

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS GRADUAÇÃO DE ENGENHARIA ELÉTRICA

METODOLOGIAS DE SINTONIA ONLINE E ÓTIMA PARA CONTROLADORES
COM AÇÕES PID BASEADAS EM MODELOS NEURO-FUZZY E GUIADAS POR
DADOS DE SENSORES (DATA-DRIVEN ÓTIMA)

JOSÉ PINHEIRO DE MOURA

SÃO LUÍS - MA
2019

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS GRADUAÇÃO DE ENGENHARIA ELÉTRICA

**METODOLOGIAS DE SINTONIA ONLINE E ÓTIMA PARA CONTROLADORES
COM AÇÕES PID BASEADAS EM MODELOS NEURO-FUZZY E GUIADAS POR
DADOS DE SENSORES (DATA-DRIVEN ÓTIMA)**

JOSÉ PINHEIRO DE MOURA

Tese de Doutorado submetida à coordenação do Programa de Pós-Graduação em Engenharia Elétrica da UFMA como parte dos requisitos necessários para obtenção do grau de Doutor em Engenharia Elétrica na área de Automação e Controle.

SÃO LUÍS - MA
2019

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Moura, José Pinheiro de.

METODOLOGIAS DE SINTONIA ONLINE E ÓTIMA PARA
CONTROLADORES COM AÇÕES PID BASEADAS EM MODELOS NEURO-
FUZZY E GUIADAS POR DADOS DE SENSORES DATA-DRIVEN ÓTIMA. :
Modelos de Sintonia Online para Sistemas MBC e DDC de
Processos Industriais / José Pinheiro de Moura. - 2019.
246 f.

Orientador(a): João Viana da Fonseca Neto.

Tese (Doutorado) - Programa de Pós-graduação em
Engenharia de Eletricidade/ccet, Universidade Federal do
Maranhão, UFMA, São Luís-MA, Brasil, 2019.

1. Controladores Lógicos Programáveis. 2.
Controladores PID. 3. Programação Dinâmica Adaptativa. 4.
Regulador Linear Quadrático. 5. Sintonia Ótima. I.
Fonseca Neto, João Viana da. II. Título.

**METODOLOGIAS DE SINTONIA ONLINE E ÓTIMA PARA
CONTROLADORES COM AÇÕES PID BASEADAS EM MODELOS
NEURO-FUZZY E GUIADAS POR DADOS DE SENSORES (DATA-DRIVEN
ÓTIMA)**

JOSÉ PINHEIRO DE MOURA

Tese de Doutorado submetida em Março de 2019

Prof. João Viana da Fonseca Neto, Dr
Orientador

Prof. Anselmo Cardoso de Paiva, Dr
Membro da Banca Examinadora

Prof. Ginalber Luiz de Oliveira Serra, Dr
Membro da Banca Examinadora

Prof. Walter Barra Júnior, Dr
Membro da Banca Examinadora

Prof. Fabrício Gonzalez Nogueira, Dr
Membro da Banca Examinadora

SÃO LUÍS - MA
2019

"Sonho que se sonha sem luta, é só um sonho. Mas, sonho que se sonha com luta é realidade."(Adaptação da frase de Raul Seixas)

Agradecimentos

A DEUS pelo dom da vida e da sabedoria.

Ao Professor Dr. João Viana da Fonseca Neto, meu grande exemplo. Para mim, é uma imensa honra e orgulho tê-lo como orientador, desde o mestrado. Por ter acreditado em mim e por ter dedicado parte do seu tempo nos ensinamentos em sala de aula e nas orientações muito valiosas. Não esqueço seus eternos e valiosos ensinamentos, seus preciosos conselhos e sua inestimável confiança na elaboração deste trabalho. MUITO OBRIGADO PROFESSOR!

Em memórias póstumas dos meus pais Salomão Pinheiro de Moura e Eli Vieira Pinheiro

A minha esposa Rosa, minha filha Nara Eli e seu esposo Marcel, meu filho José Pinheiro Júnior e sua esposa Andrea, ao meu filho Breno, minha sobrinha Osinete e seu esposo Thiago pela paciência, compreensão e incentivos em uma etapa muito importante da minha vida.

Aos meus irmãos Alzinete Pinheiro, Elinete Pinheiro, Raimundo Pinheiro, Luzinete Pinheiro, Rosinete Pinheiro e Josinete Pinheiro pela força e entusiasmo a mim dedicado.

A professora Dra. Patrícia Helena Moraes Rego pelo grande empenho, ênfase a sua participação com grande relevância no que tange a discussão da pesquisa científica.

Ao Professor Dr. Ginalber Luiz de Oliveira Serra, ao Professor Dr. Alan Kardec, Professor Dr. Sofiane Labidi e em memória póstuma ao professor Dr. Marcelo Lira pelos ensinamentos que contribuíram para a construção do meu conhecimento.

Aos meus colegas de trabalho da Vale, UEMA e SEDUC-MA por suas valiosas contribuições na busca deste sonho intelectual, profissional e pessoal.

Aos meus colegas da Universidade Estadual do Maranhão (UEMA) pelo incentivo à pesquisa, aos meus colegas de laboratórios (LCP e LABSECI) que contribuíram para realização deste trabalho e ao Alcides pelo apoio administrativo na secretaria da PPGEE.

A Vale S.A., que além de dar-me essa oportunidade, incentiva o desenvolvimento profissional e intelectual de seus empregados e por disponibilizar recursos nos testes e validação das pesquisas desta tese.

"Se eu cheguei aonde estou, é porque apoiei-me em ombros de gigantes."(Adaptação da frase de Isaac Newton)

Resumo

A sintonia *online* e ótima de controles de processos industriais é uma atividade que requer o desenvolvimento de *hardware* e *software* dedicados para a atividade de ajustes de parâmetros de controladores em plantas industriais, que auxiliam no alcance das metas a serem atingidas em um espaço de tempo relativamente pequeno contribuindo com a evolução tecnológica da indústria 4.0, que conduzem a uma sintonia autônoma dos processos industriais. No sentido de dar suporte para a sintonia de sistemas de controle que seguem abordagens de projeto dos tipos: *model-base control* (MBC) ou *data-driven control* (DDC), são metodologias propostas para sintonia *online* e ótima para controladores PID que são baseadas em modelos *Neuro-Fuzzy* e guiadas por dados de sensores. Nesta Tese de Doutorado apresenta-se metodologias inovadoras para controle de processos operacionais de sistemas industriais com aplicação em equipamentos do setor de mineração para serem embarcados em controladores lógicos programáveis (CLP). Para melhor entedimento, esta Tese está dividida em duas partes, onde na **Parte I** - faz-se a descrição geral do processo industrial, abordando-se cada uma das fases do processo e uma breve introdução sobre controladores lógicos programáveis. Apresenta-se o referencial teórico das ações proporcionais, integrais e derivativas (PID), programação dinâmica adaptativa (PDA) e inteligência computacional (IC) para o embasamento teórico, formulação e solução de problemas apresentados nesta Tese. Por fim, é apresentada a metodologia proposta. Já na **Parte II** - apresenta-se os modelos de sintonia *online* e ótima MBC e DDC de processos industriais em duas abordagens, sendo: **a) Dependente de modelos da planta** - representado em espaços de estado e funções de transferências (FTs), concebidos com dados reais dos processos para ajuste automático de ganhos de controladores PID. Este ajuste é feito da seguinte forma, no primeiro momento, os ganhos ótimos do controlador PID são determinados *offline* por meio de uma rede neuronal artificial estruturada (RNA-E) e em seguida, um sistema baseado em regras *fuzzy* é usado para fazer o ajuste dos ganhos por meio de um esquema de escalonamento *online* desse vetor de ganhos. No segundo momento, os ganhos ótimos do controlador PID são determinados *online* por meio de uma RNA-E do tipo *feed-forward* com algoritmos de treinamento com baixa complexidade computacional e algoritmos baseados em regulador linear quadrático (RLQ) com alto desempenho e **b) Independente de modelos da planta** - levando-se em conta, somente os sinais dos estados de entradas/saídas da planta medidos por sensores. Ainda neste contexto, apresenta-se uma metodologia de sintonia ótima de controladores com ganhos autoajustáveis por controle com base em RLQ (tempo contínuo/tempo discreto), em PDA, especificamente a programação dinâmica heurística aproximada/adaptativa dependente de ação (PDHADA) que foi aplicada nos experimentos apresentados nesta Tese.

Keywords: Controladores Lógicos Programáveis. Controladores PID. Programação Dinâmica Adaptativa. Regulador Linear Quadrático. Sintonia Ótima.

Abstract

Optimal online tuning of industrial process controls is an activity that requires the development of dedicated hardware and software for controller parameter setting activity in manufacturing plants that assist in achieving the goals to be achieved in a relatively short time, contributing to the technological evolution of industry 4.0, which lead to an autonomous tuning of industrial processes. In order to support tuning of control systems that follow design approaches such as model-based control (MBC) or data-driven control (DDC), proposed methodologies for online tuning for model-based PID controllers are: Neuro-Fuzzy and guided by sensor data. This Doctoral Thesis presents innovative methodologies for controlling the operational processes of industrial systems with application in mining sector equipment to be embedded in Programmable Logic Controllers (PLC). For better understanding, this Thesis is divided into two parts, where **Part I** - gives an overview of the industrial process, addressing each of the process phases and a brief introduction to programmable logic controllers. The theoretical framework of proportional, integral and derivative actions (PID), Adaptive Dynamic Programming (ADP) and Computational Intelligence (CI) are presented for the theoretical basis, formulation and problem solving presented in this Thesis. Finally, the proposed methodology is presented. Already in the textbf Part II - we present the Tuning Models Online MBC and DDC of Industrial Processes in two approaches, being: **a) Plant model dependent** - represented in state spaces and transfer functions, designed with real process data for automatic adjustment of PID controller gains. This adjustment is made as follows: at first, optimal PID controller gains are determined offline through a structured artificial neural network and then a fuzzy rules-based system is used to adjust earnings through a scaling scheme online of this gains vector. In the second moment, the optimal PID controller gains are determined online through a structured feed-forward artificial neural network with low computational complexity training algorithms and high performance RLS algorithms and **b) Independent of plant models** - taking into account only sensor input/output state signals measured by sensors. Also in this context, an optimal tuning methodology for self-adjusting gain controllers based on Quadratic Linear Regulator (RLQ) (continuous time / discrete time) is presented in Approximate Dynamic Programming (PDA), specifically Action-Dependent Adaptive Heuristic Dynamic Programming (AD-AHDP) has been applied to the experiments presented in this Thesis.

Keywords: Programmable Logic Controllers. PID Controllers. Adaptive Dynamic Programming. Linear Quadratic Regulator. Optimal Tuning.

Lista de Figuras

Figura 1 – Processo de operação.	11
Figura 2 – Vista aérea do Terminal Portuário Ponta da Madeira (TPPM).	12
Figura 3 – Virador de vagões.	13
Figura 4 – Silos.	13
Figura 5 – Empilhadeira.	14
Figura 6 – Empilhamento em <i>chevron</i>	14
Figura 7 – Empilhamento em <i>windrow</i>	15
Figura 8 – Empilhamento em <i>conevron</i>	15
Figura 9 – Representação gráfica das rotas do processo de descarga e estocagem de minério de ferro	16
Figura 10 – Retomadora de minério	17
Figura 11 – Carregador de navios.	18
Figura 12 – Representação gráfica das rotas do processo de retomada de minério de ferro e embarque de navios.	19
Figura 13 – Painel de relés.	20
Figura 14 – Controlador lógico programável.	20
Figura 15 – Topologia da RNA-E adaptada para o sistema de controle do processo de retomada de granéis sólidos por RP	33
Figura 16 – Estimação do modelo da planta retomadora de minério	37
Figura 17 – Planta em espaço de estado representada em diagrama de blocos.	38
Figura 18 – Fluxo de identificação de modelos	39
Figura 19 – Processo de retomada de granéis sólidos por RP.	40
Figura 20 – Diagrama de blocos canônico do sistema de controle em malha fechada	47
Figura 21 – Planta I	51
Figura 22 – Diagrama de blocos da Planta - I.	52
Figura 23 – Planta II.	52
Figura 24 – Diagrama de blocos da Planta - II.	53
Figura 25 – Planta III.	53
Figura 26 – Diagrama de blocos da Planta - III.	54
Figura 27 – Planta IV.	55
Figura 28 – Diagrama de blocos da Planta - IV.	55
Figura 29 – Planta V.	56
Figura 30 – Diagrama de blocos da Planta - V.	56
Figura 31 – Planta VI.	57
Figura 32 – Diagrama de blocos da Planta - VI.	58
Figura 33 – Planta VII.	59

Figura 34 – Diagrama de blocos da Planta - VII.	59
Figura 35 – Arquitetura de RNA-E para resolver um sistema de equação K^{pid}	65
Figura 36 – Arquitetura de RNA-E para o algoritmo conjugado na solução um sistema de equação K^{pids}	75
Figura 37 – Arquitetura do controlador PID-RNA e unidade treinamento.	76
Figura 38 – Configuração da RNA-E para a recuperação de perturbações paramétricas	76
Figura 39 – Resposta ao degrau unitário do sistema de controle com o PID_{Ref} e o comportamento da planta.	80
Figura 40 – Comportamento dos ganhos do gradiente do erro $\nabla \varepsilon(K^{pid})$ com o comportamento dos ganhos do erro $e(K^{pid})$	84
Figura 41 – Resposta ao degrau unitário do controlador PID_{RNA-E} para o $e(K^{pid})$ e para $\nabla \varepsilon(K^{pid})$ em comparação com o controlador PID_{Ref}	85
Figura 42 – Resposta ao degrau unitário para o PID_{RNA-E} da situação S_0 em que os parâmetros a_i^s são especificados x resposta ao degrau unitário para o PID_{RNA-E} de 4 situações em que os parâmetros a_i^s foram alterados e depois recuperados pelo algoritmo RNA-E x resposta ao degrau unitário do controlador PID_{Ref}	89
Figura 43 – Topologia do controlador PID-Neuro-Fuzzy.	91
Figura 44 – Fluxo de carga do AL até a pilha no pátio de estocagem.	93
Figura 45 – Arranjo mecânico de uma RP.	93
Figura 46 – Planta - I.	95
Figura 47 – Planta I com os controladores.	95
Figura 48 – Comportamento da Planta - II.	96
Figura 49 – Planta II com os controladores.	96
Figura 50 – Planta - III em malha aberta.	97
Figura 51 – Plant III com os controladores.	97
Figura 52 – Comportamento da Planta - IV.	98
Figura 53 – Plant IV com os controladores.	98
Figura 54 – Comportamento da Planta - V.	99
Figura 55 – Plant V com os controladores.	99
Figura 56 – Comportamento da Planta - VI.	100
Figura 57 – Plant VI com os controladores.	100
Figura 58 – Comportamento da Planta - VII.	101
Figura 59 – Plant VII com os controladores.	101
Figura 60 – Plant I - com sinal de 50% de perturbação na planta.	102
Figura 61 – Plant I - com sinal de 100% de perturbação na planta.	102
Figura 62 – Plant II - com sinal de 50% de perturbação na planta.	103
Figura 63 – Plant II - com sinal de 100% de perturbação na planta.	103
Figura 64 – Plant III - com sinal de 50% de perturbação na planta.	104
Figura 65 – Plant III - com sinal de 100% de perturbação na planta.	104

