Adaptação de Contexto* não obteve o melhor resultado entre os experimentos de servomecanismos.

Nas Figuras 5.13 e 5.14 são realizadas as comparações dos controladores sem e com *Adaptação de Contexto*, respectivamente, para o Experimento 2. É percebido um comportamento anormal da vazão com o controlador que utiliza a *Adaptação de Contexto* após $t=300s$. Há uma mudança abrupta na vazão de forma inesperada.

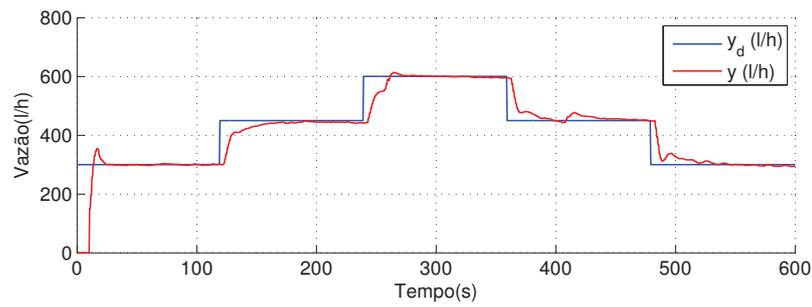


Figura 5.13: Valores de y (em vermelho) e y_d em (azul) em l/h para o Experimento 2: ONFC_{Dw} sem *Adaptação de Contexto*

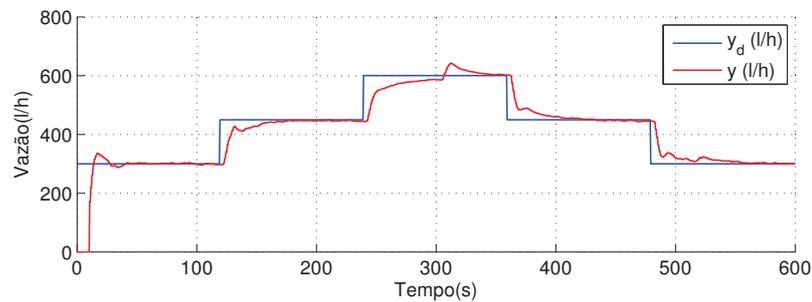


Figura 5.14: Valores de y (em vermelho) e y_d em (azul) em l/h para o Experimento 2: ONFC_{Dw} com *Adaptação de Contexto*

Ao analisar a vazão, juntamente com a saída do controlador com *Adaptação de Contexto* (Figura 5.15a), observa-se que, instantes antes ao $t=300s$, o controlador eleva a saída para zerar o erro em regime permanente, aumentando a rotação da bomba, mas não há resposta na vazão. Na Figura 5.15b, é apresentada uma variação na válvula próxima ao instante $t=300s$, que resultou em uma acréscimo da vazão. Essa é uma situação em que possivelmente a válvula gerou um distúrbio que impactou no resultado comparativo entre os dois controladores.

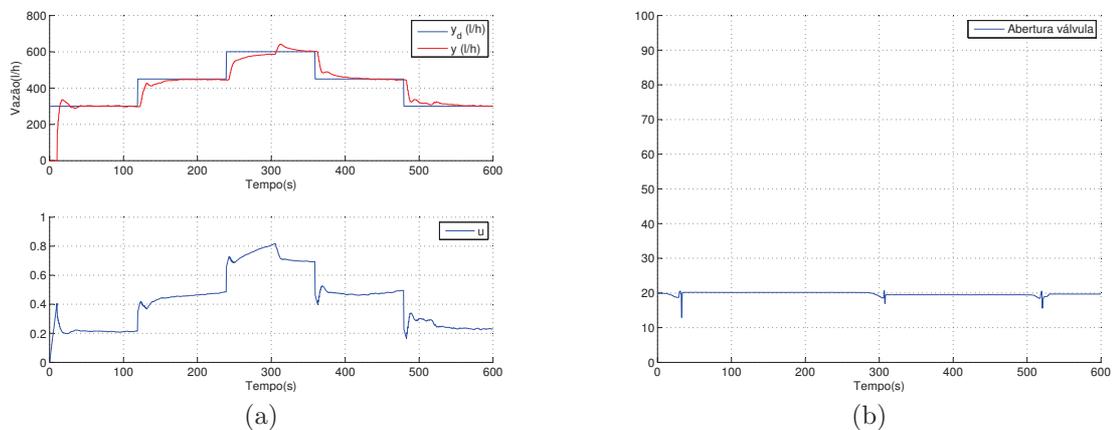
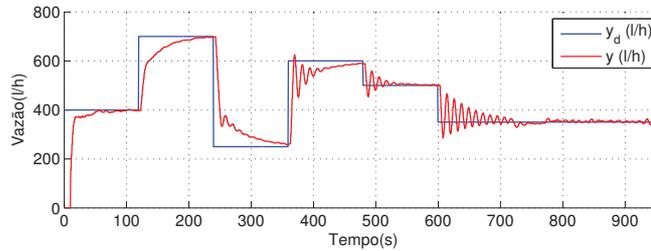
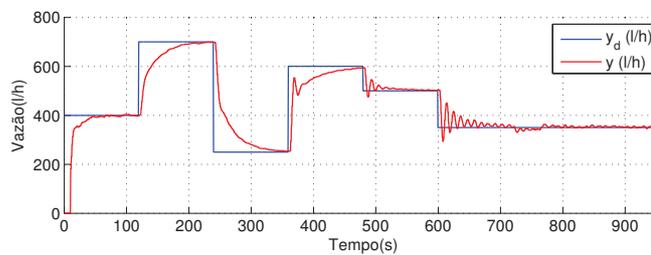


Figura 5.15: Controlador com *Adaptação de Contexto* para o Experimento 2. (a) Na parte superior, vazão e *setpoint* (l/h) e na parte inferior, a saída do controlador (b) Abertura da válvula.

Para concluir a análise da *Adaptação de Contexto* em problemas de servomecanismo, a análise do Experimento 6 é realizada. São apresentados na Figura 5.16a e 5.16b os valores de y e y_d para os controladores ONFC_{Dw} sem e com *Adaptação de Contexto*. No sexto experimento, em que a variação dos *setpoints* é de maior amplitude, o ajuste dinâmico de EM acontece com maior frequência e reduz a oscilação da variável controlada.



(a)



(b)

Figura 5.16: Valores de y (em vermelho) e y_d em (azul) em l/h para Experimento 6: (a) ONFC_{Dw} sem *Adaptação de Contexto* (b) ONFC_{Dw} com *Adaptação de Contexto*.

A variação dos valores de EM durante o Experimento 6 é apresentada na Figura 5.17. Como as mudanças de *setpoint* com diferenças maiores do que EM_{min} acontecem com uma frequência elevada, a faixa de excursão do erro vai sendo adaptada à condição da mudança de ponto de operação do processo, evitando ganhos muito elevados. Como consequência, há a redução na oscilação da variável controlada. Na parte final do experimento, ocorrem variações menores de *setpoint* e geração de distúrbios, quando $EM = EM_{min}$ e são percebidas algumas oscilações na vazão.

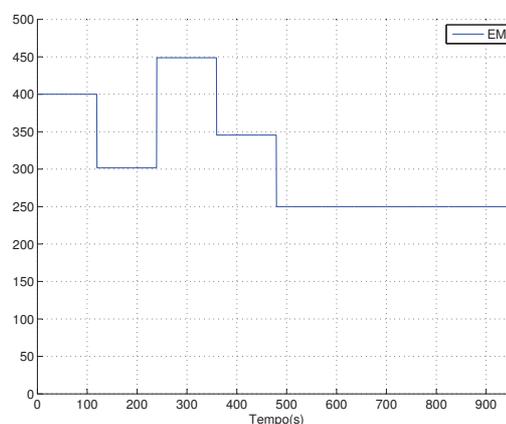


Figura 5.17: Valores de EM assumidos ao longo do Experimento 6.

Para os experimentos que apresentam somente o problema de rejeição de distúrbios, a *Adaptação de Contexto* mostrou-se ineficiente. O Experimento 5 é usado para exemplificar o comportamento, que também pode ser observado no Experimento 4. Como não há variação de *setpoint*, o EM assume o valor durante a partida da bomba. Esse valor fica fixo ao longo de todo o experimento e é maior do que EM_{min} , usado pelo controlador sem *Adaptação de Contexto*. Quando é aplicado o distúrbio, o ganho do controlador fica pequeno, devido ao elevado valor de EM , que foi ajustado somente na partida da bomba. Uma possibilidade de trabalho futuro é realizar a redução de EM , quando o controlador já está em regime permanente, para o valor de EM_{min} , por exemplo. Isso elevaria o ganho e aceleraria a adaptação do controlador no novo ponto de operação, sem prejudicar uma nova mudança no ponto de operação.

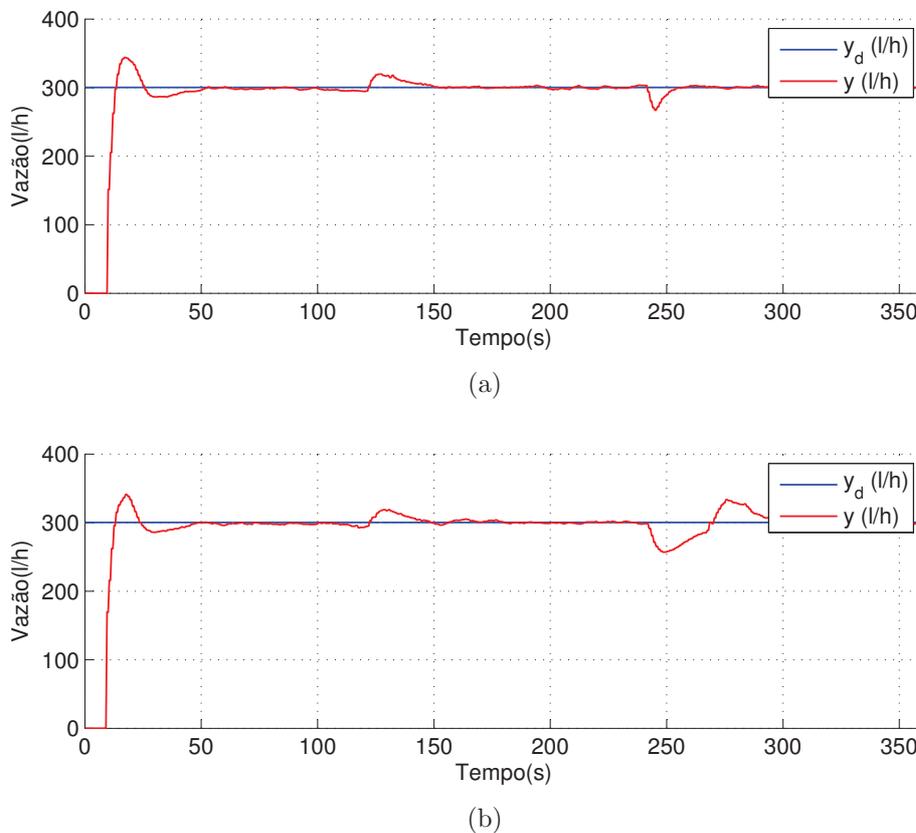


Figura 5.18: Valores de y em l/h para Experimento 5: (a) $ONFC_{Dw}$ sem *Adaptação de Contexto* (b) $ONFC_{Dw}$ com *Adaptação de Contexto*.

Assim, o controlador $ONFC_{Dw}$ com *Adaptação de Contexto* obteve o melhor desempenho nos experimentos que envolviam mudança no ponto de operação, evidenciados pelos menores valores de IAE, salvo o Experimento 2, que foi devidamente justificado. Para os experimentos de rejeição de distúrbios, o controlador apresentou bom desempenho, mas inferior ao desempenho do controlador $ONFC_{Dw}$ com *Taxa de Aprendizagem Dinâmica*, sendo apresentada uma justificativa para o desempenho inferior do controlador $ONFC_{Dw}$ com *Adaptação de Contexto* e uma possibilidade de melhoria no controlador para ter melhor desempenho nas condições apresentadas pelos experimentos 4 e 5.

5.4 Análise do $ONFC_{DwDe}$

Para análise do controlador $ONFC_{DwDe}$ é utilizado o Experimento 6. São apresentadas as respostas do controlador na Figura 5.19. O comportamento apresentado no Experimento 6 é similar em todos os outros experimentos para o controlador $ONFC_{DwDe}$.

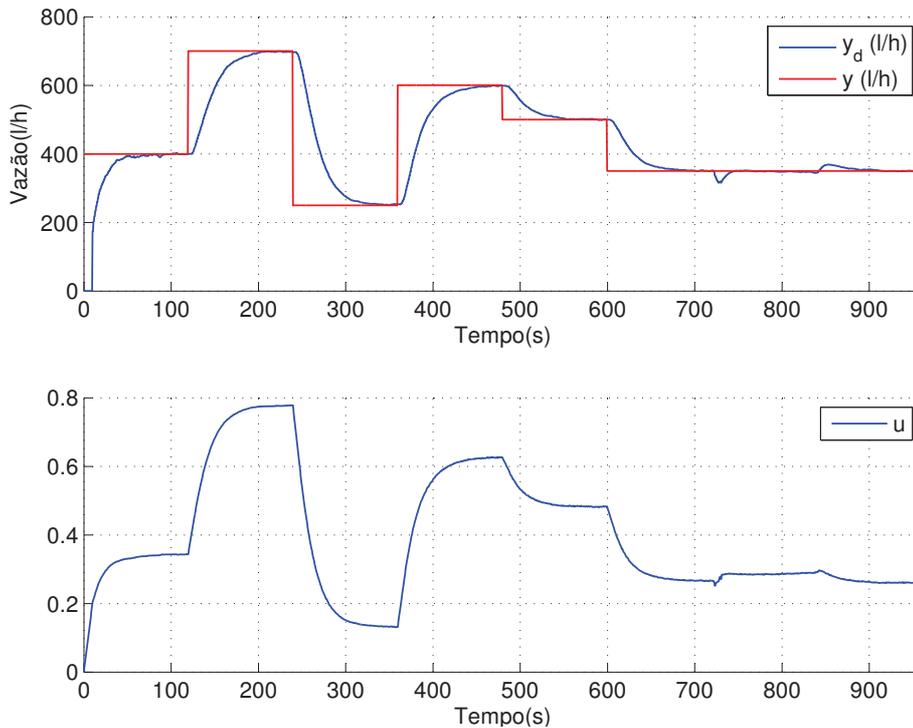


Figura 5.19: Na parte superior, vazão (azul) e *setpoint* (vermelho) em l/h e na parte inferior, a saída do controlador $ONFC_{DwDe}$.

Como é possível analisar, o controlador consegue alcançar o *setpoint* estabelecido e zera o erro em regime permanente de forma estável. Além disso, o controlador é capaz de rejeitar os distúrbios estabelecidos. O elevado valor de IAE, se comparado com os outros controladores $ONFC$ utilizados, deve-se ao comportamento da saída do controlador. Como pode ser observado na parte inferior da Figura 5.19, a saída não apresenta a ação proporcional ao erro, conforme formulação matemática no Capítulo 3, e o comportamento da saída é apenas de uma ação integral, que vai corrigindo o erro de forma lenta ao longo do tempo. A presença da ação derivativa, antecipatória ao erro, não foi perceptível em nenhum dos experimentos realizados. No entanto, há parâmetros que intensificam essa ação, que são o Δ_{EM} e a taxa de amostragem. Neste trabalho, os parâmetros desse controlador foram pouco explorados e podem intensificar a ação derivativa, levando a uma resposta mais rápida do controlador.