Figura 66 – Plant IV - com sinal de 50% de perturbação na planta.	105
Figura 67 – Plant IV - com sinal de 100% de perturbação na planta.	105
Figura 68 – Plant V - com sinal de 50% de perturbação na planta.	106
Figura 69 – Plant V - com sinal de 100% de perturbação na planta.	106
Figura 70 – Plant VI - com sinal de 50% de perturbação na planta.	107
Figura 71 – Plant VI - com sinal de 100% de perturbação na planta.	107
Figura 72 – Plant VII - com sinal de 50% de perturbação na planta.	108
Figura 73 – Plant VII - com sinal de 100% de perturbação na planta.	108
Figura 74 – Retomadora - em destaque a roda de caçambas.	110
Figura 75 – Diagrama de blocos do processo de retomada de minério.	111
Figura 76 – Fluxograma do processo de retomada.	112
Figura 77 – Fluxo de uma retomada de uma pilha.	113
Figura 78 – Comportamento da corrente elétrica do motor da RC x vazão de minério durante a retomada nas cinco camadas iniciais de uma pilha.	114
Figura 79 – Sistema de controle com aprendizado de crítico aplicado ao processo opera- cional de RP.	119
Figura 80 – Blocos de algoritmo.	121
Figura 81 – Comportamento de convergência dos parâmetros θ_1 , θ_2 e θ_3 para o processo operacional da RP.	125
Figura 82 – Comportamento de convergência dos parâmetros θ_4 , θ_5 e θ_6 para o processo operacional da RP.	126
Figura 83 – Comportamento de convergência dos parâmetros θ_7 , θ_8 e θ_9 para o processo operacional da RP.	126
Figura 84 – Comportamento de convergência dos parâmetros θ_{10} , θ_{11} e θ_{12} para o processo operacional da RP.	127
Figura 85 – Comportamento de convergência dos parâmetros θ_{13} , θ_{14} e θ_{15} para o processo operacional da RP.	127
Figura 86 – Trajetórias dos estados e do erro do sistema com atualização durante o experimento para o processo operacional da RP.	128
Figura 87 – Sinal de controle com ruído para o processo operacional da RP.	129
Figura 88 – O comportamento do traço da matriz H e os autovalores associados com o modelo de malha fechada.	130
Figura 89 – Ganhos do controlador ADHDP-DLQR-IA para o processo operacional do RP.	131
Figura 90 – Comportamento de convergência dos parâmetros θ_1 , θ_2 e θ_3 com sinal de perturbação na planta para o processo operacional da RP.	132
Figura 91 – Comportamento de convergência dos parâmetros θ_4 , θ_5 e θ_6 com sinal de perturbação na planta para o processo operacional da RP.	132
Figura 92 – Comportamento de convergência dos parâmetros θ_7 , θ_8 e θ_9 com sinal de perturbação na planta para o processo operacional da RP.	133

Figura 93 – Comportamento de convergência dos parâmetros θ_{10} , θ_{11} e θ_{12} com sinal de perturbação na planta para o processo operacional da RP.	133
Figura 94 – Comportamento de convergência dos parâmetros θ_{13} , θ_{14} e θ_{15} com sinal de perturbação na planta para o processo operacional da RP.	134
Figura 95 – Ganhos do controlador DLQR baseado em PDHDA com sinal de perturbação na planta para o processo operacional RP.	134
Figura 96 – Resposta ao degrau - Algoritmo ADHDP-DLQR-AI x PID-Fuzy x PID-ZN x SMC x Modelo de planta.	135
Figura 97 – Resposta ao impulso - Algoritmo ADHDP-DLQR-AI x PID-Fuzzy x SMC x Modelo de planta.	136
Figura 98 – Diagrama de blocos do processo de retomada de minério.	150
Figura 99 – Grafcet em nível descritivo do processo de retomada de minério	151
Figura 100–Resposta ao degrau unitário x resposta ao impulso do modelo da planta em malha aberta	152
Figura 101–Resposta ao degrau unitário das FTs representadas pelas Eq. (160) x Eqs. (165, 167 e 169).	156
Figura 102–Resposta ao impulso das FTs representadas pelas Eqs. (160) x Eqs. (165, 167 e 169).	157
Figura 103–Resposta ao degrau unitário das FTs representadas pelas Eq. (160) x Eqs. (171, 173 e 175).	159
Figura 104–Resposta ao impulso das FTs representadas pelas Eq. (160) x Eqs. (171, 173 e 175).	160
Figura 105–Resposta ao degrau das FTs representadas pelas Eq. (160) x Eqs. (177, 179 e 181).	162
Figura 106–Resposta ao impulso das FTs representadas pelas Eq. (160) x Eqs. (177, 179 e 181).	163
Figura 107–Resposta ao degrau das FTs representadas pelas Eq. (160) x Eqs. (183, 185 e 187).	165
Figura 108–Resposta ao impulso das FTs representadas pelas Eq. (160) x Eqs. (183, 185 e 187).	166
Figura 109–Controlador PID da planta representada pela Eq. (165) x Eq. (188).	167
Figura 110–Controlador PID da planta representada pela Eq. (167) x Eq. (189).	168
Figura 111–Controlador PID da planta representada pela Eq. (169) x Eq. (190).	169
Figura 112–Controlador PID da planta representada pela Eq. (171) x Eq. (191).	170
Figura 113–Controlador PID da planta representada pela Eq. (173) x Eq. (192).	170
Figura 114–Controlador PID da planta representada pela Eq. (175) x Eq. (193).	171
Figura 115–Controlador PID da planta representada pela Eq. (177) x Eq. (194).	172
Figura 116–Controlador PID da planta representada pela Eq. (179) x Eq. (195).	173
Figura 117–Controlador PID da planta representada pela Eq. (181) x Eq. (196).	174

Figura 118–Controlador PID da planta representada pela Eq. (183) x Eq. (197).	175
Figura 119–Controlador PID da planta representada pela Eq. (185) x Eq. (198).	176
Figura 120–Controlador PID da planta representada pela Eq. (187) x Eq. (199).	177

Lista de Tabelas

Tabela 1 – Zero e o Pólos da Planta - I.	51
Tabela 2 – Zero e pólos da Planta - II.	52
Tabela 3 – Zeros e pólos da Planta - III.	54
Tabela 4 – Zeros e os pólos da Planta - IV.	55
Tabela 5 – Zeros e os pólos da Planta - V.	57
Tabela 6 – Zeros e os pólos da Planta - VI.	58
Tabela 7 – Zeros e os pólos da Planta - VII.	60
Tabela 8 – Figuras de mérito com RNA-E para alocação de pólos.	82
Tabela 9 – Ganhos PID para variações na taxa de aprendizado.	83
Tabela 10 – Condições iniciais para sintonia do PID_{RNA-E}	83
Tabela 11 – Pólos especificados para alocação.	85
Tabela 12 – Pólos alocado pelo PID_{RNA-E}	86
Tabela 13 – Zeros depois da alocação de pólos pelo PID_{RNA-E}	86
Tabela 14 – Coeficientes com perturbações para S_1 , S_2 e S_3 da função de transferência da Planta em malha aberta.	87
Tabela 15 – Coeficientes a_i da função de transferência da planta em malha aberta.	88
Tabela 16 – Coeficientes do polinômio característico para variações paramétricas na planta.	88
Tabela 17 – Ganhos da recuperação K^{pid} para variações nos parâmetros especificados a_i^s via algoritmo RNA-E.	88
Tabela 18 – Método usados para determinar os ganhos dos controladores propostos.	92
Tabela 19 – Parâmetros dos controladores PID-Neuro-Fuzzy, PID-Fuzzy e PID-ZN.	92
Tabela 20 – Comportamento de fluxo em toneladas por hora (t/h) da camada L_{11} no passo (S) de 1 ate 12 (S_1 até S_{12}).	114
Tabela 21 – Receptividades (entradas).	152
Tabela 22 – Situações Possíveis	154
Tabela 23 – Situação 1 do caso 1	154
Tabela 24 – Situação 2 do caso 1	155
Tabela 25 – Situação 3 do caso 1	155
Tabela 26 – Situação 1 do caso 2	157
Tabela 27 – Situação 2 do caso 2	158
Tabela 28 – Situação 3 do caso 2	158
Tabela 29 – Situação 1 do caso 3	160
Tabela 30 – Situação 2 do caso 3	161
Tabela 31 – Situação 3 do caso 3	161
Tabela 32 – Situação 1 do caso 4	163
Tabela 33 – Situação 2 do caso 4	164

Tabela 34 – Situação 3 do caso 4	164
--	-----

Lista de Abreviaturas e Siglas

RLQ	Regulador Linear Quadrático
RLQD	Regulador Linear Quadrático Discreto
CLP	Controlador Lógico Programável
IEC	<i>International Electrotechnical Commission</i>
PD	Programação Dinâmica
PDA	Programação Dinâmica Aproximada/Adaptativa
PDH	Programação Dinâmica Heurística
PDHD	Programação Dinâmica Heurística Dual
PDHDA	Programação Dinâmica Heurística Dependente de Ação
PDHDDA	Programação Dinâmica Heurística Dual Dependente de Ação
PDHADA	Programação Dinâmica Heurística Aproximada/Adaptativa Dependente de Ação
IHM	Interface Homem Máquina
PID	Proporcionais Integrativos e Derivativos
IC	Inteligência Computacional
LF	Lógica <i>Fuzzy</i>
RNs	Redes Neurais
AGs	Algoritmos Genéticos
PI	Proporcional e Integral

PHD	Programação Heurística Dual
HJB	Hamilton-Jacobi-Bellman
TP	Terminal Portuário
TPPM	Terminal Portuário Ponta da Madeira
VVs	Virador de Vagões
CTs	Correias Transportadoras
EPs	Empilhadeiras de Minério
ERs	Empilhadeiras/Retomadoras de Minério
CTs	Correias Transportadoras
RPs	Recuperadora
CNs	Carregadores de Navios
RC	Roda de Caçambas
CCO	Centro de Controle Operacional
EDOs	Equações Diferenciais Ordinárias
FCC	Forma Canônica Controlável
MBC	<i>Model Based Control</i>
DDC	<i>Data Driven Control</i>

Sumário

1 – INTRODUÇÃO	1
1.1 Motivação	3
1.2 Objetivo Geral	4
1.2.1 Objetivos Específicos	4
1.3 Relevância	5
1.4 Contribuição	5
1.5 Estado da Arte	5
1.6 Organização da Tese	7
 I Processos Industriais, Referencial Teórico e Metodologia para Sintonia Online de Ganhos das Ações PID	 10
2 – Descrição do Sistema Industrial	11
2.1 Processo Operacional do Sistema	12
2.2 Processo de Descarregamento de Vagões	13
2.3 Processo de Empilhamento	13
2.4 Pátios de Estocagens de Granéis	15
2.5 Processo de Retomada de Granéis Sólidos	16
2.6 Sistema de Embarque	17
2.7 Controladores Lógicos Programáveis	19
 3 – Referencial Teórico das Ações PID, PDA e IC	 21
3.1 Ações de Controle PID	21
3.1.1 Controlador PID	21
3.1.2 Controle Ótimo	22
3.1.3 Regulador Linear Quadrático - RLQ	23
3.1.4 Regulador Linear Quadrático em Tempo Discreto - RLQD	24
3.2 Programação Dinâmica Adaptativa - PDA	25
3.2.1 Equações de Bellman	25
3.2.2 Programação Dinâmica Heurística - PDH	27
3.2.3 Programação Dinâmica Heurística Dual - PDHD	28
3.2.4 Programação Dinâmica Heurística Dependente de Ação - PDHDA	28
3.2.5 Programação Dinâmica Heurística Dual Dependente de Ação - PDHDDA	29
3.3 Inteligência Computacional - IC	30
3.3.1 Redes Neurais Artificiais Estruturadas - RNA-E	30

3.3.2	Lógica Fuzzy - LF	33
3.3.2.1	Conjuntos Fuzzy	34
3.3.2.2	Variáveis Linguísticas	35
4	Metodologia Proposta	36
4.1	Planta Processo de Retomada de Granéis por RP	37
II	Modelos de Sintonia Online para Sistemas MBC e DDC de Processos Industriais	41
5	Formulação da Sintonia Online das Ações PID Baseada em Modelos	42
5.1	Sintonia Online de Controladores PID Baseada em Inteligência Computacional	42
5.2	Modelo Geral da Planta	44
5.3	Modelo do Controlador PID	46
5.3.1	Função de Transferência de Malha Fechada	46
5.4	Sintonia Online de Controladores PID	47
5.4.1	Propagação da Ação K^{pid}	47
5.4.1.1	Polinômio Característico da Planta ($P_p^{MF}(s)$)	48
5.4.1.2	Matriz de Propagação	49
5.5	Formulação do Problema Proposto	50
5.6	Modelos das Plantas	50
5.6.1	Planta I	51
5.6.2	Planta II	52
5.6.3	Planta III	53
5.6.4	Planta IV	54
5.6.5	Planta V	56
5.6.6	Planta VI	57
5.6.7	Planta VII	58
6	Sintonia Inteligente de Controladores PID Baseada em Modelo	61
6.1	RNA-E para Sintonia Online e Ótima de Controladores PID	61
6.1.1	Algoritmos de Treinamentos	63
6.1.2	Formulação da RNA-E	64
6.1.3	Algoritmo RNA-E	65
6.1.3.1	Modulo 5 - Algoritmo de Treinamento do K^{pid} Ótimo	69
6.1.3.2	Modulo 6 - Algoritmo de Transferência de Ganhos	70
6.1.3.3	Algoritmo de perturbação paramétrica K_{PID}	72
6.1.4	Algoritmo do Gradiente do Erro	72
6.1.5	Algoritmo de Compensação Paramétrica Adaptativa de Projeto	75
6.1.6	Estudos de Casos	78

6.1.7	Experimentos Computacionais	78
6.1.7.1	Procedimento de Avaliação	78
6.1.8	Estudo de Caso 1	79
6.1.9	Estudo de Caso 2	80
6.1.10	Estudo de Caso 3	85
6.1.11	Estudo de Caso 4	86
6.1.12	Considerações Gerais	89
6.2	Modelo PID-Neuro-Fuzzy	90
6.2.1	Simulações	91
6.2.2	Avaliação dos Resultados	94
6.2.3	Setup	94
6.2.4	Seguidor de Referência	94
6.2.5	Rejeição a Perturbações	101
7	Sintonia Ótima de Controladores Independente de Modelos	109
7.1	Projeto do Controlador ADHDP-DLQR-IA para Processos Operacionais de RP de Caçambas	109
7.1.1	Processo de Retomada de Minério	110
7.1.2	Caracterização do Problema	111
7.1.3	Q-Learning	115
7.1.4	DLQR com Base em Sensores	116
7.1.4.1	Parametrização DLQR	116
7.1.5	Projeto de Controle Online e Ótimo	118
7.1.5.1	Formulação do Problema ADHDP-DLQR-IA	118
7.1.5.2	Algoritmo ADHDP-DLQR-IA	120
7.1.6	Resultados de Simulações	123
7.1.7	Setup da Simulação	124
7.1.8	Estimativa da Lei de Controle Ótimo	124
7.1.9	Resultados do Processo de Controle	129
7.1.9.1	Avaliação do Objetivo de Controle	129
7.1.9.2	Avaliação de Rejeição as Perturbações	131
7.1.9.3	Avaliação do método ADHDP-DLQR-IA	135
7.1.10	Considerações Gerais	136
8	CONCLUSÃO	138
8.1	Produção Científica	139
8.2	Trabalhos Futuros	140
	Referências	141
A	Experimentos e Simulações Iniciais	149

A.1	Planta Processo de Retomada de Granéis por RP	149
A.1.1	Diagrama de Blocos do Processo de Retomada de Minério	149
A.1.2	Descrição da Rotina do Processo de Retomada de Minério	150
A.1.3	Criação das Tabelas de Associação	151
A.1.4	Cálculos dos Ganhos do Vetor K^{pid}	153
A.1.4.1	Caso 1 ($s^0 + s^1 + s^2$)	154
A.1.4.2	Caso 2 ($s^1 + s^2 + s^3$)	157
A.1.4.3	Caso 3 ($s^0 + s^1 + s^3$)	160
A.1.4.4	Caso 4 ($s^0 + s^2 + s^3$)	163
A.1.4.5	Sintonia pelo Método de Tentativa e Erro	166
A.1.4.6	Caso 1 ($s^0 + s^1 + s^2$)	166
A.1.4.7	Caso 2 ($s^1 + s^2 + s^3$)	169
A.1.4.8	Caso 3 ($s^0 + s^1 + s^3$)	171
A.1.4.9	Caso 4 ($s^0 + s^2 + s^3$)	174
A.1.4.10	Considerações Gerais	177
A	– Artigos Mais Relevantes Relacionados com o Tema da Tese	178

INTRODUÇÃO

Devido a complexidade operacional dos processos industriais, os sistemas de controles com sintonia *online* ótima impõem ações relevantes para melhorar a produtividade das plantas e reduzir desperdícios. No intuito de viabilizar uma operação otimizada e segura para o ser humano que opera nessas plantas, métodos para sintonia *online* e ótima para controladores com ações proporcionais, integrais e derivativas (PID) baseadas em modelos (*model-based control* - MBC), do tipo equações diferenciais ordinárias no plano-*s* associadas com a fusão *Neuro-Fuzzy*, e guiadas por dados (*data-driven control* - DDC) de sensores ([FREDERIK et al., 2018](#)), em combinação com a programação dinâmica heurística adaptativa dependente de ações (PDHADA) e controle ótimo linear quadrático são apresentadas no intuito de fomentar uma sintonia autônoma de processos industriais.

A operação de equipamentos industriais é feita com operador embarcado ou remotamente de salas de controles. Tanto os modos de operação com operador embarcado quanto à operação remota são feitas por meio de uma interface homem máquina (IHM) ([YOU et al., 2018](#)), que envia os comandos para um controlador lógico programável (CLP), onde a lógica e o sequenciamento da mesma é implementada ([MOURA et al., 2019a](#)). Nesta Tese de Doutorado são apresentados estudos, pesquisas bibliográfica e experimentos computacionais na concepção de modelos para implementação de métodos e técnicas na sintonia *online* e ótima, também é apresentada, uma metodologia de sintonia independente de modelos com base em dados medidos por sensores para sintonia de controladores PID no processo operacional de plantas industriais baseados em inteligência computacional (IC), tais como:

- a) em primeira instância, são desenvolvidos e concebidos métodos de sintonia de controladores PID baseados em modelos matemáticos em espaço de estado e funções de transferências (FTs) das plantas em estudos e
- a) em segunda instância, métodos independentes de modelos com base em PDHADA em tempo real, isto é, baseados nos sinais de estados de entrada e saída das plantas medidos

por sensores (MOURA et al., 2019b).

Nos processos industriais, em especial os de grandes portes, ainda há um tabu no que diz respeito a implementações de técnicas e métodos baseados em programação dinâmica adaptativa (PDA) e IC, tornando-se difícil a implementação de tais técnicas e tais métodos em plantas industriais (MOURA et al., 2019b). O ambiente das futuras empresas será caracterizado por frequentes novas exigências comerciais.

A pressão do tempo de colocação no mercado de forma contínua de seus produtos e serviços com baixo custo e que atenda as especificações de padrões de qualidades exigidas, é necessária a inclusão de novas tecnologias emergentes que estão surgindo com o foco na otimização de processos e da indústria 4.0 (LASI et al., 2014), (LI, 2018) e (XU et al., 2018) com o intuito de torná-los mais competitivos (JAMMES; SMIT, 2005).

Os controladores PID são muito utilizados em processos industriais (LORENZINI et al., 2018), mas na prática, muitas vezes, sintonizados manualmente por meios de procedimentos de tentativa e erro (ZIEGLER; NICHOLS, 1943). Isto faz com que o ajuste do processo seja difícil, ou ineficiente. Em muitas situações os controladores PID são substituídos por controladores proporcionais (P), controladores proporcionais e integrativos (PI) ou controladores proporcionais e derivativos (PD), tendo um ou dois termos do controlador suprimido (ÅSTRÖM; HÄGGLUND, 1995), sacrificando-se o desempenho e eficiência da operação por um processo rápido e mais fácil de ser sintonizado.

Para resolver este problema, diversas técnicas têm sido desenvolvidas para a sintonia de controladores PID (ZIEGLER; NICHOLS, 1942), (ZIEGLER; NICHOLS, 1943) e (ÅSTRÖM et al., 2006). Se o desempenho requerido não é rigoroso, os métodos convencionais de sintonia de controladores PID são suficientes em muitos sistemas de controle industrial (NETO et al., 2013). Porém, devido ao crescimento da concorrência comercial os sistemas estão se tornando estruturas mais complexas de serem controladas e com os requisitos de desempenho mais rigorosos, onde métodos de sintonia mais eficientes são necessários (GAIDHANE et al., 2018). A crescente complexidade dos processos industriais modernos tornou-se difícil projetar sistemas de controle, sendo que a aplicação de procedimentos de controle com ganhos fixos são muitas vezes inadequados. O desenvolvimento do controle adaptativo nas ultimas décadas tem tido um esforço no sentido de estabelecer técnicas de controle capazes de sanar dificuldades como incertezas, perturbações, modelagens e variações paramétricas (NETO; LOPES, 2011).

Os problemas reais têm na, maioria das vezes, incertezas paramétricas, o que dificulta-se a modelagem matemática, no entanto, estudos e pesquisas utilizando técnicas, como a PDA; a lógica *fuzzy* (LF); as redes neurais artificiais (RNA); os algoritmos genéticos (AG) e outras que dispensam esses modelos matemáticos, estão em uso com muita eficiência (WANG et al., 2009) e (MAREN et al., 2014).

O controle operacional de sistemas dinâmicos industriais pode ser feito com operador

embarcado ou remotamente comandados por uma IHM, onde a decisão é tomada com base na *expertise* do próprio operador, a seguir, é fundamentada a motivação para elaboração deste trabalho.

1.1 Motivação

O controle operacional, tanto com operador embarcado quanto remotamente, a decisão é tomada pelo operador que decide com base em suas análises qual a melhor decisão a ser tomada, isso pode acarretar erros, devido os seguintes motivos: falta de atenção; fadiga e imperícia.

Há dificuldades de se controlar plantas industriais, os equipamentos são complexos, com estruturas metálicas de grande porte e é notória a subutilização dos instrumentos tecnológicos disponíveis para diagnosticar e controlar seus funcionamentos, tornado-se altos os custos dos processos operacionais.

Na indústria é comum uso de controladores que utilizam métodos de controle clássico, controle moderno e controle robusto sem se utilizar de técnicas de IC e bio-inspiradas nem modelos matemáticos sofisticados, tais como:

- Técnicas de PDA e aprendizado por reforço (AR);
- Métodos estocásticos;
- Mínimos quadrados;
- Métodos de espaço de *Hilbert*;
- Métodos baseados em IC e
- Outros métodos eficientes.

Com respeito aos critérios adotados e definidos para os objetivos de cada modelo usado. O uso da técnica por si só não é suficiente, no final o controlador projetado pode ser implementado sem mecanismos associados para modificar seu projeto em resposta às mudanças no contexto operacional da planta (REGO, 2014).

Os equipamentos industriais usados na identificação dos modelos apresentados nesta Tese, para a simulação dos experimentos, são equipamentos de grandes portes e manuseiam uma grande quantidade de produtos, o que não permitem erros operacionais, principalmente, aqueles que podem ser evitados (MOURA et al., 2019a) e (MOURA et al., 2019b). Deste ponto de vista e para propósitos gerais, o controle operacional é de interesse comercial das empresas e importante para um bom desempenho do sistema, com isso, pode-se conceber modelos para minimizar os erros operacionais, maximizar a eficiência produtiva e ao mesmo tempo reduzir a depreciação

de elementos do referido sistema. Com isso, tem-se um problema de otimização multiobjetivos: eficiência operacional e redução de custo na produção (MARLER; ARORA, 2004).

Para o controle de processos industriais usando PDA e controle adaptativo em tempo real (BRADTKE, 1994) o ajuste dos parâmetros de controle deve ser feito de acordo com a necessidade do sistema, devido as incertezas dos processos e variações paramétricas das plantas (MOURA et al., 2019b). Este ajuste pode ser feito usando o princípio da otimalidade de *Belman* (BELLMAN; DREYFUS, 1959).

Os processos das plantas industriais apresentados nesta Tese de Doutorado são automatizados com lógicas desenvolvidas e implementadas em CLP, que em sua estrutura, já tem embutido um módulo de programação para controladores PID, sistemas *fuzzy* e um módulo de bloco de funções que pode ser usado para a implementação de técnicas com base em IC e PDA. Diante do que foi exposto, foi a motivação para desenvolver-se metodologias com base em IC e PDA aplicada na solução dos problemas supracitados.

1.2 Objetivo Geral

Apresentar o desenvolvimento de dois métodos para sintonia *online* e ótima de controladores para sistemas industriais é o principal objetivo desta Tese. Os métodos nas abordagens MBC e DDC que são associados com IC e PDA para a tomada de decisão no controle operacional de equipamentos industriais.

1.2.1 Objetivos Específicos

Os objetivos específicos foram elaborados cuidadosamente, de forma que o objetivo geral seja alcançado. A seguir lista-se os principais objetivos específicos desta Tese:

1. Identificar/estimar modelos matemáticos das plantas;
2. Conceber e desenvolver metodologia com base em MBC para sintonia *online* e ótima de controladores PID que baseiam-se em RNA-E e LF;
3. Desenvolver uma metodologia baseada em DDC, onde as ações de controles são determinadas por dados de sensores e aprendizado Q no contexto de PDHADA;
4. Apresentar o resultados das avaliações em modelo de plantas industriais e realizar uma comparação para avaliar o desempenho das metodologias propostas nos itens 2 e 3. Esses resultados são baseados em equações diferenciais ordinárias, IC e PDA.

1.3 Relevância

Com o desenvolvimento produtivo industrial e o aumento da demanda de produção, faz-se necessário a inclusão de novos equipamentos em plantas industriais, mas isso só, não é o bastante, com isso abre caminho para o desenvolvimento e implementações de controladores por: AR; IC/bio-inspirada e PDA. Como também, desenvolver o capital intelectual dos profissionais que atuam na área de mineração, mais precisamente, em operações portuárias com o manuseio de granéis sólidos e introduzir conceitos técnicos, definições científicas aplicadas na área de mineração voltada para a otimização de operação em equipamentos industriais.

1.4 Contribuição

A contribuição da tese consiste no desenvolvimento de algoritmos inteligentes para sintonia *online* e ótima de controladores PID com base em MBC por meio da fusão de técnicas de IC (RNA-E e LF), na criação da matriz de propagação por meio da operação de produto interno entre o vetor de ganhos do controlador com os coeficientes do numerador da FT da planta e na sintonia de controladores com ações PID guiados por dados medidos por sensores DDC e por meio de algoritmos baseados em PDHADA. Além disso, a disseminação de conhecimentos acadêmicos na indústria e a familiarização dos profissionais da academia com problemas reais de plantas industriais da alta complexidade de controle.

1.5 Estado da Arte

As primeiras aplicações de controle com retroalimentação datam do desenvolvimento de mecanismos de controle de nível de líquidos, através de bóias, pelos gregos, por volta de 300 a.C.. Por volta de 250 a.C., o grego *Philon* idealizou uma lâmpada de óleo cujo nível era mantido constante através da utilização de uma bóia. Mais tarde, no século I, *Hero*, de Alexandria, construiu um engenhoso sistema para abertura das portas de um templo, comandado pelo acendimento de uma pira num altar (FACCIN, 2004).

O primeiro sistema inventado na Europa moderna foi o regulador de temperatura de uma incubadora de ovos, puramente mecânico, feito em 1624 por *Cornelis Drebbel*, um mecânico e químico alemão. Em 1681, *Dennis Papin* inventou o primeiro regulador de pressão para caldeiras a vapor, um dispositivo de segurança similar às válvulas de panelas de pressão. Em 1750, *Miekle* inventou um dispositivo para o controle automático da orientação de moinhos de vento (FACCIN, 2004).

O primeiro sistema com retroalimentação oficialmente reconhecido foi reivindicado pela Rússia e atribuído a I. *Polzunov*, em 1765. Trata-se de um sistema mecânico de controle de nível de água de caldeiras através do uso de uma bóia. No entanto, o primeiro controlador com retroalimentação automático utilizado em um processo industrial, é atribuído à *James Watt*, que

de 1769 à 1788 desenvolveu e aprimorou o regulador de esferas, um controlador centrífugo para controle de velocidade de máquinas a vapor (FACCIN, 2004).

A primeira discussão sobre instabilidade em um sistema de controle com retroalimentação é atribuída a *G. B. Airy*, quando, em 1840, ele descobriu que o regulador de esferas de *Watt* apresentava movimentos instáveis. Mas o primeiro estudo sistêmico sobre estabilidade foi feito por *J. C. Maxwell*, em 1868, que descreveu as equações diferenciais que governavam o movimento do regulador de esferas. Com seu trabalho, *Maxwell* demonstrou a importância e a utilidade de modelos e métodos matemáticos para a compreensão dos processos industriais e da própria teoria de controle. Na sequência, *E. J. Routh* (em 1877) e *A. Hurwitz* (em 1885), de forma independente, criaram seus critérios de estabilidade. Mais tarde, em 1896, *A. M. Lyapunov* também desenvolveu seu critério de estabilidade, baseado em equações diferenciais não-lineares de movimento (FACCIN, 2004).

Em 1907, foi instalado pela *C. J. Tagliabue Company*, em Nova Iorque, o primeiro controlador de temperatura pneumático automático (do tipo liga-desliga), em uma unidade de pasteurização de leite. Na sequência, *Edgar H. Bristol*, deu uma grande contribuição no desenvolvimento de sistemas de controle pneumáticos, ao protocolar, em 1914, o pedido da patente de um amplificador bocal-palheta. *N. Minorsky*, em 1922, realizou uma das primeiras aplicações de elementos deliberadamente não-lineares em sistemas a malha fechada em seu estudo de pilotagem automática de navios. Em 1932, ao reunir a transformada de *Laplace* e o princípio do argumento da teoria de *Cauchy*, *H. Nyquist*, da *Bell Telephone Laboratories*, desenvolveu um simples e notável critério de estabilidade de sistemas de malha fechada com base na resposta a entradas senoidais em regime permanente da malha aberta. No período de 1932 a 1942, também na *Bell Telephone Laboratories*, *H. W. Bode* desenvolveu uma das mais úteis técnicas no domínio da frequência para projeto de sistemas de controle (FACCIN, 2004).

Em 1935, *Ralph Clarridge* da *Taylor Instrument Companies* criou o controlador de três termos, ao utilizar um controlador que antecipava a variação no sinal de erro para solucionar um problema de oscilação de uma malha de controle de temperatura em uma indústria de celulose, chamada inicialmente pelos engenheiros da empresa de *pre-act*. Em 1939, uma versão reprojeta do controlador PID *Fulscope* foi oferecida como padrão nos sistemas de controle comerciais da empresa. No mesmo ano, a *Foxboro Instrument Company* lançou o controlador pneumático *Stabilog*, o qual possuía a tecnologia *hyper-reset*, baseada na derivada do sinal de erro (FACCIN, 2004).

Em 1942, por meio do artigo intitulado: "*Optimum Settings for Automatic Controllers*" (ZIEGLER; NICHOLS, 1942) apresentaram dois procedimentos para sintonia dos controladores, utilizando-se simples regras de ajuste baseadas em características dinâmicas do processo, consolidando assim, o uso do controlador PID em processos industriais.

Os controladores PID são extensivamente utilizados em indústria de processo, eletrônica de sistema, pilotos automáticos de aviões e mísseis, navios e robôs industriais (ÅSTRÖM;

HÄGGLUND, 1995) e (KUC; HAN, 2000). Sua popularidade é devida à sua estrutura simples, a ação de avanço e atraso de variáveis controladas, bem como a familiaridade de engenheiros e operadores com algoritmos de sintonia de controladores PID, que é de fácil implementação e atende a muitas necessidades dos sistemas de controle industriais. Apesar da sua popularidade, os controladores PID são na prática, muitas vezes, sintonizados manualmente, por meio, do procedimento de tentativa e erro. Isto faz com que o ajuste do processo seja difícil, ou ineficiente. Em muitas situações os controladores PID são substituídos por controladores PI, onde a parte de ação derivativa é retirada (ÅSTRÖM; HÄGGLUND, 1995), sacrificando o desempenho e eficiência da operação por um processo rápido e fácil de sintonizar. Os métodos convencionais de sintonia de controladores PID são suficientes em muitos sistemas de controle industrial. Porém, devido ao crescimento da concorrência comercial, os sistemas dinâmicos industriais estão se tornando estruturas mais complexas de serem controladas e com os requisitos de desempenho mais rigorosos, onde métodos de sintonia mais eficientes são necessários.