A ausência da ação proporcional teve fator determinante para os altos valores de IAE, pois o controlador tem somente a ação integral para corrigir o erro quando há mudança de *setpoint* e também quando há algum distúrbio. Ainda assim, o controlador mostrou-se estável, sem erro em regime permanente e capaz de rejeitar distúrbios de forma mais lenta.

5.5 Conclusões Parciais

Os resultados dos experimentos foram apresentados e analisados. O controlador $ONFC_{Dw}$ com *Taxa de Aprendizagem Dinâmica* apresentou os melhores resultados para os experimentos de rejeição de distúrbios e o controlador $ONFC_{Dw}$ com *Adaptação de Contexto* apresentou os melhores resultados para experimentos de servomecanismo.

A *Taxa de Aprendizagem Dinâmica* teve o seu desempenho comparado ao controlador com α fixo, mostrando que a *Taxa de Aprendizagem Dinâmica* traz contribuições para melhoria do desempenho do controlador, reduzindo *overshoot* e acelerando a estabilização da variável controlada.

A *Adaptação de Contexto* mostrou-se muito eficiente quando há mudanças de *setpoint* mais elevadas, reduzindo *overshoot* e tornando o controlador mais estável. Percebeu-se que o controlador pode apresentar lentidão para rejeitar distúrbios, em situações que houver um ajuste do EM para um valor elevado e em seguida forem aplicados distúrbios, quando o controlador apresenta um ganho reduzido.

O controlador $ONFC_{DwDe}$ foi utilizado nos experimentos, apresentou capacidade de controle, mas não foi possível visualizar em nenhum dos experimentos os efeitos da ação derivativa. A ausência da ação proporcional, formulada na análise matemática, foi percebida, mas o controlador apresentou uma saída característica de um controlador de ação integral, sem ação derivativa.

Considerações Finais

Neste capítulo, são apresentadas as considerações finais do trabalho, que incluem as conclusões e propostas de trabalhos futuros.

6.1 Conclusões

Neste trabalho foi realizado um estudo do *OnLine Neurofuzzy Controller*. Trata-se de um controlador de simples implementação, baixo custo computacional, com aprendizado online e poucos parâmetros de ajuste. O ONFC utiliza o sinal de erro para gerar o valor da saída do controlador e também para fazer os ajustes dos pesos utilizados no cálculo da saída, tornando-o adaptativo. O ONFC sintetiza a ação de um controlador PI adaptativo.

A pesquisa bibliográfica mostrou que, desde a sua formulação, vários estudos foram realizados com o controlador, analisando matematicamente o comportamento da saída, buscando solução para divergência dos pesos na presença de ruído de medição, analisando o efeito dos parâmetros, propondo metodologias de ajuste dos parâmetros, buscando desenvolver a tecnologia do controlador e aplicá-lo em processos reais. Assim, o presente trabalho buscou entender e simular cada versão do ONFC publicada, focando em verificar qual o problema identificado e qual a solução proposta, analisando também os resultados obtidos em cada implementação. Dessa forma, um resultado do presente trabalho é elaboração de um texto didático que contempla o estudo do controlador ONFC em suas várias versões.

Dentre os controladores estudados, foi utilizado o controlador $ONFC_{Dw}$, que incluiu na função custo do processo de otimização do ajuste dos pesos uma parcela referente a minimização da distância entre pesos, contornando o problema de aumento da distância dos pesos na presença de ruído.

Para o controlador $ONFC_{Dw}$ foi realizado o estudo dos parâmetros α , que é a Taxa de Aprendizagem do controlador, e EM , que é a Faixa de Excursão do Erro. As metodologias encontradas na literatura para ajuste dos dois parâmetros foram estudadas e para o parâmetro α foi dado um foco na *Taxa de Aprendizagem Dinâmica*, que é uma formulação recente e que tem apresentado bons resultados para o ajuste dinâmico desse parâmetro.

Foi apresentada uma nova forma para o cálculo da Taxa de Aprendizagem, baseada no modelo do processo a ser controlado. Esse cálculo fornece o valor de α capaz de anular a diferença entre a variável controlada e um modelo de referência com uma iteração. O cálculo foi demonstrado para sistemas de primeira ordem e simulações foram realizadas para comprovar a capacidade do sistema de acompanhar um modelo de referência sem que seja necessário um ajuste manual da Taxa de Aprendizagem. Acredita-se que tal metodologia seja válida para sistemas de ordem

maior, sendo proposto como trabalho futuro a aplicação da metodologia para um sistema de ordem n .

Para o parâmetro EM foi proposta a *Adaptação de Contexto*, uma metodologia para ajuste dinâmico da faixa de excursão do erro do controlador sempre que há mudança no ponto de operação.

Foi proposta ainda a formulação de uma nova versão para o controlador, o $ONFC_{DwDe}$, que inclui uma ação derivativa no controlador, por meio da substituição da entrada do controlador $ONFC$. Na nova abordagem proposta, o erro é substituído pela taxa de variação temporal do erro. Foi realizada a análise matemática do controlador proposto e verificou-se que essa nova formulação sintetiza uma ação de controle integral e derivativa, sendo a ação de controle proporcional ao erro substituída pela ação derivativa.

Para verificar o desempenho dos controladores estudados, um total de 6 experimentos foram planejados, incluindo experimentos com objetivos de rejeitar perturbações e acompanhar mudanças de *setpoints*. Os controladores foram aplicados em um processo real, para controle da vazão de água em uma planta para práticas de controle de processo que trabalha com instrumentos e controladores industriais. Foram aplicados nos experimentos o controlador $ONFC_{Dw}$ com α fixo, $ONFC_{Dw}$ com *Taxa de Aprendizagem Dinâmica*, $ONFC_{Dw}$ com *Adaptação de Contexto*, o $ONFC_{DwDe}$ e o controlador PI já usado na planta.

Todos os controladores conseguiram desempenho igual ou melhor ao controlador PI já utilizado na planta. O controlador $ONFC_{Dw}$ com *Taxa de Aprendizagem Dinâmica* obteve o melhor resultado para os experimentos de rejeição de distúrbios e o controlador $ONFC_{Dw}$ com *Adaptação de Contexto* para os experimentos de servomecanismo. Após analisar os resultados, é possível concluir que a *Taxa de Aprendizagem Dinâmica* melhora o desempenho do controlador $ONFC_{Dw}$, sendo superior à utilização de α fixo, já que a metodologia de ajuste dinâmico de α faz a redução do valor da taxa de aprendizagem sempre que o erro está elevado, gerando como resultado uma redução no *overshoot* da variável controlada e acelerando a estabilização da variável controlada. A *Adaptação de Contexto* mostrou-se eficiente quando há mudanças de *setpoint* frequentes e para mudanças de maior magnitude. Quando isso ocorre, o controlador com a *Adaptação de Contexto* apresentará menor *overshoot* e será mais estável. Foram detectadas situações em que *Adaptação de Contexto* pode gerar lentidão no controlador, quando houver um ajuste de EM para um valor elevado e não houver mais mudanças de *setpoint*. Nesses casos, o controlador ficará com ganho reduzido e lentidão para corrigir perturbações. Uma solução de melhoria na *Adaptação de Contexto* foi sugerida para trabalhos futuros.

Conforme esperado, o controlador $ONFC_{DwDe}$ teve desempenho inferior aos demais, em função da ausência de uma ação proporcional ao erro. Assim, o controlador fica lento e sem energia para correção do erro entre o valor da variável controlada e o valor desejado, tanto em situações de rejeição de distúrbios quanto em problemas de servomecanismo.

Por fim, conclui-se que as adaptações dinâmicas dos parâmetros α e EM , implementadas com a *Taxa de Aprendizagem Dinâmica* e a *Adaptação de Contexto*, geram melhoria no desempenho do $ONFC_{Dw}$, tornando-o um controlador mais estável. As duas ações combinadas trabalham com o erro, reduzindo o ganho quando o erro apresenta valores próximos de EM e acelerando a aprendizagem do controlador quando o sinal de erro apresenta valores menores. A nova forma de calcular a taxa de aprendizagem do controlador, proposta neste trabalho, se

mostra como um α ótimo para sistemas de primeira ordem que, em simulações computacionais, mostrou-se muito eficiente para acompanhar um modelo de referência. Essa abordagem mostra-se promissora para estudos que possam generalizá-la para qualquer sistema, o que tornaria a taxa de aprendizagem vinculada ao modelo do processo e não mais um parâmetro do controlador.

Essas análises e contribuições tornam o processo de ajuste dos parâmetros menos rigoroso, pois ao invés da utilização de um valor fixo para o α e EM , são definidos valores limites, que vão ser alterados dinamicamente, reduzindo o impacto de ajustes iniciais imprecisos. Com a utilização dos controladores em processos reais, com equipamentos industriais e trabalhando na metodologia para ajuste dos parâmetros, está sendo gerada uma contribuição para a disseminação do uso do controlador ONFC industrialmente.

6.2 Propostas de Trabalhos Futuros

A partir dos estudos realizados no presente trabalho, são listadas as seguinte propostas de trabalhos futuros:

- Dar continuidade nos estudos da Taxa de Aprendizagem baseada no modelo do processo: estender a definição para sistemas de ordem maior e aplicá-lo em processos reais.
- Aplicação da *Adaptação de Contexto* em outros processos: a *Adaptação de Contexto* é uma metodologia proposta para ajuste do parâmetro EM , de grande importância para o desempenho do controlador ONFC. Essa metodologia deve ser aplicada em outros processos reais, para validação da metodologia.
- Ajuste do EM em regime permanente: um aprimoramento da *Adaptação de Contexto* pode ser feita, realizando um novo ajuste do EM quando o controlador está em regime permanente, reduzindo o valor do parâmetro para aumentar o ganho do controlador, aumentando a capacidade de rejeitar perturbações.
- Estudo do controlador ONFC $_{DwDe}$: o controlador ONFC $_{DwDe}$ foi proposto e a análise matemática da saída do controlador foi realizada. Pode ser feito um novo estudo do controlador, verificando o ajuste dos seus parâmetros e aplicando-o a plantas que demandam de ação derivativa para o seu funcionamento.
- Dar continuidade ao estudo do controlador ONFC $_{DwD}$: o controlador ONFC $_{DwDe}$ apresentou o acréscimo da ação derivativa, mas perdeu a ação proporcional. O controlador ONFC $_{DwD}$ possui as duas ações em sua formulação, mas precisa de mais estudos para desenvolver metodologias de ajuste de seus parâmetros. Um estudo poderia também tentar reduzir o número de parâmetros do controlador, facilitando a sua utilização.
- Estudo do ONFC em sistemas MIMO: o controlador ONFC tem mostrado bom desempenho para sistemas SISO. Propõe-se, como trabalho futuro, a formulação e aplicação do controlador em sistemas de mais de uma entrada e/ou mais de uma saída.

6.3 Trabalho Publicados

O trabalho científico a seguir foi aceito para publicação durante a elaboração da dissertação.

- **Anais do XV Encontro Nacional de Inteligência Artificial e Computacional, 3:**
859-870. São Paulo, Outubro de 2018.
A Water Flow Control with OnLine Neurofuzzy Controller using a Dynamic Learning Rate

Bibliografia

- K. J. Åström e P. Kumar. Control: A perspective. *Automatica*, 50(1):3–43, 2014.
- K. J. Åström e B. Wittenmark. On self tuning regulators. *Automatica*, 9(2):185–199, 1973.
- K. J. Åström e B. Wittenmark. *Adaptive control*. Courier Corporation, 2013.
- R. Babuška e H. B. Verbruggen. An overview of fuzzy modeling for control. *Control Engineering Practice*, 4(11):1593–1606, 1996.
- Y. S. Boutalis e M. A. Christodoulou. Special issue on new results on neuro-fuzzy adaptive control systems. *International Journal of Adaptive Control and Signal Processing*, (26):557–559, 2012.
- W. Caminhas, G. Pereira, H. Tavares, e F. Gomide. Identificação de sistemas dinâmicos: Abordagem baseada em neurônio nebuloso. *Anais do V Simpósio Brasileiro de Redes Neurais (SBRN 98)*, Belo Horizonte–MG, p. 105–110, 1998.
- W. M. Caminhas, H. M. F. Tavares, e F. A. C. Gomide. A neurofuzzy approach for fault diagnosis in dynamic system. In *IEEE International Conference on Fuzzy Systems*, 1996.
- J. Carvajal, G. Chen, e H. Ogmen. Fuzzy pid controller: Design, performance evaluation, and stability analysis. *Information sciences*, 123(3-4):249–270, 2000.
- M. A. Carvalho. Controlador neurofuzzy com aprendizado on-line: Teoria e aplicação na indústria de petróleo. Dissertação de Mestrado, Universidade Federal de Minas Gerais, 2010.
- C. J. F. de Araújo. *Controlador Nebuloso por Modos Deslizantes Adaptativos*. Tese de Doutorado, Universidade Federal de Minas Gerais, 2011.
- S. R. dos Santos, J. L. Amaral, e J. F. M. Amaral. Adaptive intelligent systems applied to two-wheeled robot. In *Evolving and Adaptive Intelligent Systems (EAIS), 2016 IEEE Conference on*, p. 146–150. IEEE, 2016.
- C. Z. M. Ferreira. *Controlador NeuroFuzzy Online: Estudo Comparativo com PID em Simulação e Aplicação Real*. Monografia de Graduação. Universidade Federal de Minas Gerais, 2017.
- H. R. N. Gomes, C. Z. M. Ferreira, E. S. Oliveira, A. J. Reis, e W. M. Caminhas. A water flow control with online neurofuzzy controller using a dynamic learning rate. In *Anais do XV Encontro Nacional de Inteligência Artificial e Computacional*, p. 859–870, São Paulo, Brasil, 2018.
- M. R. Gouvêa. *Controle Neurofuzzy de Motor de Indução com Estimação de Parâmetros e Fluxo de Estator*. Tese de Doutorado, Universidade Federal de Minas Gerais, 2005.
- S. Haykin. *Redes neurais: princípios e prática*. Bookman Editora, 2007.
- J.-S. Jang e C.-T. Sun. Neuro-fuzzy modeling and control. *Proceedings of the IEEE*, 83(3):378–406, 1995.
- J.-S. R. Jang, C.-T. Sun, e E. Mizutani. *Neuro-Fuzzy and Soft Computing*. Prentice Hall, 1997.