Em meados da década 1950 surgiu a ideia de controladores auto-ajustáveis (*self-tuning*), no artigo intitulado: *Design of a Self Optimizing Control System* (KALMAN, 1958), mas só a partir dos anos 1970, é que os controladores auto-ajustáveis começaram a ter importância em processos industriais, com o aperfeiçoamento das técnicas de identificação, projeto de controladores e avanço dos circuitos digitais (ÅSTRÖM; WITTENMARK, 1973) e (CLARKE; GAWTHROP, 1979). A partir do final da década de 1970 em diante, os controladores PID foram estendidos para processos industriais mais complexos, com isso, houve a necessidade de se desenvolver algoritmos baseados em IC para atender a demanda de controle exigida pela complexidade operacional das plantas industriais.

Nas últimas décadas, métodos convencionais de sintonia de controladores PID são combinados com métodos baseado em técnicas de inteligência artificial (IA), tais como: LF; AG e RNA.

Neste trabalho, apresenta-se metodologias de sintonia para controladores PID baseadas em modelos (MOURA et al., 2019a), usando algoritmos de RNA-E e combinando RNA-E e LF, como também, metodologias de sintonia de controladores com ação integral independentes de modelos com algoritmos desenvolvidos com base em PDHDA para garantir o ponto de operação desejado em função de variações paramétricas dos processos operacionais (MOURA et al., 2019b).

1.6 Organização da Tese

A Tese é organizada em duas partes principais: I) apresenta-se os tópicos que embasam os desenvolvimentos propostos durante a pesquisa em Modelos e Algoritmos para sintonia *online* ótima de parâmetros de sistemas de controle. Apresenta-se tópicos em processos industriais, referencial teórico e metodologia para o desenvolvimento da proposta, tais como: descrição dos

processos operacionais das plantas em estudos; uma breve apresentação do estado da arte para embasamento teórico e formulação matemática dos problemas tratados nesta Tese; experimentos iniciais com dados de uma planta real do processo de descarregamento por viradores de vagões (VVs) e de retomada de granéis sólidos por retomadoras (RP) de caçambas, respectivamente e II) apresenta-se os modelos de sintonia *online* e ótima do tipo **MBC** e **DDC** para processos industriais. Apresenta-se os desenvolvimentos propostos para as duas abordagens:

- 1) **MBC** é dependente de modelos matemáticos da planta, em espaços de estado e FTs, concebidos com dados reais dos processos para ajuste automático de ganhos de controladores PID. Este ajuste é feito da seguinte forma:
 - No primeiro momento, os ganhos ótimos do controlador PID são determinados *offline* por meio de uma RNA-E e em seguida, um sistema fuzzy é usado para fazer o ajuste dos ganhos por meio de um esquema de escalonamento em tempo real;
 - No segundo momento, os ganhos ótimos do controlador PID são determinados em tempo real por meio de uma RNA-E do tipo *feed-forward* com os algoritmos de treinamento com baixa complexidade computacional e algoritmos baseados em regulador linear quadrático (RLQ) de alto desempenho.
- 2) **DDC** é independente de modelos matemáticos, levando-se em conta, somente os sinais dos estados de entradas/saídas da planta medidos por sensores. Ainda neste contexto, apresenta-se uma metodologia de sintonia ótima de controladores com ganhos autoajustáveis por controle com base em RLQ (tempo contínuo/tempo discreto), em PDA e PDHADA.

Especificamente os conteúdos dos capítulos são descritos conforme a sua ocorrência ao longo deste documento. Este é organizado com os seguintes tópicos. A Parte I é dividida em três capítulos que são: Capítulo 2 que descreve o processo industrial.

O referencial teórico apresentado no Capítulo 3 trata a respeito do estado-da-arte e dos conceitos teóricos que viabilizam o desenvolvimento de métodos para o projeto de sintonia *online* e ótima de algoritmos para ajustes de controladores PID. Inicialmente, apresenta-se os CLPs, de uma forma geral, as abordagens de controladores PID e controle ótimo nas suas representações em FT e espaço de estado são basilares para definir o caminho das metodologias MBC e DDC, respectivamente, e os métodos de PDA são apresentados para resolver o problema da sintonia *online* e ótima por meio do aprendizado Q (*Q-learning*) na forma de PDHADA. No Capítulo 4 apresenta a metodologia para sintonia *online* e ótima de ganhos das ações PID.

Os modelos de sintonia *online* e ótima para sistemas MBC e DDC de processos industriais são apresentados em três Capítulos na Parte II desta Tese. No Capítulo 5 apresenta-se a formulação da sintonia *online* e ótima das ações PID baseada em modelos, a planta e o controlador são modelados por equações diferenciais e descritas no plano s aplicando a transformada de Laplace.

A sintonia inteligente baseada em modelo, é apresentada no Capítulo 6, a RNA-E é associada com a LF para o desenvolvimento de métodos para sintonia *online* e ótima de controladores PID. Consequentemente, viabilizando o desenvolvimento do modelo proposto que é chamado de PID-Neuro-Fuzzy.

No Capítulo 7 é apresentado o método para sintonia ótima de controladores independente de modelos, os ganhos do controlador ótimo são sintonizados por meio de PDA. Especificamente, o ajuste *online* do ganhos baseado em PDHADA e RLQ em tempo discreto com ação integral para processos operacionais de retomada de minério. Os desenvolvimentos são implementados para determinar os ganhos ótimos e *online* de controladores com ações PID.

No Capítulo 8 apresenta-se as conclusões, comentários finais, contribuições e produção científica. Ainda neste contexto, apresenta-se as propostas para o desenvolvimento de trabalhos futuros.

E finalmente a Tese constitui-se ainda, de um Apêndice que trata dos experimentos e simulações iniciais e de um anexo com os artigos mais relevantes associados com as principais abordagens expostas apresentadas.

Parte I


Processos Industriais, Referencial Teórico e Metodologia para
Sintonia Online de Ganhos das Ações PID

Capítulo 2

Descrição do Sistema Industrial

Neste capítulo faz-se uma descrição geral do sistema industrial usado na concepção dos modelos das plantas em estudos e dos métodos de sintonia de controladores PID. O produto manuseado na planta é o minério de ferro que é transportado da mina até o terminal portuário (TP) em vagões via ferrovia, estes são descarregados nos VVs e transportados via correias transportadoras (CTs) até as Empilhadeiras (EPs) ou Empilhadeiras Recuperadoras (ERs) que fazem o armazenamento a granel em pátios de estocagem. Do pátio de estocagem o material é retomado por RP ou ERs e transportados via CTs até o embarque de navios por carregadores de navios (CNs). O processo tem a maior parte da automação embarcada em CLPs. A planta é operacionalizada do centro de controle operacional (CCO), este é o local onde são tomadas as decisões, tais como: quais equipamentos serão utilizados na descarga dos vagões e na retomada do minério dos pátios de estocagem para o embarque dos navios e qual pátio o material deve ser estocado. Na Figura 1 está ilustrada uma visão geral de um processo de operação do TP.

Figura 1 – Processo de operação.



A programação de descarga, estocagem, retomada e embarque é feita de forma que se utilize os equipamentos visando o menor custo operacional por tonelada movimentada. Para isso,

é considerado o planejamento de retomada e embarque, de forma que, a carga seja estocada em todos os pátios, levando-se em conta a disponibilidade dos equipamentos.

O conceito de rota é definido como equipamentos de origens, equipamentos intermediários e equipamentos de destinos. Em rotas operacionais de descarga, os VVs são os equipamentos de origens, as CTs os equipamentos intermediários e as EPs ou ERs equipamentos de destinos. Já nas rotas operacionais de embarque, as RPs ou ERs são os equipamentos de origens, as CTs os equipamentos intermediários e os CNs os equipamentos de destino.

A seguir apresenta-se uma descrição geral da planta do TP usado na validação dos estudos e pesquisas desenvolvidas neta Tese de Doutorado. O terminal portuário é constituído das seguintes etapas:

- Processo de descarregamento de vagões;
- Processo de empilhamento;
- Pátios de estocagens de granéis sólidos;
- Processo de retomada de granéis sólidos;
- Sistema de embarque de navios.

2.1 Processo Operacional do Sistema

O sistema industrial utilizado para estudo e validação da metodologia adotada foi o processo operacional do sistema de descarregamento de vagões e retomada de granéis por retomadoras de um TP que manuseia minério de ferro, conforme ilustrado na Figura 2.

Figura 2 – Vista aérea do Terminal Portuário Ponta da Madeira (TPPM).



2.2 Processo de Descarregamento de Vagões

O processo de descarga do TP é constituído dos seguintes equipamentos: VVs; CTs; EPs e ERs. Os (VVs) são equipamentos utilizados na descarga de vagões. Estes são equipamentos giratórios que giram até 180°, cada giro são descarregados dois vagões, os vagões são conjugados, isto é, entre um vagão e outro tem um engate fixo, chamado de barra fixa e nas extremidades de cada par de vagões os engates são móveis, permitindo o giro dos vagões durante a descarga sem ser necessário a desacoplagem dos mesmos, conforme ilustrado na Figura 3. Ao girar, a carga dos vagões é transferida para os silos conforme apresentado na Figura 4.

Figura 3 – Virador de vagões.



Figura 4 – Silos.



2.3 Processo de Empilhamento


O processo de empilhamento consiste em estocar a carga via EP que é o equipamento utilizado para formar pilhas de graneis sólidos. Este equipamento é utilizado no processo de mineração em geral para fazer estoque de minério a granel em pátios a céu aberto. Na Figura 5 está ilustrado uma EP de minério fazendo o estoque em pátio de estocagem a céu aberto.

Figura 5 – Empilhadeira.



A forma de se empilhar minério está associada às características físicas e químicas do mesmo, para isso existem várias formas de se fazer empilhamento de minério, os mais adotados são:


Chevron - Consiste no empilhamento de várias camadas ao longo do mesmo eixo, iniciando com um cordão no centro do pátio e fazendo várias passadas com a EP sobre esse cordão central até atingir o limite de formação da pilha. Este tipo de empilhamento é indicado para formação de pilhas de lotes de minérios com características físicas e químicas diferentes em períodos chuvosos, com isso há uma distribuição mais uniforme dos lotes em toda a pilha e reduz a absorção de umidade por ação da chuva. Na Figura 6 está ilustrado o método de empilhamento *chevron*;

Figura 6 – Empilhamento em *chevron*.

Windrow - consiste no empilhamento de vários prismas paralelos ou “empilhamento em cordões”, inicia-se a pilha com várias cordões na base, em seguida faz-se o recheio entre os cordões da base, na sequência faz-se o recheio dos cordões intermediários e por fim fecha pilha com um cordão no topo da mesma, conforme apresentado na Figura 7 esse tipo de empilhamento, também é indicado para formação de pilhas de lotes de minérios com características físicas e químicas diferentes em períodos secos, a distribuição é muito mais eficaz do que nas pilhas formadas em *chevron*, porém a área de exposição às chuvas é bem maior, como também é mais

complexa a sua formação, visto que, requer uma expertise maior do operador e há esforço maior do equipamento. As Figuras abaixo ilustram o empilhamento em *Windrow*.

Figura 7 – Empilhamento em *windrow*



Conevron ou *Coneshell* - consiste no empilhamento de cones completos com pequenos deslocamentos na translação da EP, a pilha é iniciada no centro do pátio com um cone até atingir a altura de aproximadamente 90% da altura total da pilha, em seguida desloca-se a máquina para frente ou para trás e inicia-se outro cone até atingir a altura aproximadamente 90% da altura total da pilha e assim por diante, depois de todos os cones formados, a pilha estará com 90% de sua altura final e para finalizar a formação da pilha, são dadas algumas passadas ao longo de toda a pilha, deixando-a na forma de uma pirâmide. Na Figura 8 está ilustrado uma pilha em *conevron*.

Figura 8 – Empilhamento em *conevron*




2.4 Pátios de Estocagens de Granéis

Os pátios de estocagens do TP escolhido para testes e validação dos experimentos são constituídos de nove pátios identificados pelas letras: A, B, C, D, E, F, G, H, I. Os pátios tem como função principal armazenar o estoque de granéis de forma distribuída uniforme para garantir um desempenho ótimo, tanto na descarga dos vagões, quanto no embarque de navios. Na Figura 9 estão ilustradas as rotas do sistema de descarregamento e estocagem da planta em estudo. Onde os nós VV1 a VV4 representam os VVs (equipamentos de origens), os nós D1 a D27 representam as CTs do processo de descarregamento (equipamentos intermediários). EP2

até a EP4 e ER1 até ER4 representam as EPs e ERs (equipamento de destinos) e as letras de A até I representam os pátios de estocagem.

Figura 9 – Representação gráfica das rotas do processo de descarga e estocagem de minério de ferro



2.5 Processo de Retomada de Granéis Sólidos

O processo de retomada de minério consiste em retirar o material armazenado em pilhas e transportá-lo por meio de CTs para o embarque de navios. As RPs têm uma capacidade nominal de 8000 t/h, as rotas operacionais, que são compostas por RPs, CTs e CNs têm uma capacidade nominal de transporte de até 16000 t/h, então duas RPs podem fazer a retomada simultânea para uma rota de 16000 t/h ou uma RP para fazer a retomada para uma rota de 8000 t/h (MOURA et al.,). A retomada do minério é feita com equipamentos de grande porte, sua estrutura é constituída de duas partes, uma fixa para o movimento de rotação, permitindo, somente, o o movimento de translação e outra móvel para o movimento de rotação da lança da RP (WILLIAMS et al., 2000). Na parte fixa estão instalados os *trucks* de translação, e na parte móvel a lança e o contrapeso são instalados, na ponta da lança está a roda de caçambas (RC), dispositivo que faz a retomada do minério (LOPES et al., 2012).

A retomada de granéis é feita com equipamentos de grande porte, denominados Recuperadora (Retomadora), Na Figura 10 está a representação de uma retomadora fazendo a retomada de uma pilha de minério.

Figura 10 – Retomadora de minério



O minério retomado das pilhas é transportado para o navio via correias transportadoras, estas formam as rotas operacionais, que são formadas com os seguintes equipamentos: RP; CT e CN.

O custo de tonelada embarcada é feito, desde a retomada até o carregamento do navio, levando-se em conta o custo operacional da rota, ou seja, o custo operacional da retomadora, das correias transportadora e do carregador de navios.

2.6 Sistema de Embarque

O sistema de embarque do TP consiste em retomar o minério de ferro estocado a granel via RPs ou ERs¹, transportar por CTs e fazer o carregamento de navios por CNs. Conforme apresentada na Figura 11.


¹ As ERs são equipamentos usados tanto na descarga quanto no embarque, pois estas podem ser usadas para fazerem a estocagem da carga nos pátios de estocagens como na retomada da carga dos pátios de estocagens.

Figura 11 – Carregador de navios.



As rotas operacionais de retomada e embarque são compostas por RPs ou ERs, CTs e CNs. As RPs ou ERs são utilizadas para fazer a retomada da carga a granel do pátio de estocagem, as CTs são usadas no transporte da carga das RPs ou ERs até os CNs e os CNs são utilizados no carregamento dos navios. Na Figura 12 está ilustrado o sistema de retomada e embarque com os equipamentos e pátios de estocagens, as linhas na cor verde representam os equipamentos com capacidade nominal de 16.000 t/h e as linhas na cor vermelha representam os equipamentos com capacidade nominal de 8.000 t/h. Onde ER1 até ER4 e RP2 até RP4 são as empilhadeira/retomadoras e retomadoras respectivamente (os equipamentos de origens), os nós E1 a E31 são as CTs do processo de embarque (equipamentos intermediários) e CN1 a CN6 são os CNs (equipamentos de destinos).

Figura 12 – Representação gráfica das rotas do processo de retomada de minério de ferro e embarque de navios.



2.7 Controladores Lógicos Programáveis

As plantas apresentadas e usada nos experimentos desta tese são automatizadas e implementadas em CLPs. A automação industrial é uma área de pesquisa que vem ampliando sua atuação gradativamente nos últimos anos. O uso de dispositivos e a aplicação de soluções desenvolvidas em automação industrial tem grande repercussão sobretudo no setor industrial. As aplicações não se resumem em substituir o trabalho humano em tarefas exaustivas, monótonas e perigosas. Elas trazem melhoria na qualidade de processos, otimização dos espaços, redução no tempo de produção e custos.

Existem diversos equipamentos utilizados na automação industrial, porém, o CLP é um dos mais importantes. O CLP surgiu no final da década de 1960 e revolucionou os comandos e controles industriais. Nessa época, a automação era executada quase totalmente por relés com base em lógica fixa, ou lógica *hardwired*, o que resultava em enormes armários de relés eletromecânicos interligados por circuitos elétricos e extensas fiações conforme apresentado na Figura 13.

Figura 13 – Painel de relés.



Com o surgimento dos circuitos integrados, foi possível viabilizar e difundir a utilização do CLP em grande escala, melhorando o poder de processamento e diminuindo o tamanho dos equipamentos. Esse avanço está atrelado, em grande parte, ao desenvolvimento tecnológico dos computadores, até mesmo em sua arquitetura de *hardware* e *software*. O uso de microprocessadores e microcontroladores de última geração e o de arquitetura híbrida, aliados às novas técnicas de processamento paralelo e às redes de comunicação que contribuíram para o sucesso desse equipamento industrial. Na Figura 14 ilustra-se um painel com um CLP industrial e seus periféricos, que substituiu os painéis de relés, onde pode se observar que além de serem mais eficientes que os relés, ocupam menos espaços.

Figura 14 – Controlador lógico programável.



Antes do surgimento dos CLP's, as tarefas de comando e controle de máquinas e processos industriais eram feitas por relés eletromagnéticos, especialmente projetados para este fim. O controle baseado em relés exigia modificações na fiação, no caso de alterações no processo automatizado e em muitos casos isso se tornava inviável, sendo mais barato substituir todo o painel por um novo (MARTINS, 2007).

Capítulo 3

Referencial Teórico das Ações PID, PDA e IC

Em termos de contextualização das abordagens MBC e DDC, as ações de controle PID, PDA e IC são as abordagens que são associados para embasar os desenvolvimentos apresentados nesta tese de doutorado. Enfatiza-se que as ações PID são caracterizadas pelas abordagens MBC e a PDA é caracterizada pelas as abordagens DDC. Este capítulo condensa os fundamentos teóricos e estado-da-arte das referidas abordagens.

3.1 Ações de Controle PID

Ações de controle PID e de controle ótimo do tipo RLQ são apresentadas neste capítulo.

3.1.1 Controlador PID

Os controladores PID são extensivamente utilizados na indústria de processo, eletrônica de sistema, pilotos automáticos de aviões e mísseis, navios e robôs industriais ([ÅSTRÖM; HÄGGLUND, 1995](#)) e ([KUC; HAN, 2000](#)). Sua popularidade é devida à sua estrutura simples e à robustez em muitas aplicações, bem como a familiaridade de engenheiros e operadores com os algoritmos PID, pois estes são de fácil implementação e atende a muitas necessidades dos sistemas de controle industriais. Apesar da sua popularidade, os controladores PID são na prática, muitas vezes, sintonizados manualmente por meio do procedimento de tentativa e erro. Isto faz com que o ajuste do processo seja difícil ou ineficiente. Em muitas situações os controladores PID são substituídos por controladores PI, onde a parte da ação derivativa é retirada ([ÅSTRÖM; HÄGGLUND, 1995](#)), sacrificando o desempenho e eficiência da operação por um processo rápido e fácil de sintonia.

Para resolver este problema, diversas técnicas têm sido desenvolvidas para a sintonia de controladores PID ([ZIEGLER; NICHOLS, 1942](#)), ([ZIEGLER; NICHOLS, 1943](#)) e ([ÅSTRÖM;](#)

[HÄGGLUND, 1995](#)). Se o desempenho requerido não é rigoroso, estes métodos convencionais de sintonia de controladores PID são suficientes em muitos sistemas de controle industrial. Porém, devido ao crescimento da concorrência mundial os sistemas estão se tornando estruturas mais complexas de serem controladas e com os requisitos de desempenho mais rigorosos, onde métodos de sintonia mais eficientes são necessários.

A complexidade dos processos industriais modernos requer técnicas mais avançadas para o desenvolvimento de projeto de sistemas de controle, sendo que a aplicação de procedimentos de controle com ganhos fixos são muitas vezes inadequados. O desenvolvimento do controle adaptativo nas ultimas décadas promove um esforço no sentido de estabelecer técnicas de controle capazes de sanar dificuldades como: incerteza e variação paramétrica, dificuldade de modelagem e perturbações.

Os controladores de processos podem ser classificados em controladores clássicos ou convencionais e controladores avançados ([FILATOV et al., 1996](#)). Controle em cascata e alimentados para frente (*feedforward*) são considerados controladores clássicos, enquanto os controladores adaptativos, preditivos, ótimo, não linear e inteligentes são classificados como controladores avançados.

3.1.2 Controle Ótimo

O controle ótimo depende da solução das equações do modelo concebido da planta. Estas equações podem ser complicadas e a solução exata das equações de *Hamilton-Jacobi* para sistemas não-lineares podem não ser possíveis. Para esses casos o controle adaptativo ótimo, fornece métodos práticos para resolver essas equações. Algoritmos são implementados para encontrar soluções aproximadas *online* em tempo real utilizando-se de técnicas de aprendizagem adaptativa com base em estados do sistema.

Neste capítulo inicia-se a modelagem com as equações de restrição, uma vez que estas representam a dinâmica do sistema. Essas relações de restrição são fixadas pela física do problema e o índice de desempenho é selecionado pelo especialista para representar o comportamento desejado do sistema dinâmico.

Solução para o problema de controle ótimo para sistemas não-lineares com índices de desempenho muito gerais são difíceis de serem deduzidos com expressões matemáticas explícitas para o controle ótimo ([ZHOU et al., 1996](#)). Considerando o caso especial extremamente importante de sistemas lineares com índices de desempenho quadráticos, onde esses índices de desempenho podem ser considerados como superfícies quadráticas $(n + m)$ - dimensionais, onde n e m são as dimensões dos vetores de estado e de controle ([LEWIS; SYRMOS, 1995](#)).

Observa-se que soluções muito refinadas podem ser dadas em duas instâncias: a situação de estado final fixo, que leva a uma estratégia de controle em malha aberta e a situação de estado livre final, o que leva a uma estratégia em malha fechada ([LEWIS; SYRMOS, 1995](#)).

Considerando que a planta a ser controlada pode ser descrita pela equação linear dada por

$$x_{k+1} = A_k x_k + B_k u_k, \quad (1)$$

com $x_k \in R^n$ e $u_k \in R^m$. O índice de desempenho associado é a função quadrática dada por

$$J_i = \frac{1}{2} x_N^T S_N x_N + \frac{1}{2} \sum_{i=1}^{N-1} (x_N^T Q_k x_k + u_k^T R_k u_k), \quad (2)$$

definido o intervalo de tempo $[i, N]$. Observa-se que tanto a planta como as matrizes de ponderação de custos podem, em geral, serem variáveis no tempo. O estado inicial da planta é dado como x_i . Considera-se que Q_k e S_k são matrizes definidas semipositivas simétricas e que $|R_k| \neq 0$ para todo k (LJUNG; SÖDERSTRÖM, 1983).

3.1.3 Regulador Linear Quadrático - RLQ

Seja o sistema contínuo controlável de ordem n ,

$$\dot{x} = Ax + Bu. \quad (3)$$

Deseja-se encontrar a lei de controle que minimiza o funcional J que é dado por

$$\min_u J = \int_0^\infty (x^T Q x + R u^2) dt, \quad (4)$$

sendo Q positiva semidefinida e $R > 0$, a solução é dada por

$$u = -Kx, \quad (5)$$

o vetor K tem dimensão $[1 \times n]$, para obter K , resolve-se a Equação algébrica de Riccati contínua que é dada por

$$A^T P + PA - PBR^{-1}B^T P = -Q, \quad (6)$$

K é então dado por:

$$K = R^{-1}B^T P. \quad (7)$$

A matriz Q e o fator escalar R ponderam os efeitos da minimização sobre os estados e a entrada, respectivamente: $\text{diag}(Q) > R : \min \|x\|$ prevalece sobre $\min |u|$ (esforço de controle) e $R > \text{diag}(Q)$ enfatiza-se a redução do esforço de controle (ARNOLD; LAUB, 1984).

Calculando-se os ganhos K para o sistema em malha fechada

$$\dot{x} = (A - BK)x, \quad (8)$$

o sistema é estável, se as raízes de $\det[sI - (A - BK)] = 0$ para toda parte real $R < 0$, conseqüente

$$\lim_{t \rightarrow \infty} x(t) = 0. \quad (9)$$

3.1.4 Regulador Linear Quadrático em Tempo Discreto - RLQD

Seja o sistema discreto controlável de ordem n ,

$$x(k+1) = \Phi x(k) + \Gamma u(k). \quad (10)$$

A lei de controle que minimiza J é dada por

$$\min_{u(k)} J = \frac{1}{2} \sum_{k=0}^{\infty} (x^T(k) Q x(k) + R u^2(k)), \quad (11)$$

sendo Q definida semipositiva, $R > 0$ e K um vetor $1 \times n$. A solução é dada por

$$u(k) = -Kx(k). \quad (12)$$

K obtido recursivamente da Equação de *Riccati* discreta, que é dada por

$$P(k+1) = Q + \Phi^T P(k) \Phi - \Phi^T P(k) \Gamma^T (R + \Gamma^T P(k) \Gamma)^{-1} \Gamma^T P(k) \Phi. \quad (13)$$

e finalmente

$$K = (R + \Gamma^T P \Gamma)^{-1} \Gamma^T P \Phi. \quad (14)$$

A matriz Q e a matriz R ponderam os efeitos da minimização sobre os estados e a entrada, respectivamente. Se Q e R forem definidas positivas, a matriz K calculada garante que as raízes da equação característica, estejam dentro do círculo unitário e garante portanto que

$$\lim_{k \rightarrow \infty} x(k) = 0. \quad (15)$$

3.2 Programação Dinâmica Adaptativa - PDA

O uso da PD clássica para encontrar a política ótima de um problema de decisão markoviano (PDM) com espaços de estado é bastante viável, caso se conheça o modelo completo do ambiente, pois nessa condição é possível determinar os valores exatos de cada estado e armazená-los em uma tabela em memória (LEWIS; LIU, 2013). No entanto, para PDM com elevada dimensão e com grande quantidade de ações possíveis por estado pode ser impossível percorrer todos esses estados e calcular seus valores. Por outro lado, pode ser possível encontrar uma função que se adeque à função que gerou todos os valores dos estados e armazenar em memória, apenas alguns parâmetros. Essa representação é dita aproximada, porque não se conhece a estrutura da função verdadeira, sendo possível escolher uma que talvez não corresponda a verdadeira. O que é mais significativo é a generalização que ocorre para estados não visitados, ou seja, visitando poucos estados é possível encontrar uma função- V bem adequada para todo o espaço de estado (SILVA et al., 2014).

Essas limitações da PD, pequenos espaços e necessidade de modelo, podem ser contornadas por meio da PDA. O agente de PDA por meio de interação com o ambiente estima uma função que se ajusta aos valores ótimos de cada estado ou par estado-ação. De posse dessa função aproximada, é possível determinar a política ótima ou subótima. Em cada passo, o agente de PDA deve estimar um modelo, calcular a função- V ótima e a política ótima para o modelo aprendido (SILVA et al., 2014).

3.2.1 Equações de Bellman

A PD é uma técnica para a construção de algoritmos para a resolução de problemas computacionais, em especial os de otimização combinatória. Ela é aplicável aos problemas nos quais a solução ótima pode ser computada a partir da solução ótima previamente calculada e memorizada, de forma a evitar recálculo, de outros subproblemas que, sobrepostos, compõem o problema original. A técnica de PD tem uma longa história no campo do controle ótimo. Ela remonta àqueles dias em que o tema do controle estava emergindo de uma forma moderna nas décadas de 1950 e 1960 que foi concebido por *Richard Bellman*, que deu uma visão moderna em seu trabalho *The Theory of Dynamic Programming* em 1954 (BELLMAN, 1954).

Funções- V estão no centro do AR e praticamente todos os métodos se concentram em aproximações de funções- V para calcular políticas ótimas ou sub-ótimas (WIERING; OTTERLO, 2012). A ideia chave da PD é o uso de função valor para organizar e estruturar a busca de políticas ótimas (SUTTON; BARTO, 1998), ou seja, cada estado ou par estado-ação tem um valor dado pela função- V , considerando uma dada política. Então, qualificar uma política (π) é encontrar a função valor para ela. A função- V pode ser de dois tipos:

- 1) Função- V estado conhecida também como função- V , é uma função que relaciona cada estados admissível do espaço de estado X a uma valor escalar, $V^\pi : X \rightarrow \mathbb{R}$;

- 2) Função- V ação ou função- Q , é uma função que relaciona cada par estado-ação possível do produto cartesiano do espaço de estado X com o espaço de ações A a um valor escalar $Q^\pi : X \times A \rightarrow \mathbb{R}$.

O valor de um estado x_t sob a política π é o retorno esperado quando se inicia no estado x_t e segue-se a política π (SUTTON; BARTO, 1998). Para a função- V , o valor de um estado é dado por

$$\begin{aligned} V^\pi(x) &= E_\pi\{R(x_t)|x_t = x\} \\ &= E_\pi\left\{\sum_{k=0}^{\infty} \gamma^k r(x_{t+k}, \mu_{t+k})|x_t = x\right\}, \end{aligned} \quad (16)$$

e, para a função- Q , é dado por

$$\begin{aligned} Q^\pi(x) &= E_\pi\{R(x_t, \mu_t)|x_t = x, \mu_t = \mu\} \\ &= E_\pi\left\{\sum_{k=0}^{\infty} \gamma^k r(x_{t+k}, \mu_{t+k})|x_t = x, \mu_t = \mu\right\}, \end{aligned} \quad (17)$$

que é muito parecida com a função dada na Eq. (16), mas difere desta pelo fato do custo médio ser calculado para cada par (x, μ) . O termo E_π é o valor esperado quando o agente segue a política π , μ é a taxa de treinamento e γ^k é o fator de esquecimento no tempo atual (k).

Calcular os valores dos estados utilizando as definições acima traz um inconveniente, pois antes de calcular o valor de um estado é necessário percorrer toda a trajetória imposta pela política. Uma forma de contornar essa dificuldade é utilizar a equação de *Bellman* que relaciona valores de estados vizinhos ou sucessores (SILVA et al., 2014).

Primeiramente, foca-se na caracterização da equação de *Bellman* para a função- V e depois, na função- Q . Estas são fundamentais nos algoritmos de iteração de política e iteração de valor (BUSONI et al., 2010).

Para estruturar a função dada na Eq. (16) na forma da equação de *Bellman*, deve-se separar o primeiro termo ($k = 0$) e pôr em evidência o γ da soma restante da função- V , resultando em

$$\begin{aligned} V^\pi(x) &= E_\pi\left\{r(x_t, \mu_t) + \gamma \sum_{k=1}^{\infty} \gamma^{k-1} r(x_{t+k}, \mu'|x_t = x)\right\} \\ &= E_\pi\left\{r(x_t, \mu_t) + \gamma \sum_{k=1}^{\infty} \gamma^{k-1} r(x_{t+k+1}, \mu'|x_t = x)\right\}, \end{aligned} \quad (18)$$

as ações μ , que são tomadas do conjunto de ações possíveis para o estado x .