- F. Lamnabhi-Lagarrigue, A. Annaswamy, S. Engell, A. Isaksson, P. Khargonekar, R. M. Murray, H. Nijmeijer, T. Samad, D. Tilbury, e P. Van den Hof. Systems & control for the future of humanity, research agenda: Current and future roles, impact and grand challenges. *Annual Reviews in Control*, 43:1–64, 2017.
- K. Narendra e Z. Han. A new approach to adaptive control using multiple models. *International Journal of adaptive Control and signal processing*, 26(8):778–799, 2012.
- M. H.-T. Nguyen e K. K. Tan. From parametric model-based optimization to robust pid gain scheduling. *arXiv preprint arXiv:1305.6402*, 2013.
- K. Ogata. *Engenharia de Controle Moderno*. Pearson Prentice Hall, 2003.
- L. C. Oliveira. *Contribuições ao controlador ONFC: inclusão de ação derivativa e metodologia de estimativa das taxas de aprendizagem*. Monografia do Curso de Especialização em Automação Industrial, Universidade Federal de Minas Gerais, 2017.
- K. M. Passino e S. Yurkovich. *Fuzzy Control*. Addison Wesley, 1998.
- A. V. Pires. Controladores baseados em técnicas de inteligência computacional: Análise, projeto e aplicações. Dissertação de Mestrado, Universidade Federal de Minas Gerais, 2007.
- F. Rashidi. Adaptive neurofuzzy control of engine idle speed. *Journal of Intelligent & Fuzzy Systems*, (32):817–829, 2017.
- T. Sato, H. Tajika, R. Vilanova, e Y. Konishi. Adaptive pid control system with assigned robust stability. *IEEE Transactions on Electrical and Electronic Engineering*, 2018.
- S. Skogestad. Probably the best simple pid tuning rules in the world. In *AICHE Annual Meeting, Reno, Nevada*, Volume 77, 2001.
- S. Suryakala e D. Rathikarani. Self tuning regulators for a liquid level process. *Advances in Natural and Applied Sciences*, 8(22):19–28, 2014.
- T. Takagi e M. Sugeno. Fuzzy identification of systems and its applications to modeling and control. *IEEE transactions on systems, man, and cybernetics*, (1):116–132, 1985.
- R. Vilanova e A. Visioli. *PID control in the third millennium*. Springer, 2012.
- T. Yamakawa, E. Uchino, e T. Miki. A neo fuzzy neuron and its application to system identification and prediction of the system behaviour. *Proceedings of the Second International Conference on Fuzzy Logic and Neural Networks*, (2):477–483, 1992.
- H. Yang, Y.-T. Fu, K.-P. Zhang, e Z.-Q. Li. Speed tracking control using an anfis model for high-speed electric multiple unit. *Control Engineering Practice*, 23:57–65, 2014.
- D. Zhang e B. Wei. Convergence performance comparisons of pid, mrac, and pid+mrac hybrid controller. *Frontiers of Mechanical Engineering*, 11(2):213–217, 2016.

Resultados dos Experimentos

São apresentados os gráficos com os resultados dos 6 experimentos para todos os controladores utilizados.

A.1 ONFC_{Dw} com α fixo

a) Experimento 1

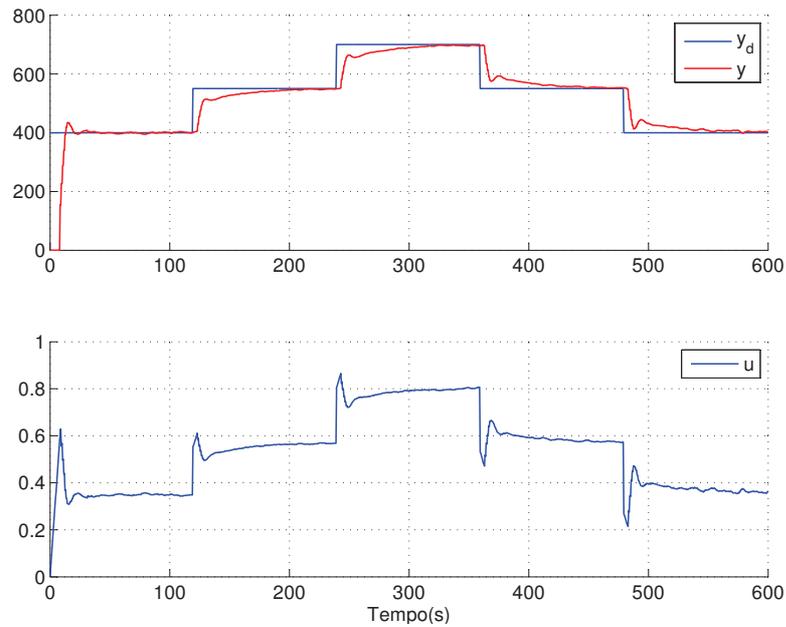


Figura A.1: Experimento 1 - ONFC_{Dw} com α fixo - Valores de y_d , y e u .

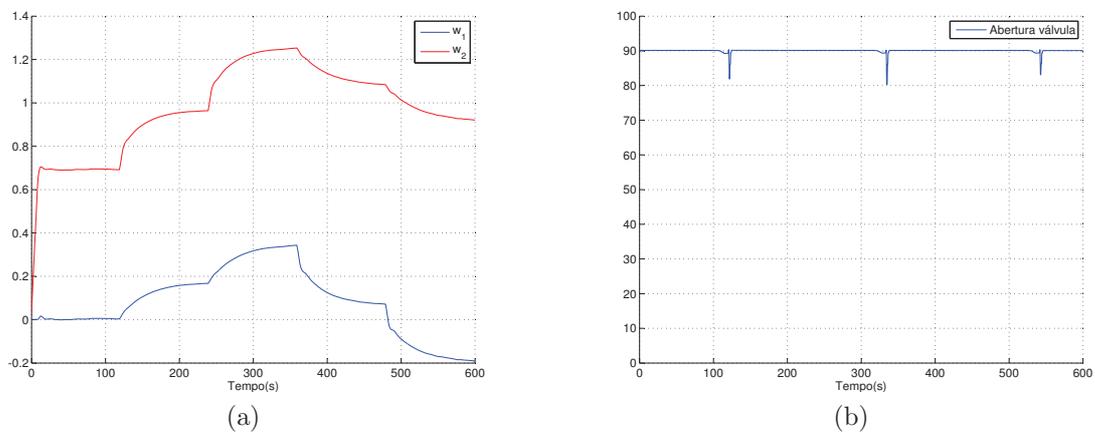


Figura A.2: Experimento 1 - ONFC_{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

b) Experimento 2

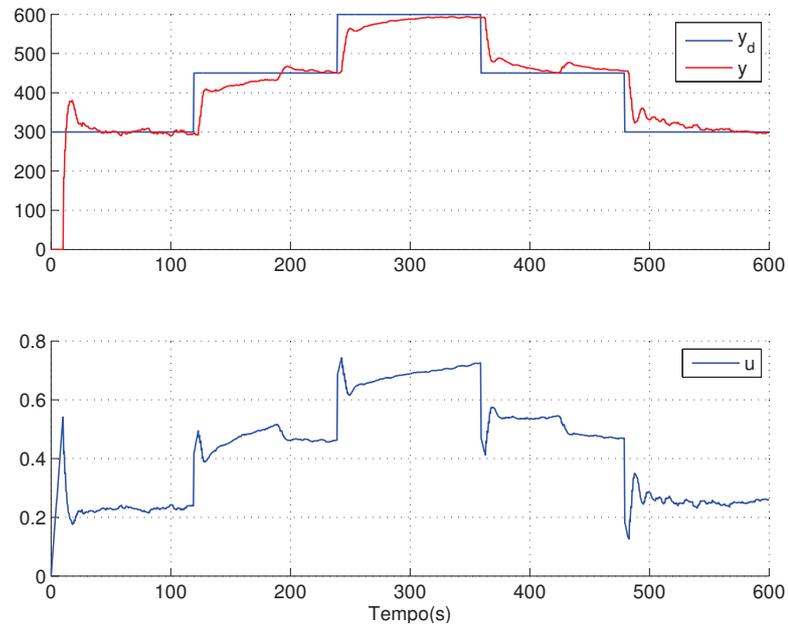


Figura A.3: Experimento 2 - ONFC_{Dw} com α fixo - Valores de y_d , y e u .

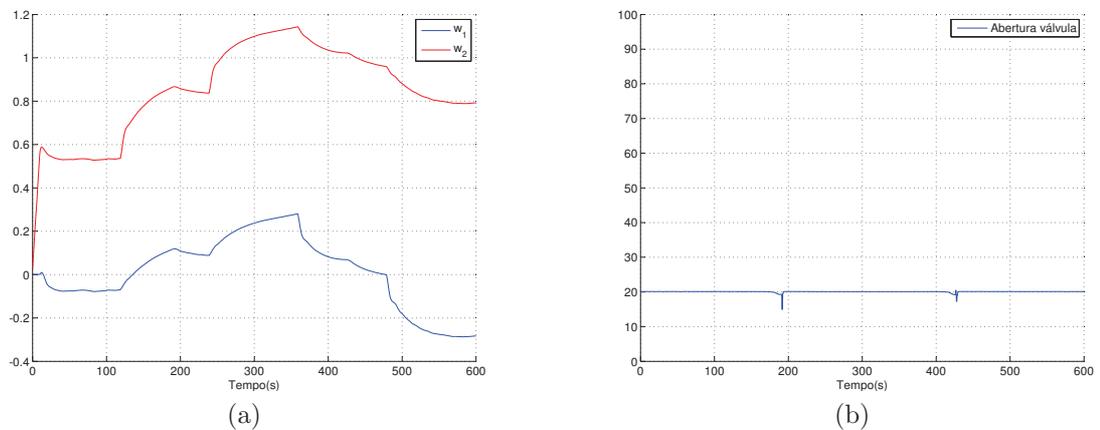


Figura A.4: Experimento 2 - ONFC_{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

c) Experimento 3

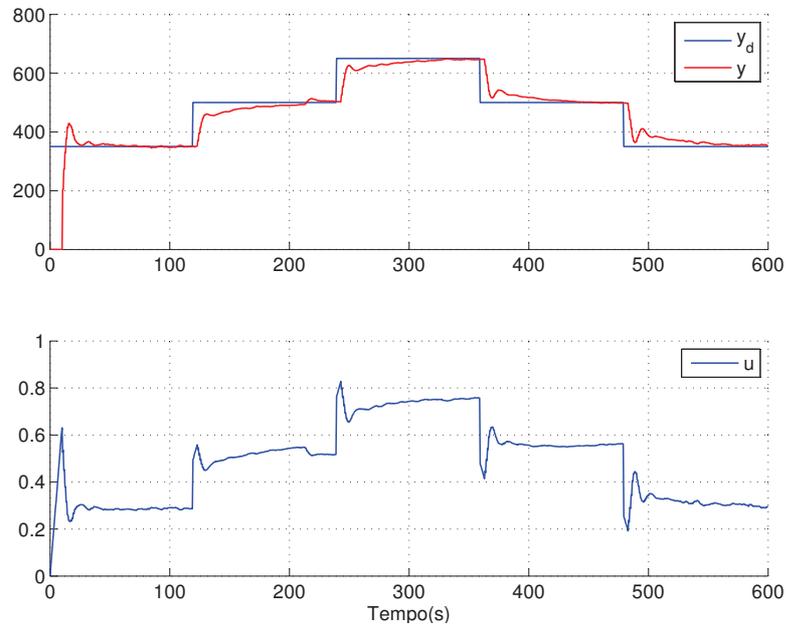


Figura A.5: Experimento 3 - ONFC_{Dw} com α fixo - Valores de y_d , y e u .

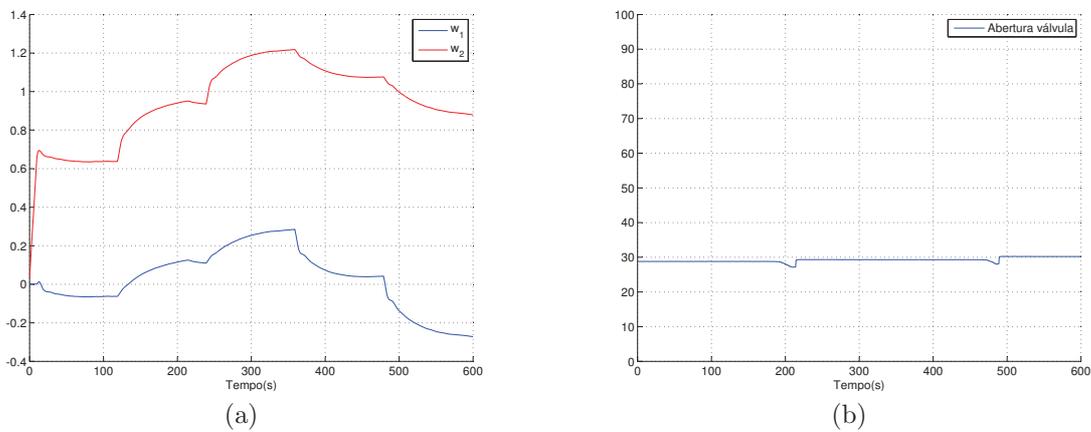
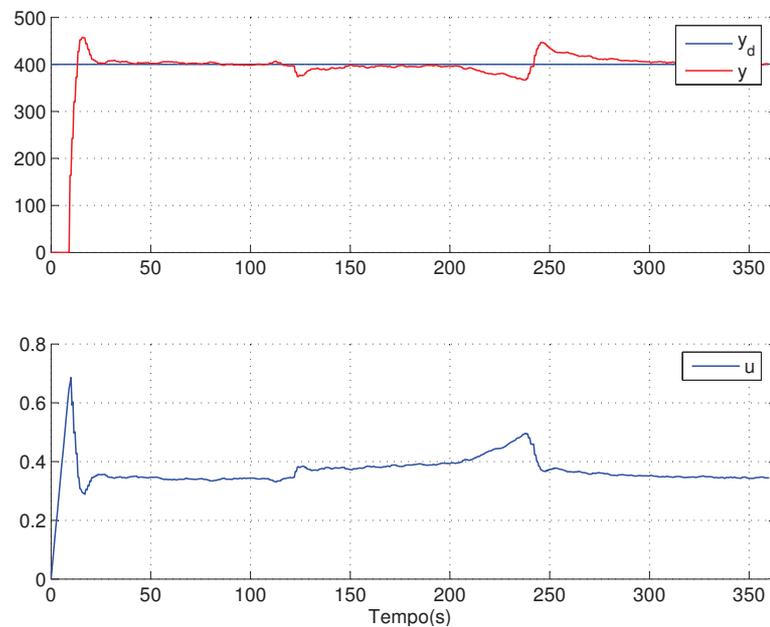
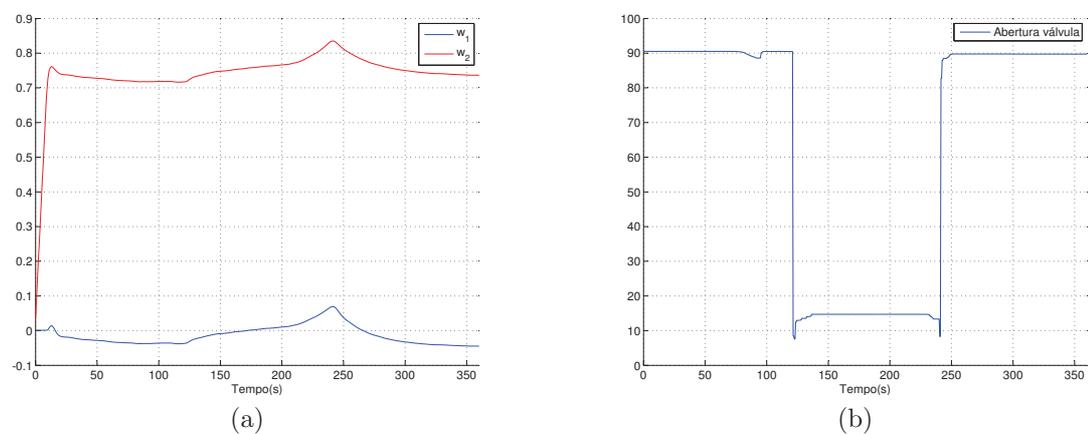