Por fim, utiliza-se novamente a Eq. (18), agora aplicada ao estado x_{t+k+1} , substituindo em Eq. (18) para obter a equação de *Bellman* que é dada por

$$V^\pi(x) = E_\pi\{r(x_t, \mu) + \gamma V^\pi(x_{t+k+1})\}, \quad (19)$$

que relaciona o valor de um estado ao valor do seu sucessor, ou seja, para se conhecer o valor de um estado basta conhecer o valor do estado sucessor e o custo da transição.

De forma semelhante a Eq. (19), a função- Q na forma de *Bellman* resulta em

$$\begin{aligned} Q^\pi(x, \mu) &= E_\pi \left\{ \sum_{k=1}^{\infty} \gamma^k r|(x_t, \mu_t)|x_t = x, \mu_t = \mu \right\} \\ &= E_\pi \left\{ r(x_t, \mu_t) + \gamma \sum_{k=0}^{\infty} \gamma^k r|(x_{t+k+1}, \mu_{t+k+1})|\mu_t = \mu \right\} \\ &= E_\pi \{ r(x_t, \mu_t) + \gamma Q^\pi(x_{t+k+1}, \mu_{t+k+1}) | x_t = x, \mu_t = \mu \}. \end{aligned} \quad (20)$$

Pode-se ver que o valor da função- Q para um determinado par estado-ação (x, μ) para uma política π é dado pelo custo imediato de se tomar a ação μ no estado x mais o valor descontado λ da função- Q do estado sucessor seguindo a política π . As equações de *Bellman* dadas nas Eqs. (19) e (20) são o centro dos algoritmos de iteração de política e iteração de valor.

3.2.2 Programação Dinâmica Heurística - PDH

A técnica de PDH é utilizado para estimar uma função- V estado a partir de amostras do ambiente. A PDH utiliza o algoritmo de iteração de política para estimar uma função- V estado de uma dada política, apenas recebendo amostras instantâneas dos custos. Esta etapa é a avaliação da política que é realizada pelo crítico. Após avaliar a política, a etapa seguinte é melhorar a política que é responsabilidade do ator, sendo necessário o modelo do ambiente. A função- V para uma determinada política é dada por

$$V(x_k) = r(x_k, \mu_k) + \gamma V(f(x_k, \mu_k)), \quad (21)$$

como, o que interessa é a função- V estado parametrizada, então, tem-se

$$V(x_k, \theta) = r(x_k, \mu_k) + \gamma V(f(x_k, \mu_k), \theta), \quad (22)$$

sendo θ os parâmetros da função- V aproximada.

A Eq. (21) pode ser vista como um alvo ($V^{alvo} = V(x)$) da Eq. (22) no processo de aproximação paramétrica que é dada por

$$h(V^{alvo}, V(x_k, \theta')), \quad (23)$$

que representa uma função objetivo de um algoritmo de aprendizagem supervisionado como, por exemplo $h(V^{alvo}, V(x_k, \theta')) = (V^{alvo}, V(x_k, \theta'))^2$ para o LMS.

Para atualizar o parâmetro θ da função- V parametrizada é necessário encontrar o argumento que minimizar h , ou seja,

$$\theta = \arg \min_{\theta'} (h(V^{alvo}, V(x_k, \theta'))). \quad (24)$$

A parametrização da função- V de estado induz a parametrização da política μ que é dado por

$$\mu(x_k) = \mu(x_k, w), \quad (25)$$

sendo w o vetor de parâmetros da política. Portanto, deve-se encontrar w de forma a minimizar a função- V de estado, ou seja,

$$w = \arg \min_{w'} (r(x_k, \mu_k(x_k, w')) + V(f(x_k, \mu_k(x_k, w')), \theta)). \quad (26)$$

3.2.3 Programação Dinâmica Heurística Dual - PDHD

Diferentemente da PDH que estima a função- V estado diretamente, a PDHD estima a derivada parcial da função- V em relação aos estados, o que a torna dependente do modelo do processo nas etapas de avaliação e melhoria da política. A partir da Eq. (21), tem-se que

$$\begin{aligned} \frac{\partial V(x)}{\partial x} &= \frac{\partial r}{\partial x} + \frac{\partial r}{\partial \mu} \frac{\partial \mu}{\partial x} + \gamma \frac{\partial V}{\partial f} \left(\frac{\partial f}{\partial x} + \frac{\partial f}{\partial \mu} \frac{\partial \mu}{\partial x} \right) \\ &= r_x + r_\mu \mu_x + \gamma V_f (f_x + f_\mu \mu_x), \end{aligned} \quad (27)$$

o subíndice no lado direito da Eq. (27) refere-se a derivada parcial em relação a variável indicada por esse subíndice. No entanto, essa equação pode ser utilizada como alvo para a função parametrizada $V_x(x, \theta)$, sendo θ seu vetor de parâmetros.

3.2.4 Programação Dinâmica Heurística Dependente de Ação - PDHDA

A PDHDA ou aprendizagem Q é um método bastante utilizado quando o PDM que se deseja solucionar não é conhecido antecipadamente. O método utiliza a função- Q que é uma função depende de estado e ação de controle. Nesta tese utilizou-se, somente, PDHDA para um sistema de controle independente de modelo da planta, baseado apenas nos sinais dos estados de entrada e saída medidos por sensores.

A equação de *Bellman* para função- Q ao longo de uma trajetória é dada pela Eq. (16) que em sua forma determinística é representada por

$$Q(x_k, \mu(x_k)) = r(x_k, \mu(x_k)) + Q(x_{k+1}, \mu(x_{k+1})), \quad (28)$$

que na versão parametrizada, toma a seguinte forma

$$Q(x_k, \mu(x_k)) = r(x_k, \mu(x_k)) + \gamma Q(x_{k+1}, \mu(x_{k+1}), \theta), \quad (29)$$

que pode ser usada como alvo para algum algoritmo de aprendizagem supervisionada no processo de aproximação paramétrica da função- V ação ou função- Q . Para atualizar o parâmetro θ da função- Q parametrizada é necessário encontrar o argumento que minimizar o mapeamento h , ou seja,

$$\theta = \arg \min_{\theta'} (h(Q^{Alvo}, Q(x_k, \mu_k, \theta'))). \quad (30)$$

A melhoria da política é feita encontrando o valor mínimo de Q para todas as ações possíveis para cada estado que é dado por

$$\mu = \arg \min_{\mu'} (Q(x, \mu')). \quad (31)$$

Resolvendo a Eq. (31), resulta em

$$\frac{\partial Q}{\partial \mu} = 0, \quad (32)$$

que é a derivada parcial da função- Q em relação a ação de controle μ .

3.2.5 Programação Dinâmica Heurística Dual Dependente de Ação - PDHDDA

A PDHDDA busca encontrar a política ótima a partir das derivadas parciais da função- Q em relação aos estados e ações. A partir da Eq. (28), o alvo para o ADDHP é dado por

$$\begin{bmatrix} \frac{\partial Q}{\partial x} & \frac{\partial Q}{\partial \mu} \end{bmatrix} = \begin{bmatrix} \frac{\partial r}{\partial x} + \frac{\partial Q}{\partial f} \frac{\partial f}{\partial x} + \frac{\partial Q}{\partial \mu} \frac{\partial \mu}{\partial f} \frac{\partial f}{\partial x} & \frac{\partial r}{\partial \mu} + \frac{\partial Q}{\partial f} \frac{\partial f}{\partial \mu} + \frac{\partial Q}{\partial \mu} \frac{\partial \mu}{\partial f} \frac{\partial f}{\partial x} \end{bmatrix}, \quad (33)$$

ou

$$\begin{bmatrix} Q_x^{Alvo} & Q_\mu^{Alvo} \end{bmatrix} = \begin{bmatrix} r_x + Q_f f_x + Q_\mu \mu_f f_x & r_\mu + Q_f f_\mu + Q_\mu \mu_f f_x \end{bmatrix}, \quad (34)$$

A atualização da política é feita da mesma forma do caso PDHDDA.

3.3 Inteligência Computacional - IC

A inteligência computacional é abordada em duas instâncias, sendo: 1) RNA-E e 2) LF.

3.3.1 Redes Neurais Artificiais Estruturadas - RNA-E

A proliferação rápida e bem sucedida de aplicações que incorporam tecnologia de RNA em campos tão diversos como comércio, ciência, indústria e medicina oferece uma garantia e quebra do paradigma das RNAs. As RNAs têm três características importantes que sustentam esse sucesso: A primeira é a maneira comparativamente direta em que as RNAs adquirem informações/conhecimentos sobre um determinado domínio complexo por meio de uma etapa de treinamento. Esse processo é bastante distinto do processo mais complicado de engenharia/aquisição de conhecimento para sistemas simbólicos de IA. A segunda característica é a forma compacta (embora completamente numérica) na qual a informação/conhecimento adquirida é armazenada dentro da RNA treinada e a facilidade de velocidades comparativas com que esse **conhecimento** pode ser acessado e usado. A terceira característica é a robustez da solução com base em uma RNA na presença de ruído nos dados de entradas da planta. Além dessas características, uma das vantagens mais importantes das RNAs treinadas é o alto grau de precisão relatado quando uma solução RNA é usada (ANDREWS et al., 1995).

A combinação de computação quântica (CQ) e RNA é um tópico que tem atraído muitos pesquisadores nos últimos anos, com a possibilidade de se construir modelos que melhore a eficiência da computação. As principais orientações de pesquisa na rede neuronal quântica (RNQ) incluem memória associativa quântica (VENTURA; MARTINEZ, 2000), RNQ (BEHRMAN et al., 1996), rede neuronal convencional com propriedades mecânicas quânticas (VENTURA; MARTINEZ, 1998), rede quântica *Hopfield* (AKAZAWA, 1997). Em suma, o mecanismo e as propriedades da CQ fornecem um padrão inovador para resolver os problemas da rede neuronal original e provavelmente, a maldição da dimensionalidade.

As RNAs são ferramentas poderosas para modelar processos multivariáveis complexos, está técnica é mais usada no campo computacional. Mas, atualmente está ganhando uma atenção especial na engenharia de controle de processos. *Haykin* apresentou um livro texto significativo sobre redes neurais, que forneceu informações abrangentes de redes neurais numa perspectiva de engenharia (HAYKIN, 1994).

Seja o sistema dado por

$$Ax = b, \quad (35)$$

sendo $A \in R^{n \times m}$, $x \in R^n$ e $b \in R^m$.

Assumindo o conjunto geral de equações lineares fornecidas pela Eq. (35) com $m \geq n$ (o sistema sobre determinado), primeiro consideramos o problema de mínimos quadrados de

classificação completa (GOLUB; LOAN, 2012). Em outras palavras, assumimos que a matriz A tem classificação completa⁺ $\rho(A) = n$ e busca uma solução x . Para conseguir isso, esforça-se para minimizar a função de custo escalar para alguns p dada por

$$E(x) = \|Ax - b\|_p. \quad (36)$$

Dependendo da escolha de p (ou seja, diferentes normas), as diferentes soluções ótimas serão determinadas. Se a 1-norma (L_1 -norma) e ∞ -norma (L_∞ -norma) (ou a norma *Chebyshev*) forem usadas. Mas, a minimização da Eq. (35) é difícil porque a função da Eq. (36) não é diferenciável para esses valores de p . Quando $p = 1$, este é o problema de derivação menos absoluta. Para $p = 2$, isso é calculado como o problema linear de mínimos quadrados. E $p = \infty$, isto é referido como o problema *minimax*. O tipo de norma que é utilizada na Eq. (35) depende muito da distribuição dos dados de erros e do tipo de aplicação que está sendo usada (HUBER, 1996), (HUBER,), (HAMPEL et al., 2011). Para o caso em que os erros têm uma distribuição exponencial dupla (ou distribuição de *Laplace*), o L_1 -norma pode ser usado (MOOD et al., 1974), (ABRAMOWITZ et al., 1972). Quando a distribuição do erro tem transições marcadamente afiadas, por exemplo, uma distribuição uniforme, então o L_∞ -norma (ou a norma *Chebyshev*) deve ser usado. No entanto, se a distribuição de erros for *Gaussiana* (normal), então é melhor usar a norma *Euclidiana* (ou L_2 -norma). Usando a norma euclidiana, o problema dos mínimos quadrados resultante é mais tratável do que os outros casos. A norma *Euclidiana* é dada por

$$\min_{\forall x} E(x) = \min_{\forall x} \|Ax - b\|_2. \quad (37)$$

Se A tiver o *rank* completo, Eq. (35) possui soluções únicas (GOLUB; LOAN, 2012). A função de custo escalar que normalmente é usado pode ser escrita como

$$E(x) = \frac{1}{2} \|Ax - b\|_2^2 = \frac{1}{2} \|e\|_2^2, \quad (38)$$

sendo a solução do vetor de erro dada por

$$e = Ax - b, \quad (39)$$

calculando o gradiente da Eq. (38) em relação ao vetor x e definindo o resultado igual a zero, ou seja, $\nabla_x E(x) = 0$, resultando na equação normal que é dada por

$$A^T Ax - A^T b = 0. \quad (40)$$

Resolvendo-se, x diretamente na Eq. (40), tem-se que

$$x = (A^T A)^{-1} A^T b, \quad (41)$$

sendo

$$A^+ = (A^T A)^{-1} A^T, \quad (42)$$

é definida como o pseudo-inversa de A . A solução da Eq. (35) é a solução para o problema da Eq. (35). Se $m < n$ (problema super-determinado) e $\rho(A) = m$ (isto é, tem *rank* completo), a solução para a Eq. (35) é dado por

$$x = A^T (A A^T)^{-1} b, \quad (43)$$

sendo agora a pseudoinversa de A dada por

$$A^+ = A^T (A A^T)^{-1}. \quad (44)$$

Assumindo que existe uma solução para a Eq. (35) e que se baseia, não em um método formulado, mas sim em uma abordagem que aprende uma solução. A regra de aprendizagem contínua (analogica) é dada por

$$\frac{dx}{dt} = -\mu \nabla_x \varepsilon(x), \quad (45)$$

sendo $\mu \in \mathbb{R}^{n \times n}$ ($\mu = [\mu_{ij}]$, para $i, j = 1, 2, \dots, n$) uma matriz definida positiva, normalmente é diagonal, isto é, $\mu_{ij} = \mu_j \delta_{ij}$, sendo $\mu_j > 0$, δ_{ij} o delta *Kronecker* e $x(0) = x_0$. O gradiente mostrado na Eq. (45) já foi determinado e é o lado esquerdo da Eq. (40), o gradiente fornece a regra de aprendizagem para resolver um sistema de equações dado por

$$\frac{dx}{dt} = -\mu (A^T A x - A^T b) = -\mu A^T (A x - b). \quad (46)$$

Substituindo a Eq. (39) na Eq. (46), tem-se

$$\frac{dx}{dt} = -\mu A^T e, \quad (47)$$

O problema é dado por


$$\min_{K^{pid}} \frac{1}{2} \|E\|_2^2 \Rightarrow \min \|\bar{B}^T \bar{B} K^{pid} - B^T e\|_2^2. \quad (48)$$

A solução é dada por

$$\begin{aligned} \frac{\partial \|E\|}{\partial K^{pid}} &= \left(\frac{1}{2} \|\bar{B}^T \bar{B} K^{pid} - B^T e\|_2^2 \right) \\ &= \bar{B}^T \bar{B} (\bar{B}^T \bar{B} K^{pid} - B^T e) \\ &\Rightarrow \nabla_{K^{pid}} E (K^{pid}). \end{aligned} \quad (49)$$

Na Figura 15 está a representação da topologia da RNA-E desenvolvida a partir da Eq. (49).

Figura 15 – Topologia da RNA-E adaptada para o sistema de controle do processo de retomada de granéis sólidos por RP



3.3.2 Lógica Fuzzy - LF

A Lógica *Fuzzy* foi desenvolvida em 1965 por *Lotfi A. Zadeh*, professor de Ciência da Computação na Universidade da Califórnia em *Berkeley*. A lógica *fuzzy* é uma extensão da convencional (booleana) que manipula o conceito de verdade parcial, valores de verdade entre "completamente verdadeiro" e "absolutamente falsa". *Zadeh* notado que a complexidade do sistema vem de como as variáveis foram representadas e manipuladas (SILVA, 2018) e (WEI et al., 2018).

A teoria dos conceitos *fuzzy* e lógica *fuzzy* pode ser usada para traduzir em termos matemáticos a informação imprecisa expressa por um conjunto de regras linguísticas. Se um operador humano é capaz de articular estratégia de ação como um conjunto de regras da forma SE ... ENTÃO que pode ser implementado em um computador através de um algoritmo. O resultado é um sistema baseado em regras de inferência, em que a teoria dos conjuntos *fuzzy* e lógica *fuzzy* fornecem as ferramentas matemáticas para lidar com tais regras linguísticas (JANG et al., 1997), (BÄCK et al., 2018).

Na teoria clássica dos conjuntos, o conceito de relevância de um elemento de um conjunto é bem definida. Dado um conjunto A em um universo X , os elementos deste universo simplesmente pertencem ou não pertencem a esse conjunto (KECHRIS; KECHRIS, 1995). Isto pode ser expresso pela função característica, que é dada por

$$f_A(x) = \begin{cases} 1 & \text{se, e somente se } x \in A, \\ 0 & \text{se, e somente se } x \notin A. \end{cases} \quad (50)$$

Zadeh propôs uma caracterização mais ampla, generalizando a função característica de modo que ela pudesse assumir um número infinito de valores no intervalo $[0, 1]$. Um conjunto *fuzzy* A em um universo X é definido por uma função de pertinência $\mu_A(x) : \rightarrow [0, 1]$, e

representado por um conjunto de pares ordenados $A = \{ \mu_A x / x \} \quad x \in X$, onde $\mu_A(x)$, indica o quanto é compatível com o conjunto. Um determinado elemento pode pertencer a mais de um conjunto *fuzzy*, com diferentes graus de pertinência (ZADEH, 1996).

Um sistema nebuloso é formado pela agregação de um conjunto de regras de inferência que mapeia regiões no espaço das entradas $U_1 \times U_2 \times \dots \times U_r$ para regiões no espaço das saídas $V_1 \times V_2 \times \dots \times V_m$ (PEDRYCZ; GOMIDE, 2007). Este mapeamento se dá através do mapeamento de conjuntos *fuzzy* para conjuntos *fuzzy* (SERRA, 2012).

Na grande maioria das aplicações dos sistemas *fuzzy* em engenharia, a troca de informações entre o ambiente e o sistema deve acontecer por meio de variáveis cujos valores são números reais. Exemplificando: a saída de um sensor de temperatura é um valor real (ex. $65^\circ C$) e não um conjunto *fuzzy*. Assim, este interfaceamento entre o sistema *fuzzy* puro e o ambiente no qual ele está situado, se dá através de dois blocos funcionais chamados de Fuzificador e Desfuzificador, respectivamente. O bloco fuzificador tem a função de converter um valor real em um conjunto *fuzzy*. O mais simples dos fuzificadores é o fuzificador "*singleton*" que converte um número real em um conjunto *fuzzy singleton*. O bloco desfuzificador realiza o processo inverso.

Note que um valor de entrada (u ou v) pode ativar mais de uma regra ao mesmo tempo. Isto é completamente diferente do sistema especialista clássico, onde uma premissa simples só ativa uma única regra.

3.3.2.1 Conjuntos Fuzzy

A Lógica Difusa pode ser utilizada para a implementação de controladores *fuzzy*, aplicados nos mais variados tipos de processos. A utilização de regras nebulosas e variáveis linguísticas confere ao sistema de controle várias vantagens, incluindo:

- Simplificação do modelo do processo;
- Melhor tratamento das imprecisões inerentes aos sensores utilizados;
- Facilidade na especificação das regras de controle, em linguagem próxima à natural;
- Satisfação de múltiplos objetivos de controle;
- Facilidade de incorporação do conhecimento de especialistas humanos.

Entretanto, tanto as leituras de sensores quanto os sinais esperados pelos atuadores do sistema de controle, não são *fuzzy*, são necessários elementos adicionais entre o controlador *fuzzy* e o processo a ser controlado. Estes elementos são denominados fuzificador e defuzificador, e estão posicionados na entrada e saída do sistema de controle, respectivamente. Estes elementos são responsáveis por transformar as medidas obtidas dos sensores em conjuntos *fuzzy* (fuzificador),

e em transformar os conjuntos *fuzzy* obtidos na saída do controlador em valores não *fuzzy* de controle para o processo (defuzificador).

O conceito formal de conjunto *fuzzy*, fundamentado da Lógica Difusa, foi introduzido por Lofti A. Zadeh em 1965. Na teoria clássica dos conjuntos, os conjuntos são ditos "*crisp*", de tal forma que um dado elemento do universo em discurso (domínio) pertence ou não pertence ao referido conjunto. Na teoria dos conjuntos *fuzzy* existe um grau de pertinência de cada elemento a um determinado conjunto (WANG, 1999).

3.3.2.2 Variáveis Linguísticas

Um conceito relacionado com conjuntos *fuzzy* é o de variável linguística. Entende-se por variável um identificador que pode assumir um dentre vários valores. Deste modo, uma variável linguística pode assumir um valor linguístico dentre vários outros em um conjunto de termos linguísticos.

Formalmente, uma variável linguística é caracterizada pela quintupla $\{X, T(X), U, M\}$, onde X é o nome do conjunto de termos, U o universo de discurso, uma gramática G é usada para gerar os termos $T(X)$ e M . O significado dos termos linguísticos é representado por meio de conjuntos *fuzzy* (WANG, 1994).

Variáveis linguísticas podem também conter modificadores (também linguísticos) que alteram seu valor. Exemplos de modificadores válidos são: muito, pouco, não muito, mais ou menos. Existem também conectivos que podem ser aplicados à estas variáveis, "e" e "ou". Assim, um valor válido para a variável linguística altura seria não muito alto e não muito baixo (KALAIARASSAN et al., 2018). Os modificadores linguísticos podem ser definidos matematicamente, como no exemplo dos conjuntos, baixo e muito baixo, onde o modificador muito é caracterizado por elevar cada ponto da função de pertinência à segunda potência (PEDRO; DAHUNSI, 2011).

Os conectivos *and*(e) e *or*(ou) são equivalentes à operações de união e interseção de conjuntos, respectivamente, podendo dar origem a conjuntos complexamente definidos, porém representados linguisticamente de maneira simples (CHEN et al., 2006). Os sistemas *fuzzy* têm as seguintes vantagens: funcionam bem com poucas regras; as variáveis são observáveis e valoradas; o uso de variáveis linguísticas aproximam-se mais do pensamento humano; simplificam a solução de problemas; proporcionam um rápido protótipo dos sistemas e simplificam a aquisição da base do conhecimento (WANG, 1999) e (NGUYEN et al., 2018).

Capítulo 4

Metodologia Proposta

Neste capítulo apresenta-se a metodologia proposta para sintonia *online* de ganhos das ações PID aplicada no desenvolvimento desta Tese. O mesmo inicia-se com o levantamento de pesquisas bibliográficas relevantes associadas com os temas abordados para dar embasamento teórico e fundamento científico na mesma.


Depois identifica-se modelos baseados em dados reais do processo operacional de uma retomadora de granéis e iniciados os experimentos de sintonia de controladores PID em plantas reais por meio de métodos convencionais de tentativa e erro e pelos métodos de *Ziegler-Nichols*, ainda neste contexto, incluiu-se na metodologia operações de produto interno por meio da função de transferência do controlador PID associada com os zeros da função de transferência da planta $\langle K^{pid}, \bar{b}_i \rangle$ para determinar o vetor de ganhos K^{pid} . Na sequência, desenvolve-se metodologias de sintonia ótima e *online* de controladores com ações PID baseadas em modelos (MBC).

Na exploração dessas metodologias, propõe-se duas abordagens, sendo uma *offline* e outra *online*. Na primeira abordagem, desenvolveu-se algoritmos de sintonia baseados em RNA-E para determinar o vetor de ganhos K^{pid} *offline* e fazer o escalonamento desse vetor *online* por regras *fuzzy* e na segunda abordagem. Os algoritmos de sintonia de controladores PID baseada em RNA-E determinam os coeficientes a_i da função de transferência *online*, fazendo a alocação de pólos e consequentemente o ajuste do vetor de ganhos K^{pid} . A metodologia, ainda se estendeu para métodos de sintonia independente de modelos (DDC). Nesta, foram desenvolvidos algoritmos para sintonia *online* e ótima de controladores com ações PID guiados por dados medidos por sensores. Por fim, analisou-se os resultados experimentais comparando-os com os métodos convencionais e em plantas reais com os métodos utilizando os algoritmos proposto nesta Tese.

4.1 Planta Processo de Retomada de Granéis por RP

A planta do processo de retomada de granéis é utilizada para dar continuidade nos experimentos baseados em dados de plantas industriais coletados durante o processo produtivo. O modelo em espaço de estado é concebido com dados reais da planta de retomada de minério, usando-se do método de subespaço (Mínimos Quadrados) e do algoritmo de busca *Numerical algorithms for Subspace State Space System IDentification* (N4SID) (OVERSCHEE; MOOR, 2012) e (OVERSCHEE, 1996). Foram definidas como variáveis de estado $X(s)$, sendo x_1 a intensidade da corrente elétrica (I) do motor da roda de caçambas da RP, x_2 o tamanho do passo de translação, x_3 a carga medida pela balança, que é igual a $Y_m(s)$ e $Y(s)$ a saída (MOURA et al., 2019a) e (MOURA et al., 2019b), conforme ilustrado na Figura 16.

Figura 16 – Estimação do modelo da planta retomadora de minério



Matematicamente, esses modelos são descritos pelo seguinte conjunto de equações à diferença, que é dado por

$$x_{k+1} = Ax_k + Bu_k + w_k, \quad (51)$$

e

$$y_k = Cx_k + Du_k + v_k, \quad (52)$$


com

$$E \left[\begin{pmatrix} w_p \\ v_p \end{pmatrix} \begin{pmatrix} w_q^T & v_q^T \end{pmatrix} \right] = \begin{pmatrix} Q & S \\ S^T & R \end{pmatrix} \delta_{pq} \geq 0, \quad (53)$$

sendo E o operador de valor esperado e δ_{pq} delta de Kronecker (OVERSCHEE; MOOR, 2012). Os vetores $u_k \in \mathbb{R}^m$ e $y_k \in \mathbb{R}^\ell$ são as medições de entrada e saída do processo no instante k respectivamente. $x_k \in \mathbb{R}^n$ é o vetor de estado do processo no instante de tempo discreto


k e contém os valores numéricos de n estados. Esses estados não têm necessariamente uma interpretação física direta, mas têm uma relevância conceitual. É claro que, se os estados do sistema tiverem algum significado físico, pode-se encontrar uma transformação de semelhança do modelo espaço de estado para converter os estados em significados físicos. Os sinais $v_k \in \mathbb{R}^\ell$ e $w_k \in \mathbb{R}^n$ não são mensuráveis (são desconhecidos). $A \in \mathbb{R}^{n \times n}$, $B \in \mathbb{R}^{n \times m}$, $C \in \mathbb{R}^{p \times n}$, e $D \in \mathbb{R}^{p \times m}$. A matriz de saída que descreve como o estado interno é transferido para o sinal de saída y_k medido no sistema. Em sistemas de tempo contínuo, este termo é usualmente 0, o que não é o caso em sistemas de tempo discretos devido à amostragem. As matrizes de covariância das sequências de ruído w_k e v_k são $Q \in \mathbb{R}^{n \times n}$, $S \in \mathbb{R}^{n \times \ell}$ e $R^{\ell \times \ell} \in \mathbb{R}$. Considera-se observável o par de matrizes A, B o que implica que todos os sinais de entrada do sistema podem ser observados na saída y_k e, portanto, podem ser identificados. Supõe-se, que o par de matrizes $\left\{ A, \begin{bmatrix} B & Q^{1/2} \end{bmatrix} \right\}$ têm todos os sinais do sistema excitados pela entrada determinística u_k e/ou pela entrada estocástica w_k . A Figura 17 é a representação em diagrama blocos da planta. Sendo u_k e y_k conhecidos, enquanto que v_k e w_k são os distúrbios (perturbações) e são desconhecidos e Δ é o operador de atraso, a matriz A representa a dinâmica da planta. Supõe-se que não existe ruído de medição.

Figura 17 – Planta em espaço de estado representada em diagrama de blocos.



Na Figura 18 está ilustrado o fluxo de identificação de sistema para a construção de modelos em subespaço e a identificação clássica a partir dos dados de entrada e saída. Quando um modelo de ordem reduzida é necessário, em algumas abordagens clássicas (à direita da Figura 18), primeiro identifica-se um modelo de alta ordem e, em seguida, aplica-se uma técnica de redução de modelo para obter um modelo de baixa ordem. O lado esquerdo da Figura 18 ilustra-se a abordagem de identificação em subespaço.

Figura 18 – Fluxo de identificação de modelos



De acordo com as técnicas de identificação utilizadas, as matrizes A , B , C e D são geradas, representando o modelo matemático linear em espaço de estados, necessário para obter um simulador de processo para o propósito do projeto. O processo de identificação resultou no seguinte modelo de espaço de estados de tempo contínuo linear de terceira ordem que têm as referidas matrizes dada por

$$A = \begin{bmatrix} -0,08728 & -0,2905 & 0,3078 \\ 0,206 & -0,009143 & 1,035 \\ -0,0963 & -0,9774 & -0,09775 \end{bmatrix}, \quad (54)$$

$$B = \begin{bmatrix} -0,02255 \\ -0,03438 \\ -0,01721 \end{bmatrix}, \quad (55)$$

$$C = \begin{bmatrix} 0 & 0 & 1 \end{bmatrix}, \quad (56)$$

$$D = [0]. \quad (57)$$

Como a implementação deve ser feita em tempo discreto, as matrizes do sistema em tempo contínuo (54) e (55) foram discretizadas pelo método *hold-order-zero* e são dadas por

$$A_d = \begin{bmatrix} 0,8736 & -0,3570 & 0,1022 \\ 0,1196 & 0,5159 & 0,8369 \\ -0,1581 & -0,7528 & 0,4595 \end{bmatrix}, \quad (58)$$


$$B_d = \begin{bmatrix} -0,168 \\ -0,0382 \\ 0,0026 \end{bmatrix}, \quad (59)$$

$$C_d = \begin{bmatrix} 0 & 0 & 1 \end{bmatrix}, \quad (60)$$

$$D_d = [0]. \quad (61)$$

O modelo em espaço de estado foi utilizado para a obtenção do modelo da planta em função de transferência (MOURA et al., 2019b). Onde, define-se como o vetor de variáveis de estado $X(t) = [x_1 \ x_2 \ x_3]$. Sendo $x_1(t)$ a corrente elétrica do motor da roda de caçambas da RP, $x_2(t)$ o tamanho do passo de translação, a carga medida pela balança $x_3(t)$ que é igual a saída $Y(s)$, $H(s)$ os sensores de medição e $R(s)$ a entrada de referência. Na Figura 19 está ilustrado de forma genérica, o processo de retomada de granéis sólidos por RP.

Figura 19 – Processo de retomada de granéis sólidos por RP.



As pesquisas aqui desenvolvidas, se caracterizam em científicas avançadas e tecnológicas inovadoras, tanto no âmbito metodológico quanto em aplicações. No âmbito metodológico, utilizou-se de métodos avançados de sintonia de controladores com ações PID baseado em inteligência computacional e no âmbito de aplicação, plantas de grande porte do setor da indústria de mineração de alto grau de complexidade de controle foram usadas para a validação da metodologia proposta (MOURA et al., 2019a) e (MOURA et al., 2019b).