Figura A.6: Experimento 3 - ONFC_{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

d) Experimento 4

Figura A.7: Experimento 4 - ONFC_{Dw} com α fixo - Valores de y_d , y e u .Figura A.8: Experimento 4 - ONFC_{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

e) Experimento 5

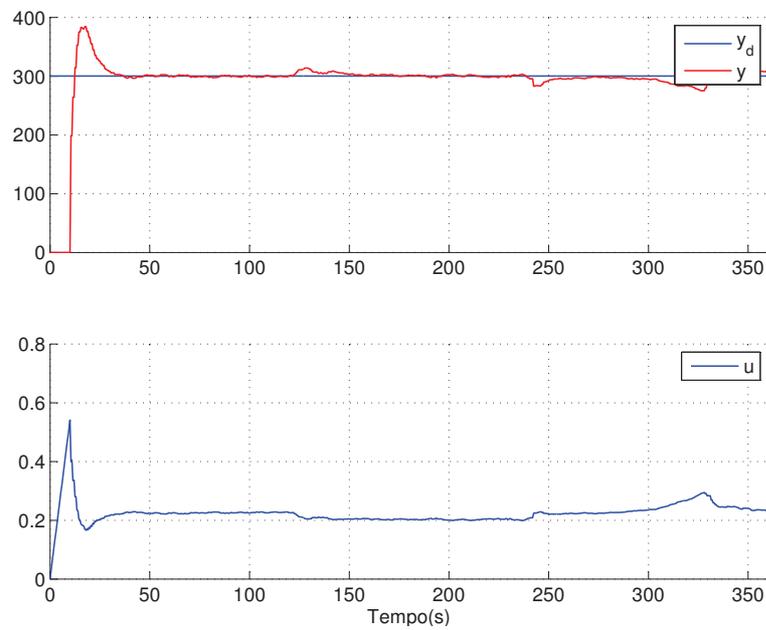


Figura A.9: Experimento 5 - ONFC_{Dw} com α fixo - Valores de y_d , y e u .

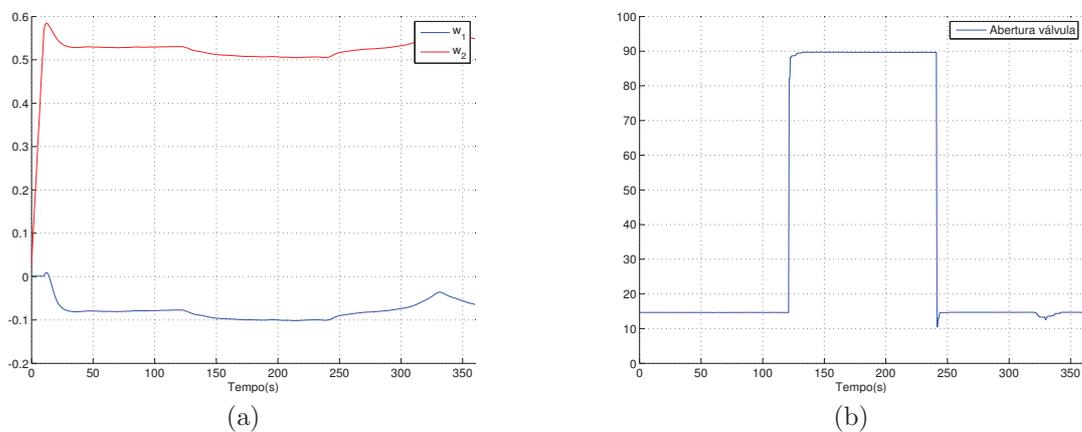


Figura A.10: Experimento 5 - ONFC_{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

f) Experimento 6

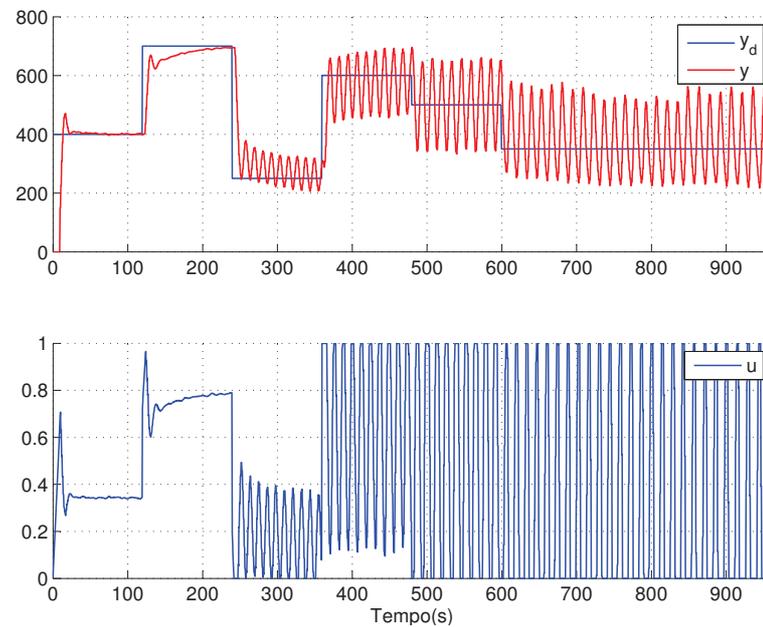


Figura A.11: Experimento 6 - ONFC_{Dw} com α fixo - Valores de y_d , y e u .

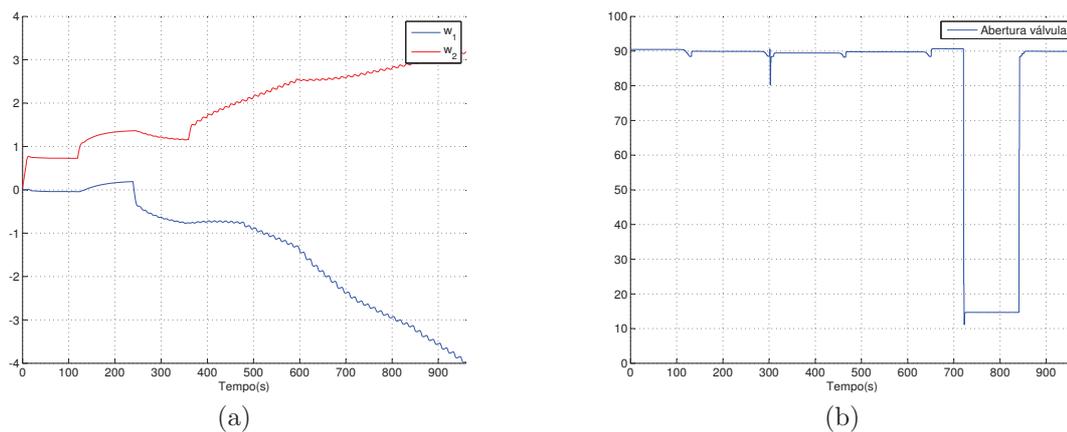


Figura A.12: Experimento 6 - ONFC_{Dw} com α fixo - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

A.2 ONFC_{Dw} com Taxa de Aprendizagem Dinâmica

a) Experimento 1

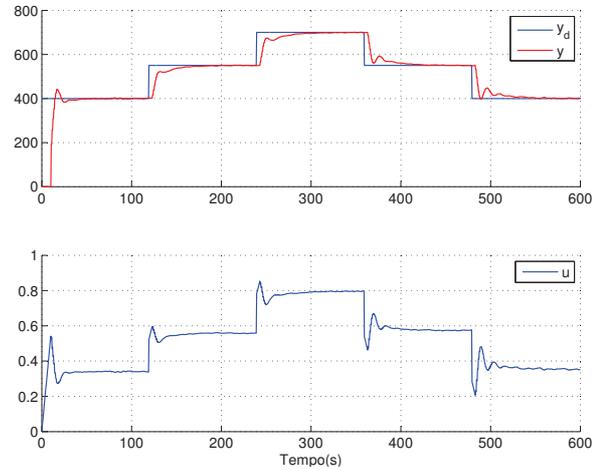


Figura A.13: Experimento 1 - ONFC_{Dw} com α dinâmico - Valores de y_d , y e u .

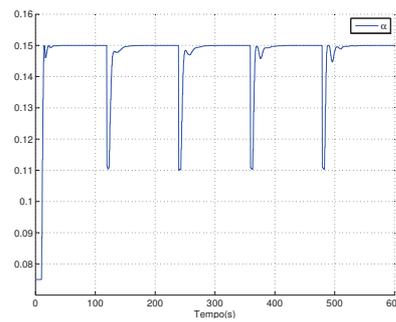


Figura A.14: Experimento 1 - ONFC_{Dw} com α dinâmico - Valores de α

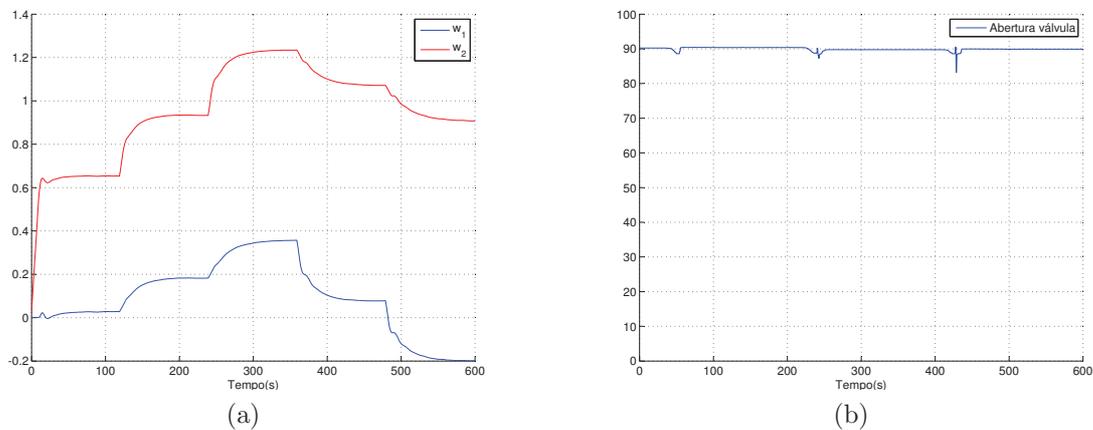


Figura A.15: Experimento 1 - ONFC_{Dw} com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

b) Experimento 2

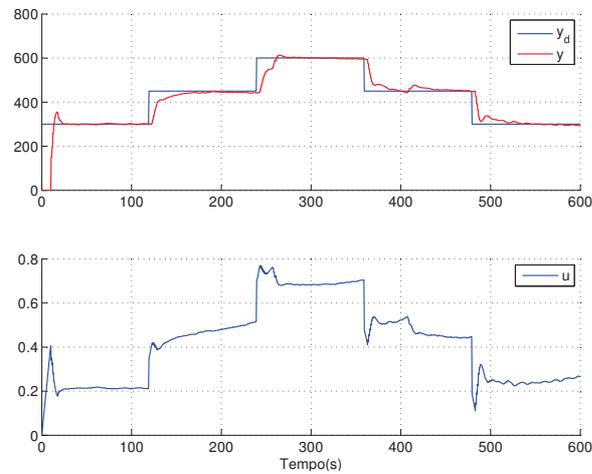


Figura A.16: Experimento 2 - ONFC_{Dw} com α dinâmico - Valores de y_d , y e u .

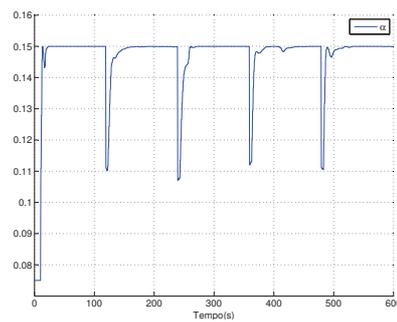


Figura A.17: Experimento 2 - ONFC_{Dw} com α dinâmico - Valores de α

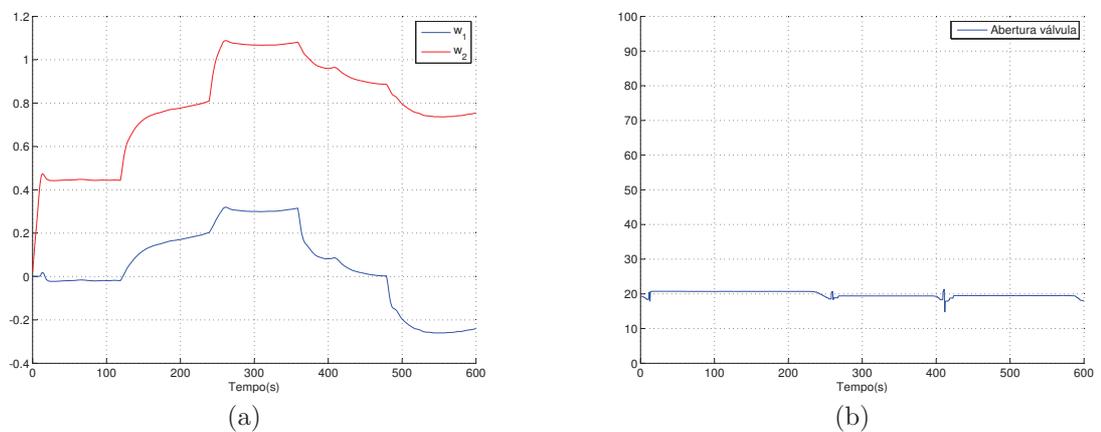


Figura A.18: Experimento 2 - ONFC_{Dw} com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

c) Experimento 3

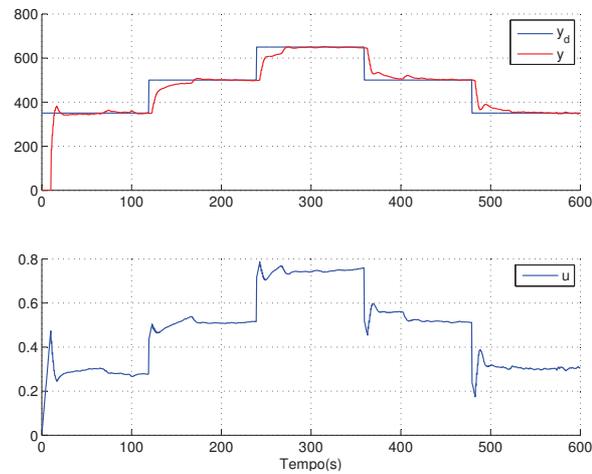


Figura A.19: Experimento 3 - ONFC $_{Dw}$ com α dinâmico - Valores de y_d , y e u .

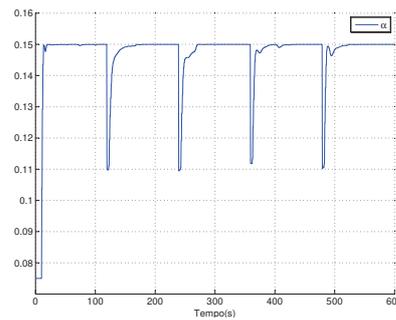


Figura A.20: Experimento 3 - ONFC $_{Dw}$ com α dinâmico - Valores de α

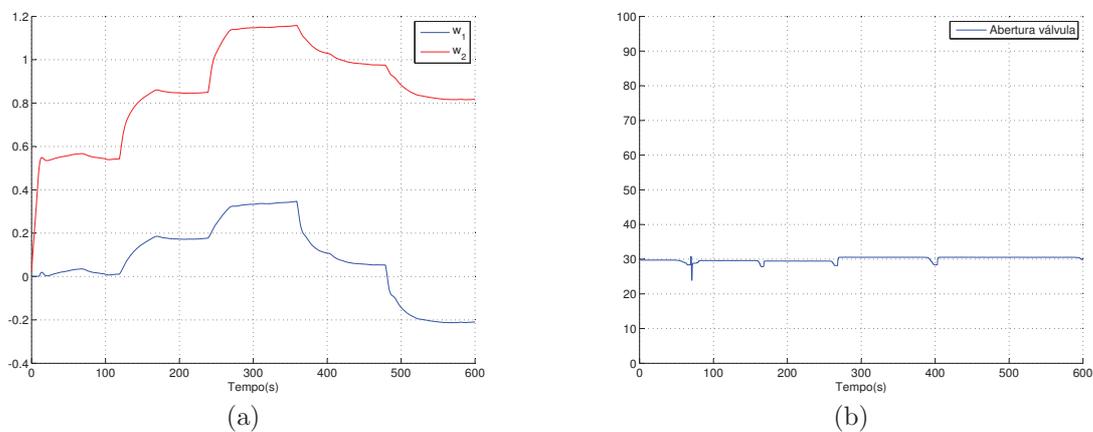


Figura A.21: Experimento 3 - ONFC $_{Dw}$ com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

d) Experimento 4

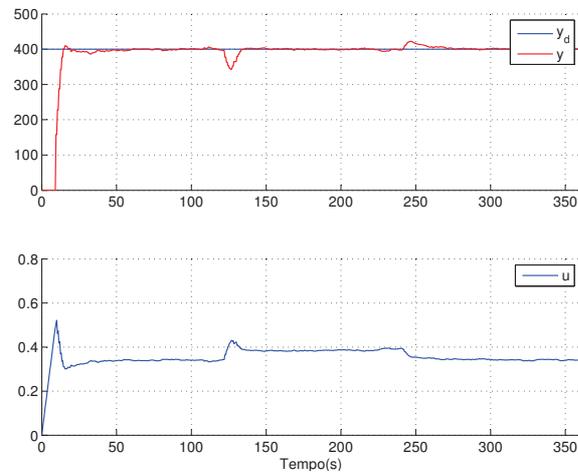


Figura A.22: Experimento 4 - ONFC_{Dw} com α dinâmico - Valores de y_d , y e u .

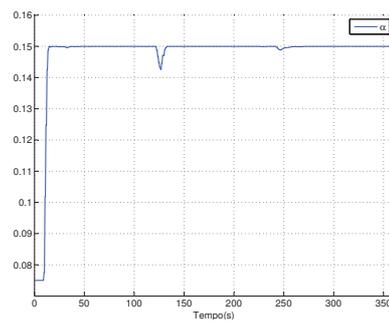


Figura A.23: Experimento 4 - ONFC_{Dw} com α dinâmico - Valores de α

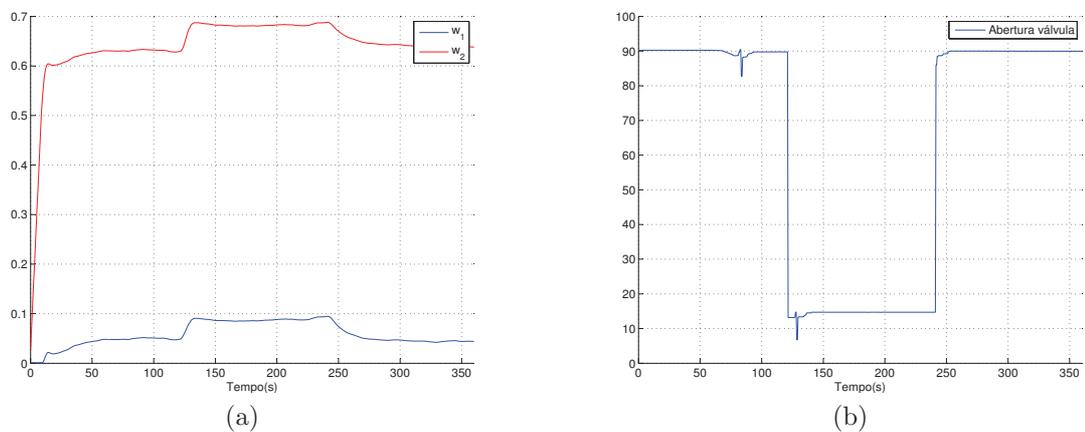


Figura A.24: Experimento 4 - ONFC_{Dw} com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

e) Experimento 5

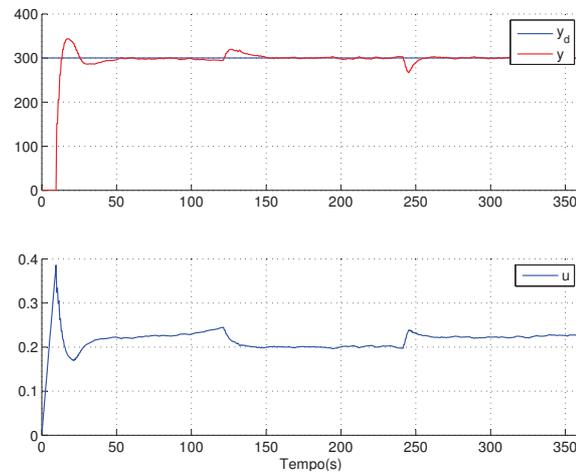


Figura A.25: Experimento 5 - ONFC_{Dw} com α dinâmico - Valores de y_d , y e u .

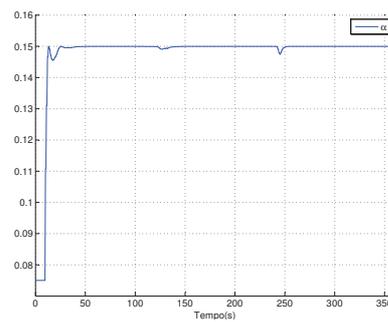


Figura A.26: Experimento 5 - ONFC_{Dw} com α dinâmico - Valores de α

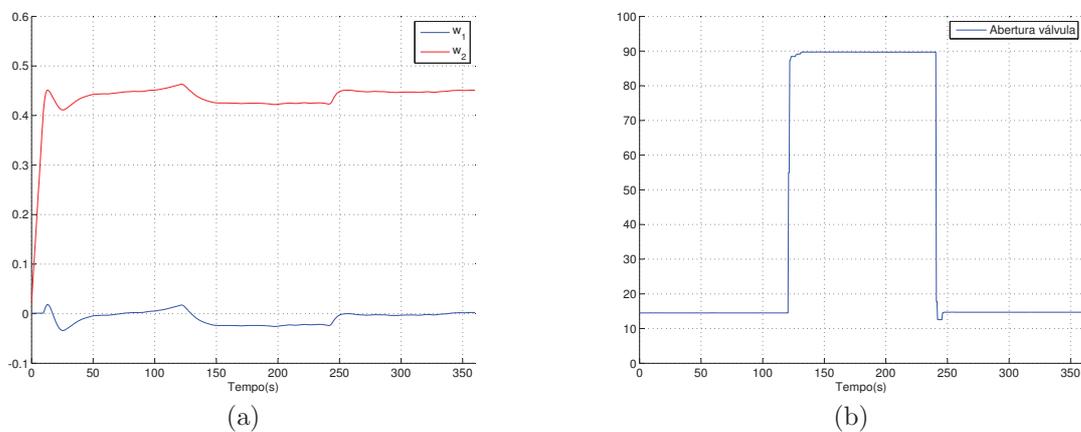
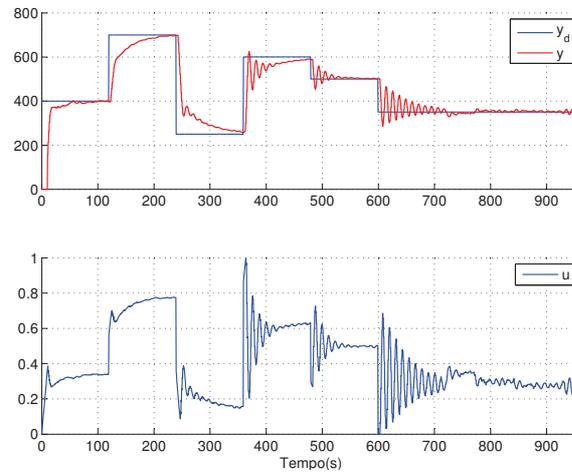
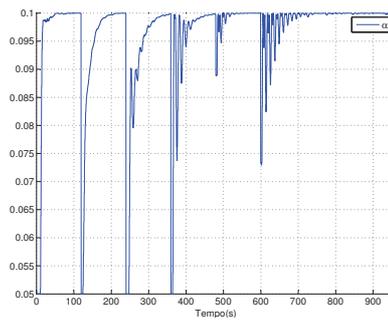
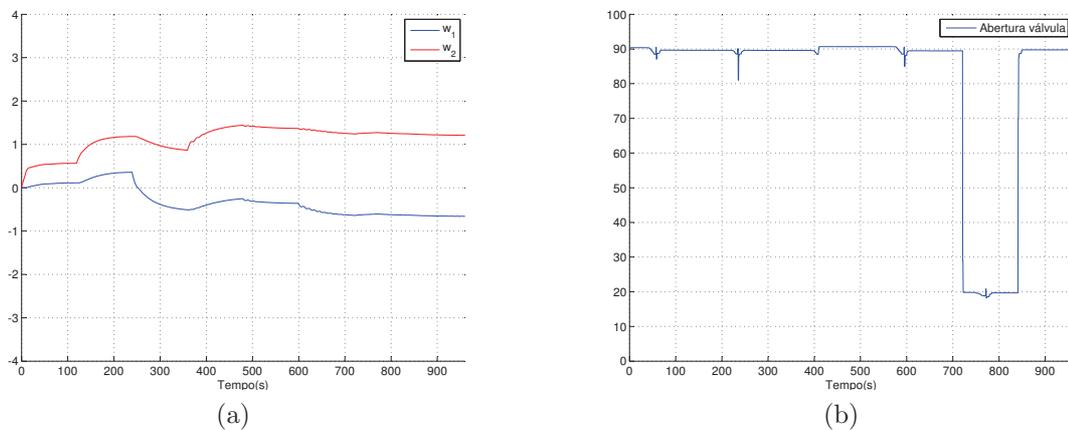


Figura A.27: Experimento 5 - ONFC_{Dw} com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

f) Experimento 6

Figura A.28: Experimento 6 - ONFC_{Dw} com α dinâmico - Valores de y_d , y e u .Figura A.29: Experimento 6 - ONFC_{Dw} com α dinâmico - Valores de α Figura A.30: Experimento 6 - ONFC_{Dw} com α dinâmico - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

A.3 ONFC_{Dw} com Adaptação de Contexto

a) Experimento 1

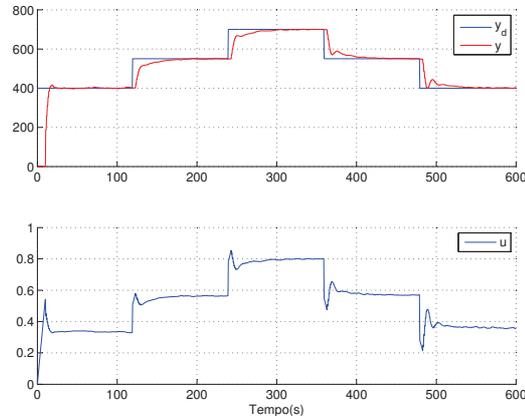


Figura A.31: Experimento 1 - ONFC_{Dw} com Adaptação de Contexto - Valores de y_d , y e u .

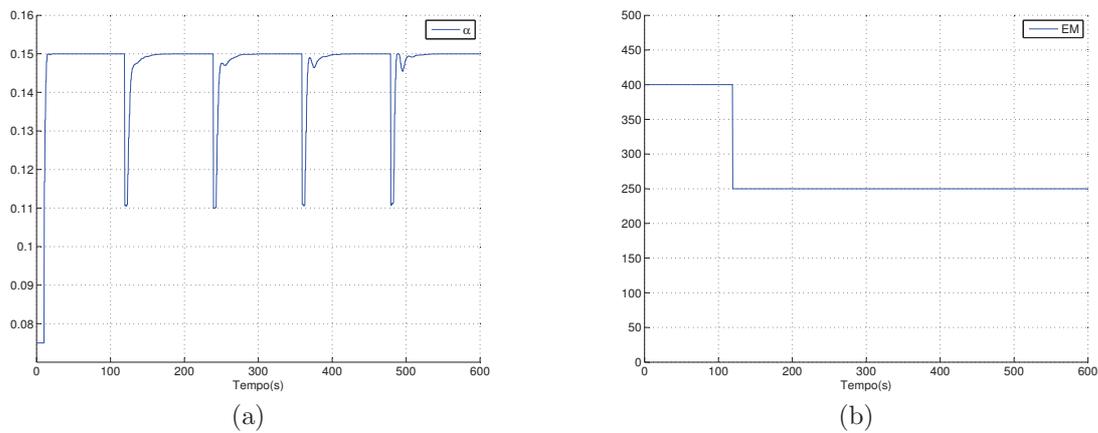


Figura A.32: Experimento 1 - ONFC_{Dw} com Adaptação de Contexto - (a) Valores de α . (b) Valores de EM .

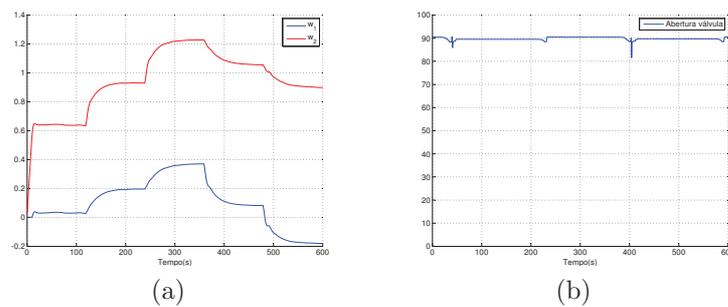


Figura A.33: Experimento 1 - ONFC_{Dw} com Adaptação de Contexto - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

b) Experimento 2

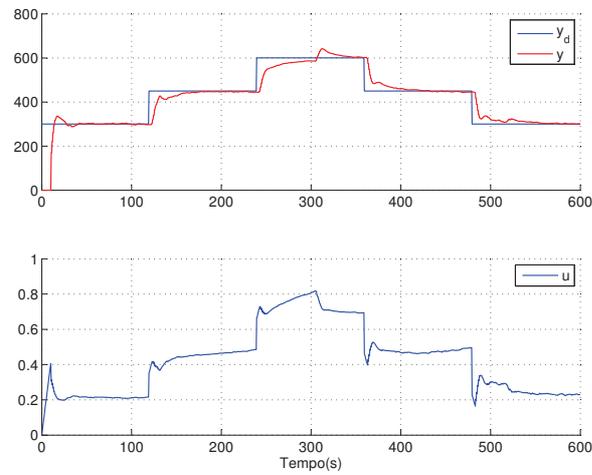


Figura A.34: Experimento 2 - ONFC_{Dw} com *Adaptação de Contexto* - Valores de y_d , y e u .

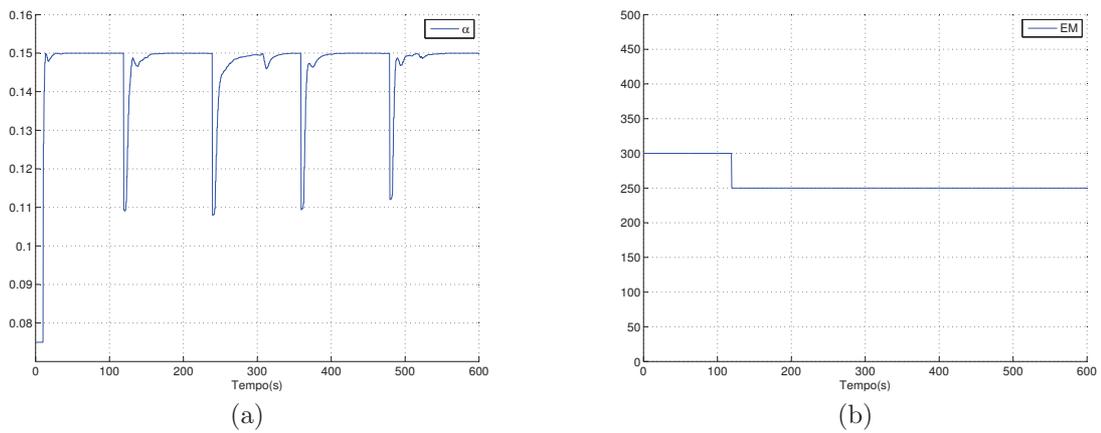


Figura A.35: Experimento 2 - ONFC_{Dw} com *Adaptação de Contexto* - (a) Valores de α . (b) Valores de EM .

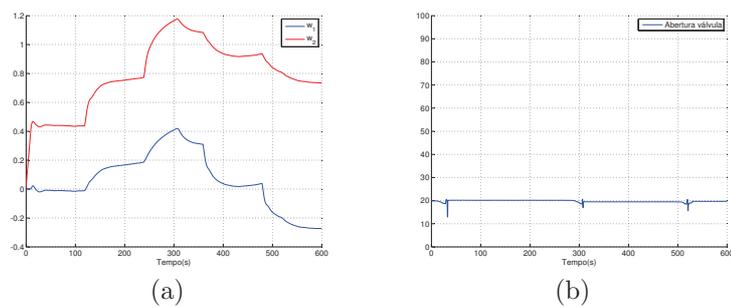


Figura A.36: Experimento 2 - ONFC_{Dw} com *Adaptação de Contexto* - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

c) Experimento 3

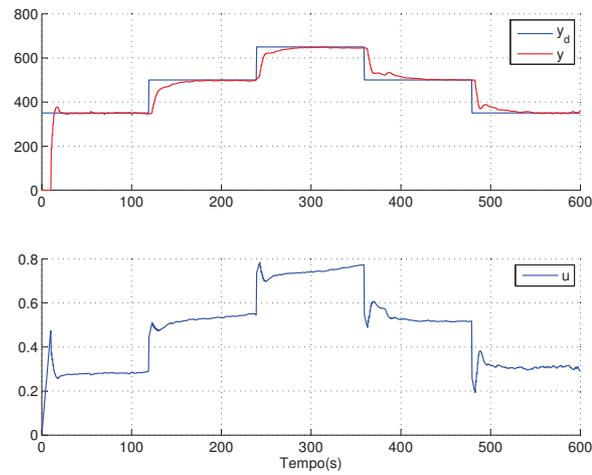


Figura A.37: Experimento 3 - $ONFC_{Dw}$ com *Adaptação de Contexto* - Valores de y_d , y e u .

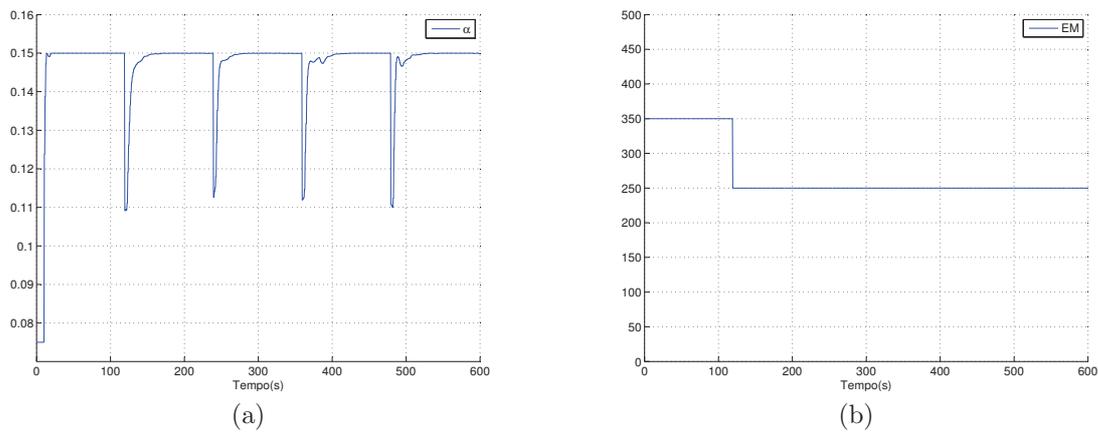


Figura A.38: Experimento 3 - $ONFC_{Dw}$ com *Adaptação de Contexto* - (a) Valores de α . (b) Valores de EM .

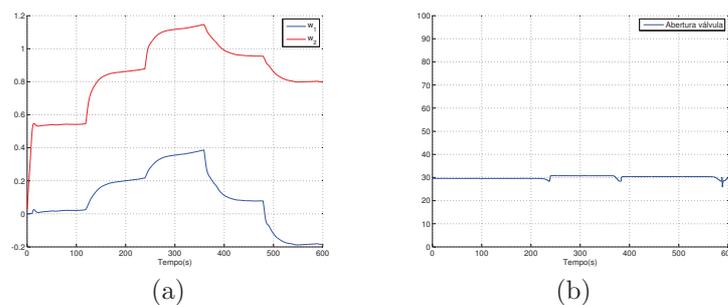


Figura A.39: Experimento 3 - $ONFC_{Dw}$ com *Adaptação de Contexto* - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

d) Experimento 4

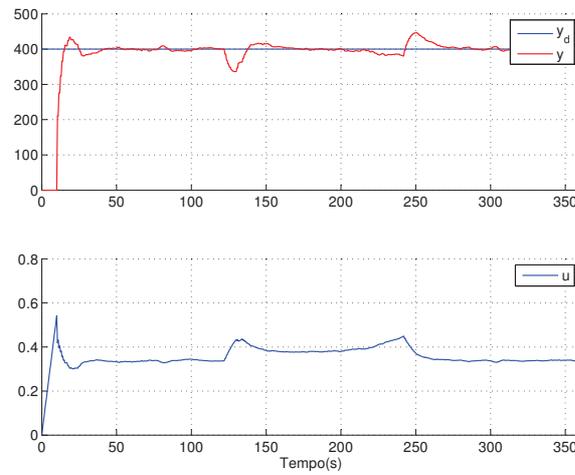


Figura A.40: Experimento 4 - ONFC_{Dw} com *Adaptação de Contexto* - Valores de y_d , y e u .

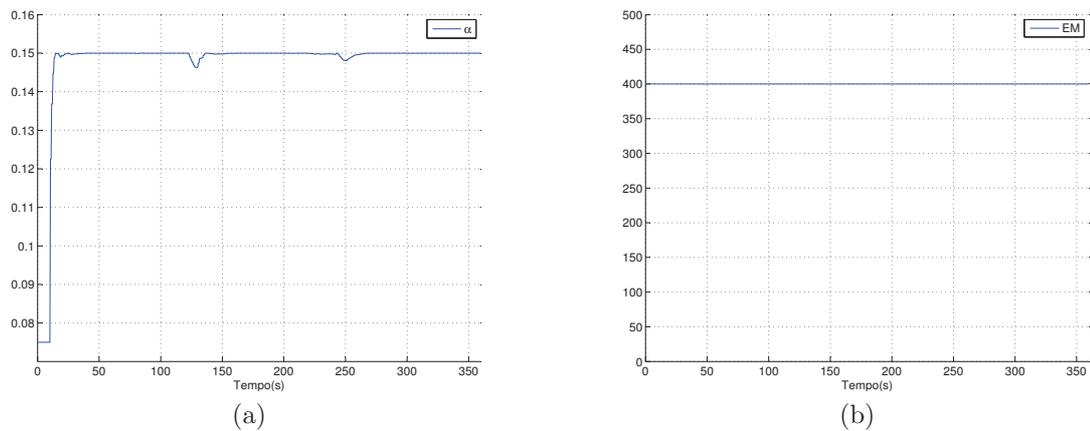


Figura A.41: Experimento 4 - ONFC_{Dw} com *Adaptação de Contexto* - (a) Valores de α . (b) Valores de EM .

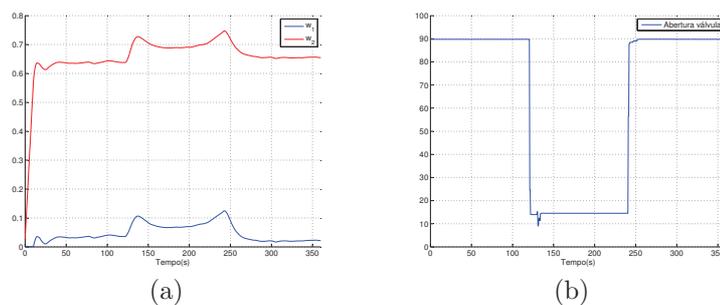


Figura A.42: Experimento 4 - ONFC_{Dw} com *Adaptação de Contexto* - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

e) Experimento 5

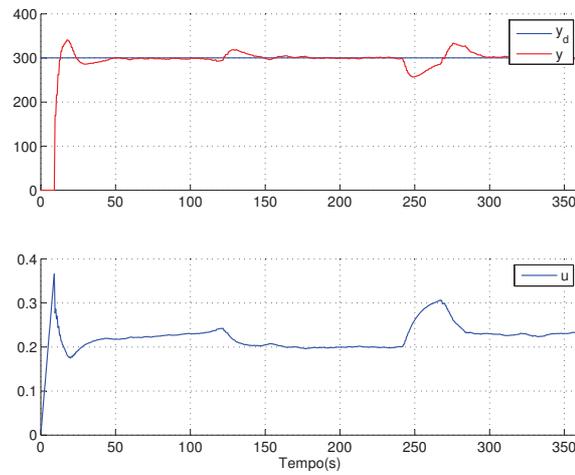


Figura A.43: Experimento52 - ONFC_{Dw} com *Adaptação de Contexto* - Valores de y_d , y e u .

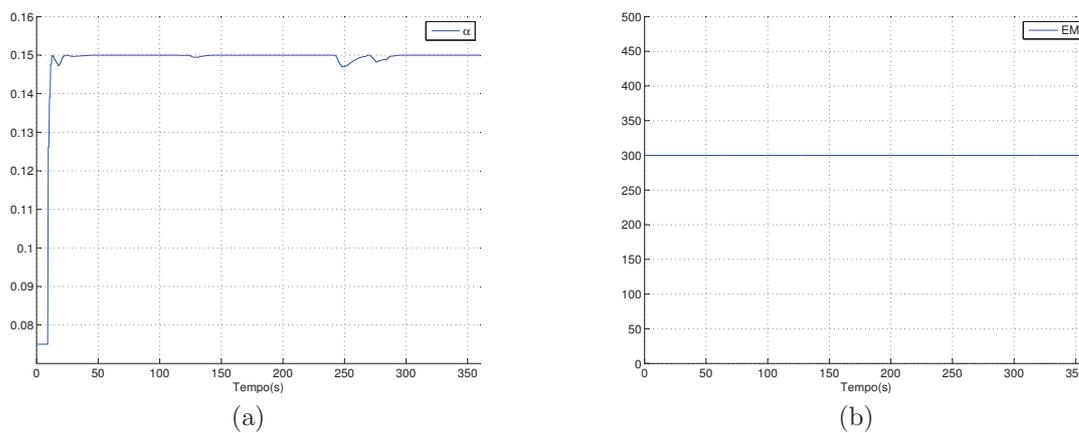


Figura A.44: Experimento 5 - ONFC_{Dw} com *Adaptação de Contexto* - (a) Valores de α . (b) Valores de EM .

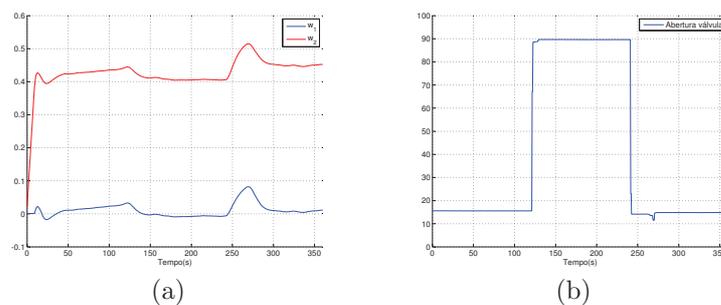


Figura A.45: Experimento 5 - ONFC_{Dw} com *Adaptação de Contexto* - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

f) Experimento 6

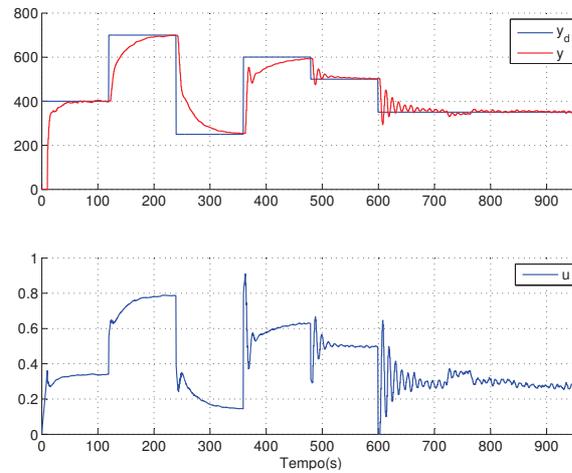


Figura A.46: Experimento 6 - ONFC_{Dw} com *Adaptação de Contexto* - Valores de y_d , y e u .

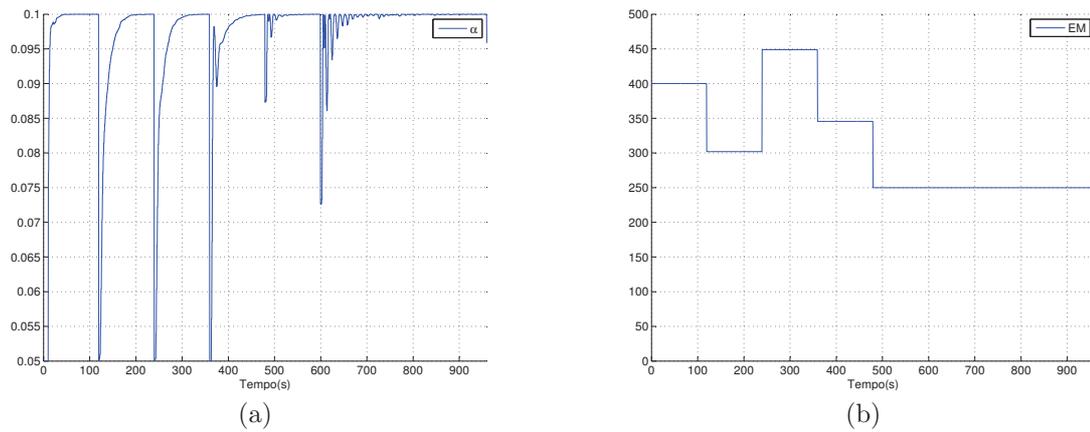


Figura A.47: Experimento 6 - ONFC_{Dw} com *Adaptação de Contexto* - (a) Valores de α . (b) Valores de EM .

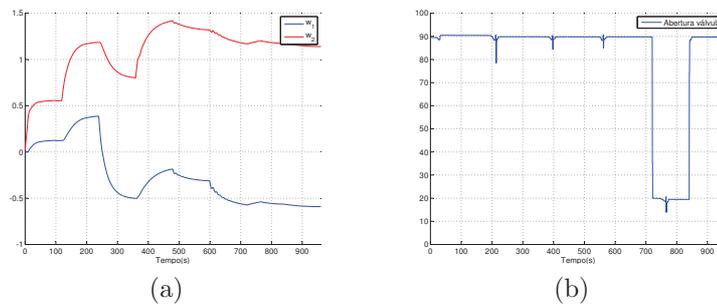


Figura A.48: Experimento 6 - ONFC_{Dw} com *Adaptação de Contexto* - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

A.4 ONFC_{DwDe}

a) Experimento 1

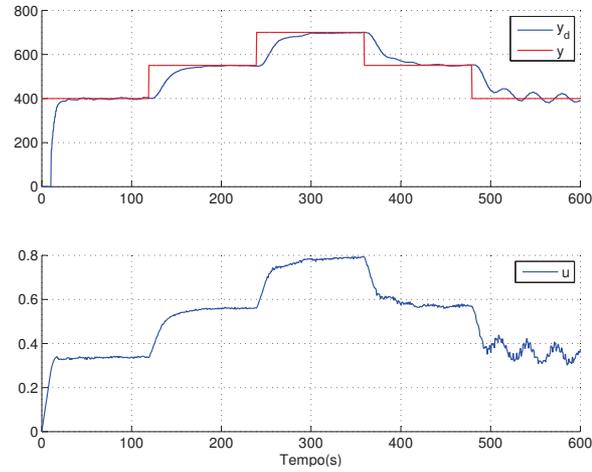


Figura A.49: Experimento 1 - ONFC_{DwDe} - Valores de y_d , y e u .

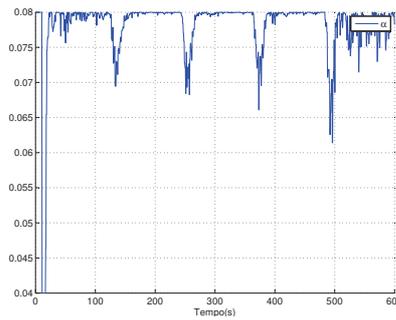


Figura A.50: Experimento 1 - ONFC_{DwDe} - Valores de α

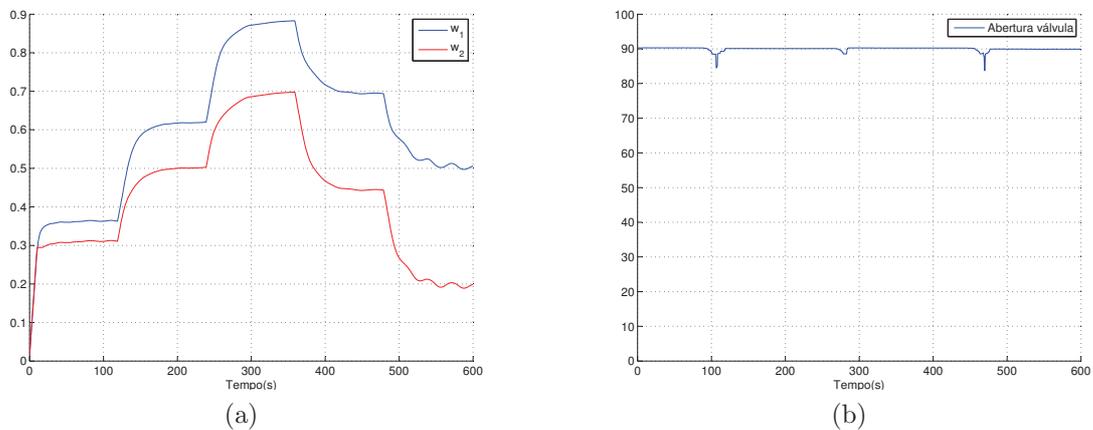
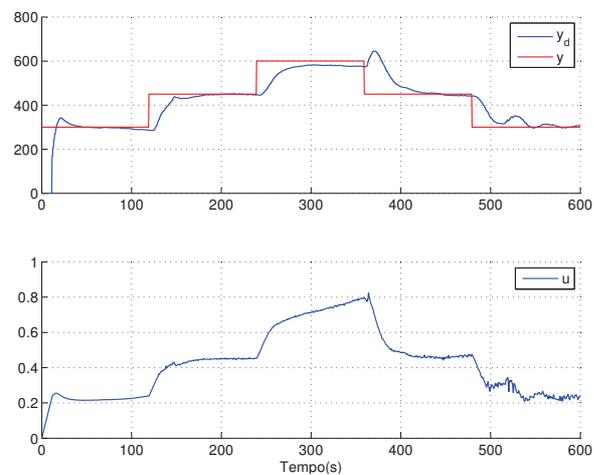
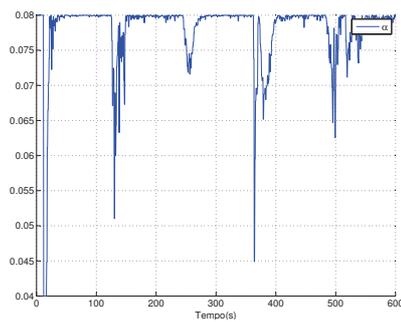
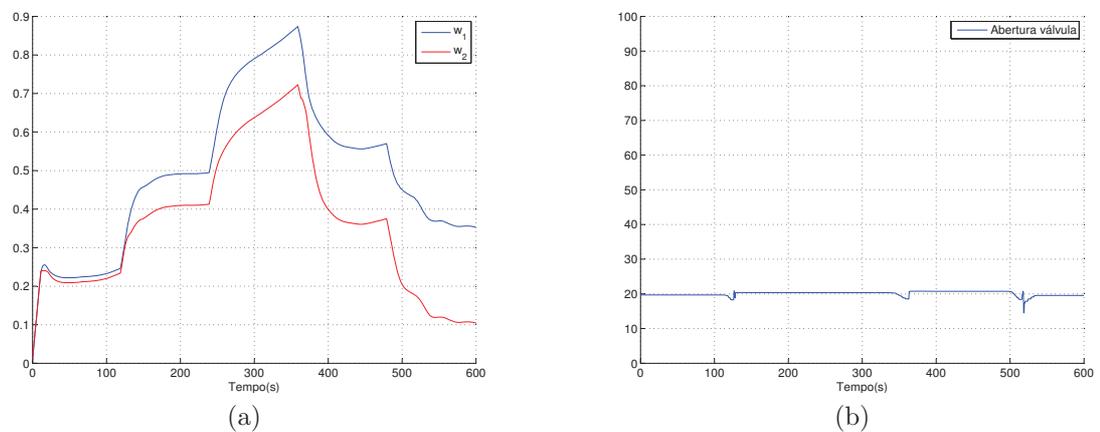


Figura A.51: Experimento 1 - ONFC_{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

b) Experimento 2

Figura A.52: Experimento 2 - ONFC_{DwDe} - Valores de y_d , y e u .Figura A.53: Experimento 2 - ONFC_{DwDe} - Valores de α Figura A.54: Experimento 2 - ONFC_{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

c) Experimento 3

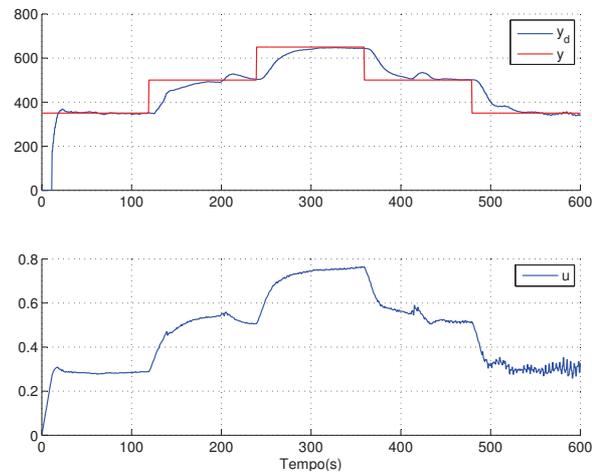


Figura A.55: Experimento 3 - ONFC_{DwDe} - Valores de y_d , y e u .

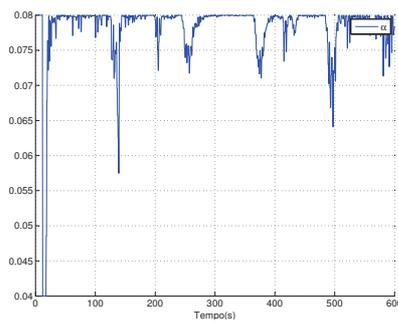


Figura A.56: Experimento 3 - ONFC_{DwDe} - Valores de α

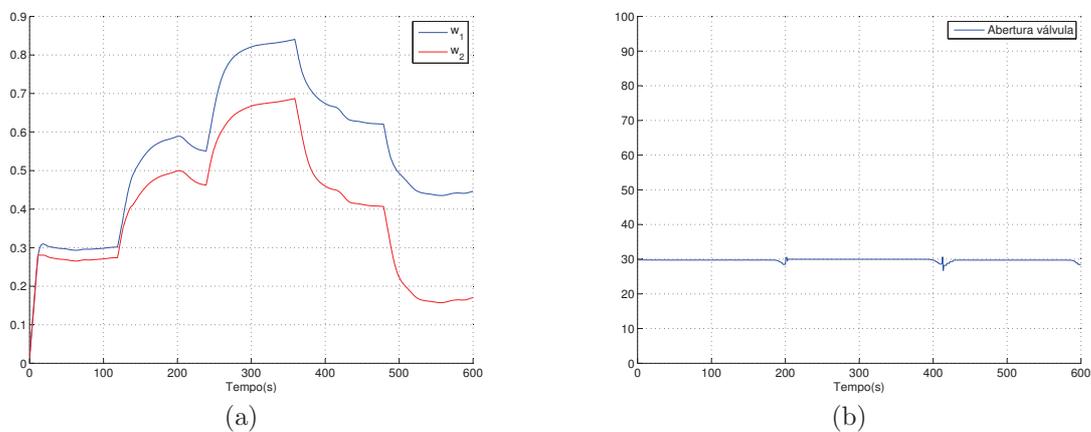
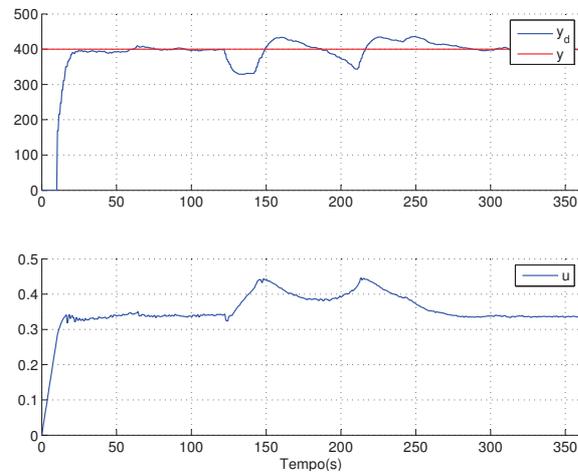
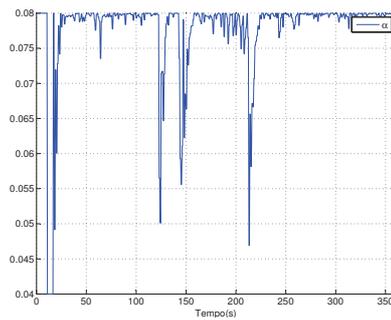
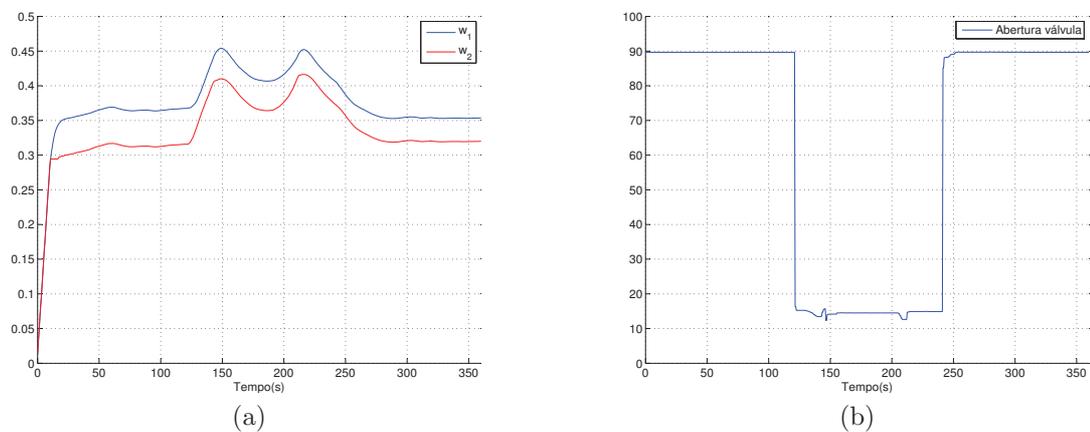


Figura A.57: Experimento 3 - ONFC_{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

d) Experimento 4

Figura A.58: Experimento 4 - ONFC_{DwDe} - Valores de y_d , y e u .Figura A.59: Experimento 4 - ONFC_{DwDe} - Valores de α Figura A.60: Experimento 4 - ONFC_{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

e) Experimento 5

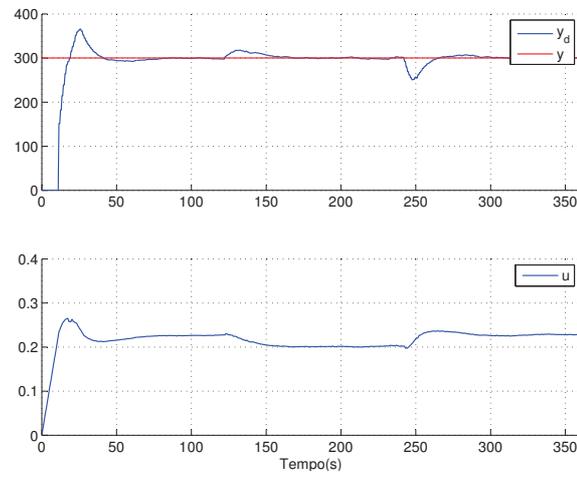


Figura A.61: Experimento 5 - ONFC_{DwDe} - Valores de y_d , y e u .

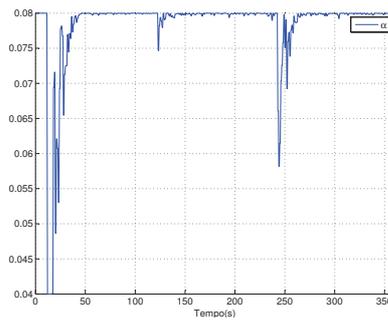


Figura A.62: Experimento 5 - ONFC_{DwDe} - Valores de α

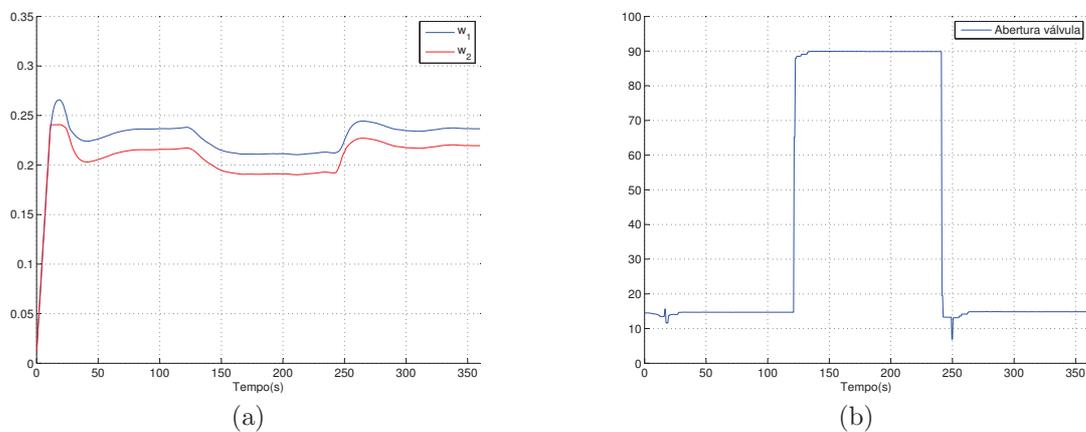
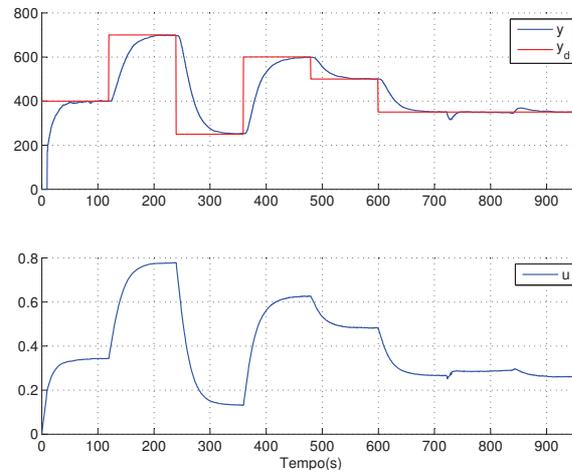
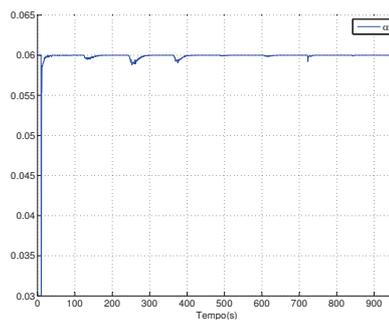
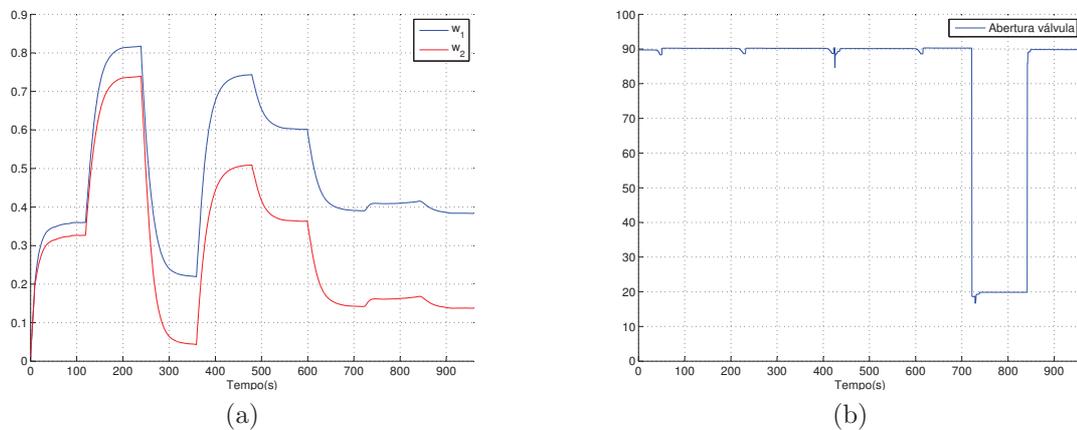


Figura A.63: Experimento 5 - ONFC_{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

f) Experimento 6

Figura A.64: Experimento 6 - ONFC_{DwDe} - Valores de y_d , y e u .Figura A.65: Experimento 6 - ONFC_{DwDe} - Valores de α Figura A.66: Experimento 6 - ONFC_{DwDe} - (a) Valores de w_1 e w_2 . (b) Valores de abertura da válvula.

A.5 Controlador PI

a) Experimento 1

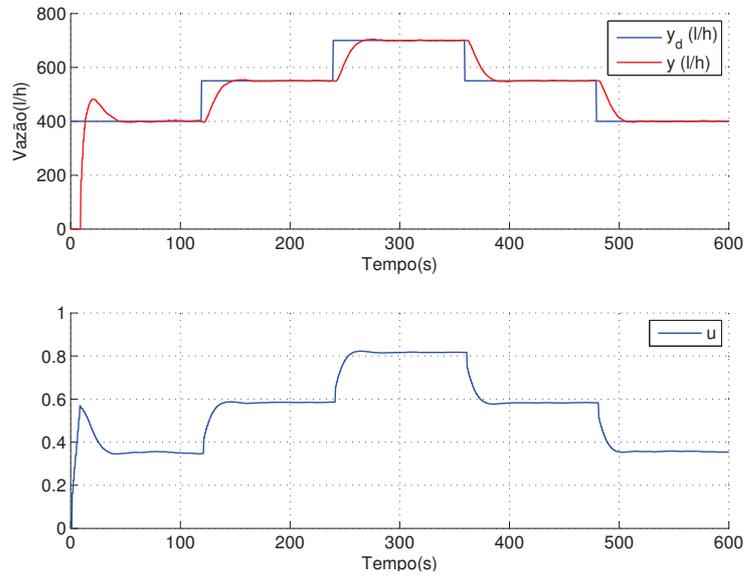


Figura A.67: Experimento 1 - Controlador PI - Valores de y_d , y e u .

b) Experimento 2

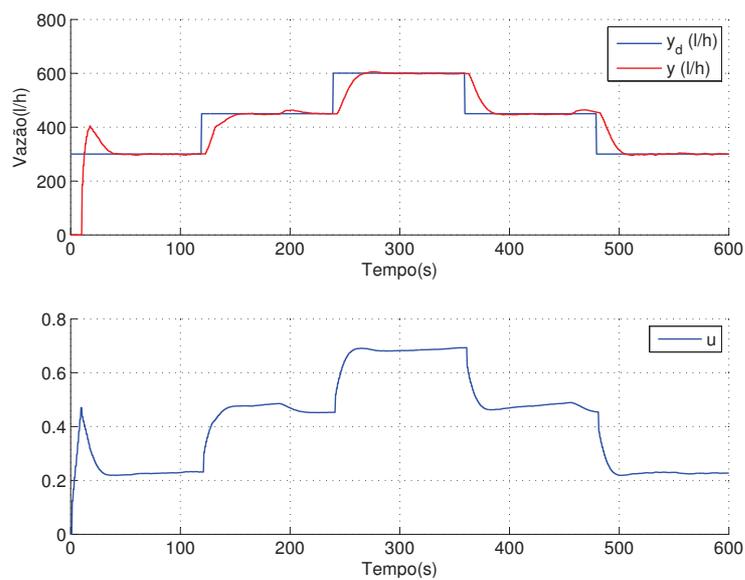
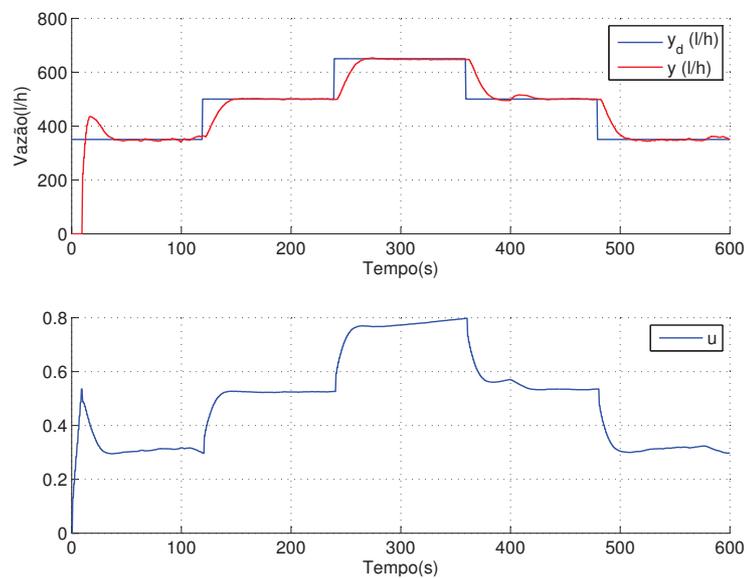
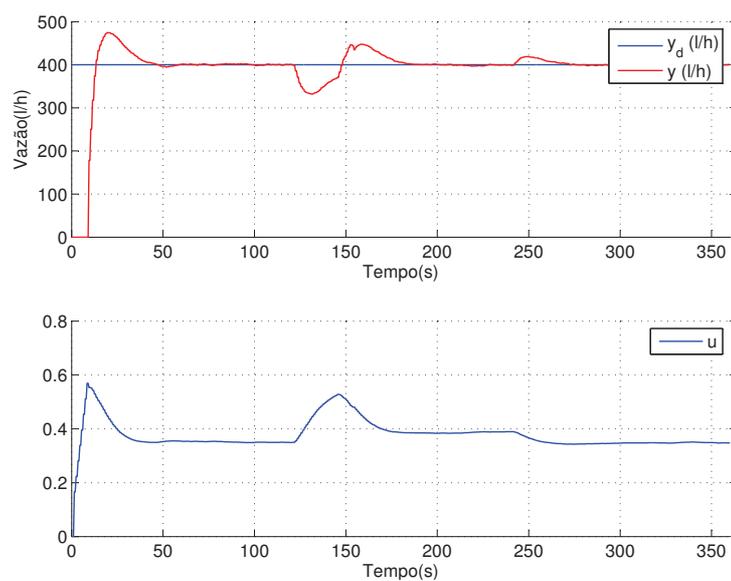


Figura A.68: Experimento 2 - Controlador PI - Valores de y_d , y e u .

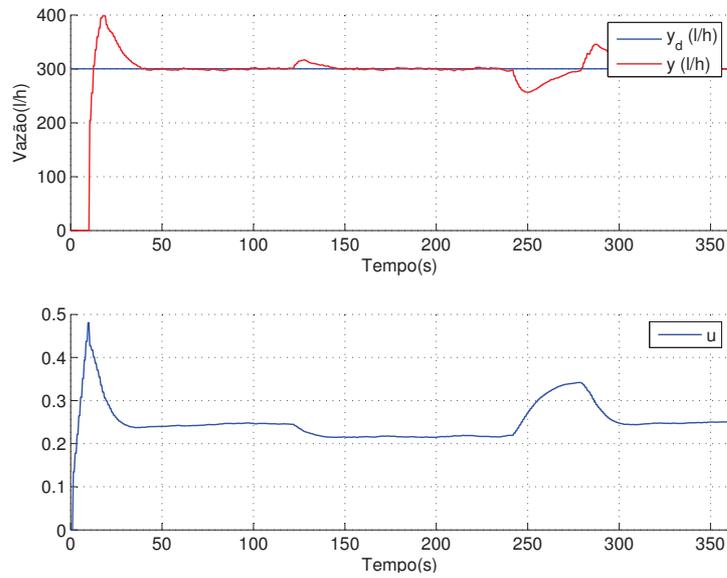
c) Experimento 3

Figura A.69: Experimento 3 - Controlador PI - Valores de y_d , y e u .

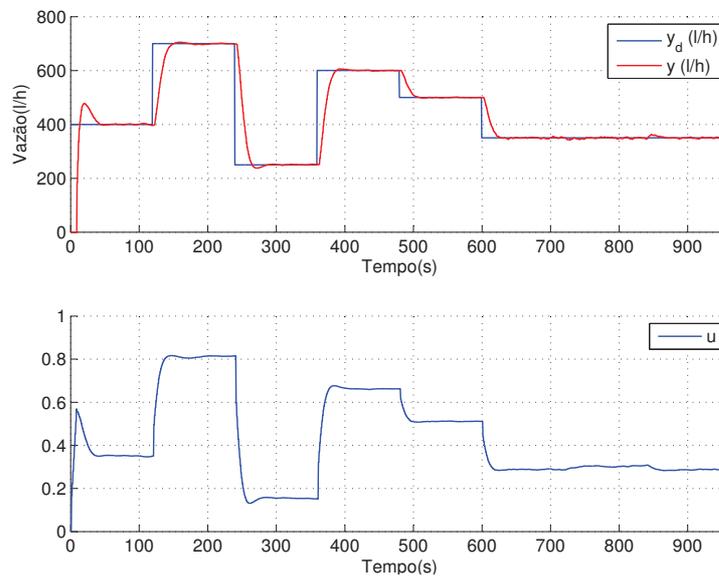
d) Experimento 4

Figura A.70: Experimento 4 - Controlador PI - Valores de y_d , y e u .

e) Experimento 5

Figura A.71: Experimento 5 - Controlador PI - Valores de y_d , y e u .

f) Experimento 6

Figura A.72: Experimento 6 - Controlador PI - Valores de y_d , y e u .