Parte II

Modelos de Sintonia Online para Sistemas MBC e DDC de Processos Industriais

Capítulo 5

Formulação da Sintonia Online das Ações PID Baseada em Modelos

No intuito de contribuir para o atendimento de novas exigências de mercado e com o desenvolvimento tecnológico, novos métodos baseados em MBC para sintonia *online* e ótima de controladores PID em sistemas industriais são apresentados neste Capítulo.

5.1 Sintonia Online de Controladores PID Baseada em Inteligência Computacional

Métodos para sintonias baseados em IA são associados por meio da seleção dos ganhos do vetor K^{pid} dos modelos descritos por FTs que definem os mapeamentos das entradas de erro da realimentação para os espaços de saídas. O vetor de ganhos K^{pid} conduz as transformações entre os espaço de entrada e os espaço de saída. Por sua vez, o espaço de saída é mapeado para os espaços das figuras de mérito no domínio do tempo e da frequência para avaliar os custos operacionais da atuação dos controladores. Os modelos *online* e ótimos fornecem vetores de ganhos K^{pid} que assumem compromissos entre as especificações de projeto e atendimentos aos custos com energia de controle por meio de fusões entre as abordagens bio-inspiradas e aprendizado de máquina (MOURA et al., 2019a).

Os modelos de controladores apresentados, são baseados nas abordagens de redes neurais artificiais estruturadas e lógica *fuzzy*, sendo chamado de modelo PID-Neuro-Fuzzy e PID-Neuro. Além disso, o desempenho dos modelos apresentados é avaliado em sete plantas da indústria do setor de mineração aplicado ao processo operacional de descarregamento de vagões de sólidos a granelis aplicado ao processo de descarga de vagões de sólidos a granelis por VV e ao processo operacional de retomada de granelis por RP (MOURA et al., 2019a).

Os métodos de ajuste dos controladores PID são projetados usando os dados reais das

plantas coletados durante a operação do processo pelo Sistema de Gerenciamento de Informações, do inglês *Plant Information Management System* (PIMS) (BANKER et al., 2006). O PIMS é um *software* em que os sensores são cadastrados para o registro *online* de eventos que ocorrem durante o processo (PEPPER et al., 2006).

As estruturas propostas exibem um alto grau de modularidade e, na maioria dos casos, um número relativamente pequeno de blocos de construção básicos (unidades de processamento) é necessário para implementar algoritmos de otimização eficazes e poderosos. A validade e desempenho das arquiteturas de redes neurais propostas são ilustradas por extensas simulações computacionais por VV e ao processo operacional de retomada de granéis por RP (MOURA et al., 2019a) e (MOURA et al., 2019b).

Controladores PID são normalmente, os mais usados no controle de sistemas industriais devido à sua estrutura simples, natureza robusta e fácil implementação (GARPINGER et al., 2014). Como os controladores PID aplicam um sinal ao processo que é proporcional ao sinal de acionamento, além de adicionar um sinal integrativo e derivativo de acionamento, esses componentes de sinal são facilmente percebidos e visualizados no domínio do tempo, os controladores PID são comumente projetados usando métodos no domínio do tempo (GOLNARAGHI, 2009).

Sintonia de controladores PID é uma tarefa importante (ÅSTRÖM; HÄGGLUND, 2005), (GARPINGER, 2015) e os métodos convencionais têm limitações em atender as variações paramétricas durante o processo operacional (CHOPRA et al., 2014). Essas limitações podem ser atendidas usando-se técnicas de inteligência computacional, tais como: lógica *fuzzy* e RNA/RNA-E. Nesta Tese são apresentados métodos de sintonia de controladores PID com base em IC, primeiramente, combina-se Lógica *fuzzy* com RNA-E, sendo os ganhos do vetor K^{pid} determinados por uma RNA-E e os ajustes *online* são feitos por regras *fuzzy* e depois os ganhos do vetor K^{pid} são determinados e ajustados *online* por uma RNA-E.

O controlador sintonizado pela combinação de uma RNA-E com os ganhos ajustados por regras *fuzzy* e o controlador sintonizado pelos métodos convencionais e, também, ajustado por regras *fuzzy* foram validado em sete plantas de dois processos industriais, sendo: 1) processos de descarregamento de vagões e 2) processo de retomada de sólidos a granéis por retomadora. RNA e algoritmos evolutivos (AE) são amplamente utilizados na concepção de sistemas de controle (ASSAREH; BIGLARI, 2015).

Os resultados da simulação revelam que os métodos inteligentes proporcionam melhor desempenho do que o segundo método *Zigler Nichols* em termos das especificações de desempenho.

A escolha da metodologia de sintonia, usando uma RNA-E para determinar os ganhos do controlador PID *offline* e fazer o ajuste *online* por regras *fuzzy* para processos operacionais de sistemas industriais do setor de mineração, deu-se em função desses processos serem automatizados com suas lógicas de automação desenvolvidas em CLP, que já trazem inseridos em

sua estrutura um módulo de programação PID e *fuzzy*, com isso é factível a implementação da metodologia proposta neste trabalho (MOURA et al., 2019a).

O problema da sintonia de controladores PID remonta desde o século passado, o que tem levado intensas pesquisas sobre o tema. A quantidade de métodos desenvolvidos para o ajuste dos ganhos de controladores PID é bastante intensa, como pode ser observado na literatura, que cita como abordagens pioneiras, os métodos de *Ziegler-Nichols* (ZIEGLER; NICHOLS, 1942) em configurações ótimas para controladores automáticos. No contexto de arquitetura e sintonia, a referência (NADA, a) desde 1935 até 2008 apresenta um *timeline* das regras para sintonia de controladores PID, enfatizando a melhoria do desempenho e robustez destes controladores. Ainda, observando-se a referência (ZULU, 2017), verifica-se a gama de aplicações das ações que os controladores PID demandam em desenvolvimentos no campo de *machine learning*. Embora o controlador PID sempre tenha sido muito importante, no entanto, só recebeu um interesse moderado dos pesquisadores. Portanto, muitas questões importantes não foram bem documentadas na literatura. Um resultado disso é que muitos erros foram repetidos quando a tecnologia mudou de pneumática via elétrica para digital. Houve, no entanto, um interesse crescente nos últimos dez anos. Uma razão é o surgimento da sintonia automática, outra é o aumento do uso do controle preditivo do modelo, que requer controladores PID bem ajustados no nível básico (ÅSTRÖM; HÄGGLUND, 2001).

As aplicações em, praticamente, todos os setores da indústria, promovem a motivação para implantação de controladores baseados em IC, pois os problemas surgem a cada momento da vida profissional e as soluções não estão *on the shelf*, o projetista deve propor soluções técnicas e inteligentes com rapidez, com qualidade e com baixo custo. Em face ao aparato tecnológico, a motivação se estende para o desenvolvimento de métodos de sintonia de alto desempenho para controladores PID, constatado em diversas aplicações e pesquisas.

Já em termos de imbuir otimalidade no desempenho de controladores PID, cita-se as necessidades tecnológicas, que são observadas em referências técnicas, para justificar o desenvolvimento de métodos avançados de sintonia com aplicações na indústria de processos. Em (BAI, 2010), os autores apresentam o método de otimização que baseia-se no *Integral Performance Criteria* (ISE, ISTE, IST²E) e um algoritmo *Particle Swarm Optimization* (PSO) para obter parâmetros ótimo do controlador.

5.2 Modelo Geral da Planta

Nesta Secção apresenta-se o projeto de sintonia de ganhos de controladores PID, abordando-se a influência dos zeros na dinâmica do sistema de controle em malha fechada e o ajuste dos ganhos $K^{pid} = \{K_D, K_P, K_I\}$.

Em termos de representação generalizada direcionada para teoria de compensadores, a FT genérica da planta tem o seu nascimento na estrutura de polinômios racionais no plano s que

é dada por

$$G_p(s) = \frac{b_0 s^m + b_1 s^{m-1} + \dots + b_{m-1} s + b_m}{a_0 s^n + a_1 s^{n-1} + \dots + a_{n-1} s + a_n}, \quad (62)$$

sendo $G_p(s)$ a FT genérica da planta, n a ordem da planta e a quantidade de pólos que é inserida no sistemas e m é a quantidade de zeros. Os coeficientes a_i e b_i são os parâmetros, chamados de ganhos do compensador que devem ser ajustados para impor o desempenho especificado na operação de uma dada planta. A FT da Eq. (62) é particularizada para executar as ações proporcional, integral e derivativa do controlador. Considera-se $n = 1$, $m = 2$, $a_1 = 1$, $b_0 = K_D$, $b_1 = K_P$, e $b_2 = K_I$.

Para fins de projeto a FT é especificada na forma fatorada, i.e, em termos das raízes dos polinômios do numerador e do polinômio característico da FT (62). A FT na forma fatorada é representada em termos de produtório. Consequentemente, o projetista insere as especificações técnicas de projeto na FT desejada que é dada por

$$G_p^d(s) = K \frac{\prod_{k=1}^m (s - s_{zk})}{\prod_{i=1}^n (s - s_{pi})}, \quad (63)$$

sendo $G_p^d(s)$ a FT da planta desejada, $s_{pi} = \alpha_i \sigma_i \pm j \gamma_i \omega_{di}$ os pólos e $s_k = \alpha_k \sigma_k \pm j \gamma_k \omega_{dk}$ os zeros do sistema dinâmico. Os pólos e zeros do sistema são representados em termos do par (ζ, ω_n) , a primeira componente é o fator de amortecimento e a segunda é frequência natural não amortecida, $\sigma_i = \zeta_i \omega_{ni}$ e $\omega_{di} = \omega_{ni} \sqrt{1 - \zeta_i^2}$. Os pares de fatores (α_i, γ_i) e (α_i, γ_i) tem a função de posicionar os pólos e zeros no plano s , respectivamente, tendo como escolha para referência o pólo (σ_i, ω_{di}) mais próximo da origem.

A partir do modelo do PID em termos de equações integral diferencial e da transformada de Laplace, obtém-se a FT do controlador PID em termos de produto interno $\langle \cdot \rangle$ que é dada por

$$C_{K^{pid}}(s) = \frac{\langle K^{pid}, s^{pid} \rangle}{s}. \quad (64)$$

A FT em malha aberta ou ramo direto do sistema de controle que é dado por

$$G_p^{MA}(s) = K_p(s) \frac{\langle K^{pid}, s^{pid} \rangle \langle b_i, s^m \rangle}{s^{n+1} + s \langle a_i, s^{n-1} \rangle}, \quad (65)$$

sendo $G_p^{MA}(s)$ a FT da planta em malha aberta e $K_P(s)$ o ganho da planta. De acordo com o diagrama de blocos da Figura 20 a FT $Y(s)/R(s)$, $W(s) = 0$ e $V(s) = 0$ é dada por

$$G_p^{MF}(s) = \frac{C_{K^{pid}}(s)G(s)}{1 + C_{K^{pid}}(s)G(s)H(s)}. \quad (66)$$

sendo $a_i = \alpha_i \zeta w_n$ e $a_j = \omega_n^2$ e $b_j = \alpha_j \zeta w_n$.

Levando-se em consideração a inserção das características da planta nos seus pólos e zeros, conforme apresentado na FT (63), na forma de produto interno, a representação da FT (62) é dada por

$$G_p^{s^{ip}}(s) = K \frac{\langle b_i, s^m \rangle}{s^n + \langle a_i, s^{n-1} \rangle}, \quad (67)$$

sendo $G_p^{s^{ip}}$ a FT na forma de produto interno e os coeficientes a_i com $i = 1, \dots, n$ e b_i com $i = 0, \dots, m$ uma combinação dos fatores $\alpha_i \zeta w_n$ e $\alpha_j \zeta w_n$, respectivamente.

5.3 Modelo do Controlador PID

A partir do modelo do PID em termos de equações integral diferencial e das transformadas de *Laplace*, obtém-se a FT do controlador PID em termos de produto interno que é dada por

$$G_{P_{Int}}^{K^{pid}}(s) = \frac{\langle K^{pid}, s^{pid} \rangle}{s}. \quad (68)$$

5.3.1 Função de Transferência de Malha Fechada

A FT de de Malha Fechada é representada por meio da FT de malha aberta ou ramo direto do sistema de controle que é dada por

$$G_{MF}(s) = K^{G(s)} \frac{\langle K^{pid}, s^{pid} \rangle \langle b_j, s^m \rangle}{s^{n+1} + s \langle a_i, s^{n-1} \rangle}, \quad (69)$$

sendo $K^{G(s)}$ o ganho da planta.

Quanto a estrutura da FT e da ordem, os sistemas próprios e estritamente próprios, são apresentados da seguinte forma:

- 1) caso $n = 4$ e $m = 2$;
- 3) caso $m^{PID} = 2$ e $n^{PID} = 1$.

A relação geral entre a ordem do controlador PID e da planta é apresentada a seguir


$$\begin{aligned} n + 1 &> 2 + m, \\ n &= m^{PID} + m. \end{aligned}$$

Logo, observa-se que o PID impõe uma FT própria, pois o sistema em malha fechada tem ordem $n + 1$ e o numerador tem ordem $(m^{PID} + m)$.

5.4 Sintonia Online de Controladores PID

A sintonia *online* e ótima de controladores PID são apresentadas nesta Secção associado ao diagrama de blocos da Figura 20. Observa-se nessa figura as FTs do sistema de malha fechada que relacionam os sinais das entradas $R(s)$, $W(s)$ e $V(s)$, com os sinais de saída da planta $Y(s)$ e $Y_m(s)$, do esforço de controle $U(s)$ e por fim, do erro da malha fechada $E(s)$. Desta forma, no contexto da proposta, a matriz de desempenho do sistema de controle fornece os meios para desenvolver os métodos bio-inspirados para sintonia *online* e ótima, ainda neste contexto, avalia-se o comportamento da planta para as ações dos controladores da família PID.

Figura 20 – Diagrama de blocos canônico do sistema de controle em malha fechada



5.4.1 Propagação da Ação K^{pid}

O desenvolvimento dos polinômios dos zeros e pólos é apresentado sob o ponto de vista da propagação do vetor de ganhos K^{pid} do controlador por meio dos coeficientes do numerador da FT da planta. A referida matriz mostra a atuação do controlador na dinâmica da planta, salientando a alteração da ordem e dos coeficientes do polinômio característico por meio do produto interno dos coeficientes dos zeros e dos ganhos dos controladores PID (MOURA et al., 2019a). O polinômio do numerador da FT em malha fechada é dado por

$$\begin{aligned} N^{MF}(s) &= N_{C_{K^{pid}}}(s)N_{G_p}(s) \\ &= (K_D s^2 + K_P s + K_I) \\ &\quad \times (b_0 s^m + \dots + b_{m-1} s + b_m). \end{aligned} \quad (70)$$

O polinômio dos zeros do sistema de controle de malha fechada tem ordem $m + m^{pid}$, sendo m a ordem polinomial dos zeros da planta e m^{pid} é a ordem do controlador PID, onde $m^{pid} = 0, 1, 2$ (MOURA et al., 2019a).

- Se $m^{pid} = 0$, tem apenas o ganho K_P ;
- Se $m^{pid} = 1$, este tem os ganhos K_I e K_P e

- Se $m^{pid} = 2$, têm os três termos K_P , K_I e K_D .

Expandindo e ordenando a Eq. (70), tem-se

$$\begin{aligned}
 N^{MF}(s) = & (b_0 K_D + b_{-1} K_P + b_{-2} K_I) s^{m+m^{pid}} \\
 & + (b_1 K_D + b_0 K_P + b_{-1} K_I) s^{m+m^{pid}-1} \\
 & + (b_2 K_D + b_1 K_P + b_0 K_I) s^m \\
 & + (b_3 K_D + b_2 K_P + b_1 K_I) s^{m-1} \\
 & \dots\dots\dots \\
 & + (b_m K_D + b_{m-1} K_P + b_{m-2} K_I) s^2 \\
 & + (b_{m+1} K_D + b_m K_P + b_{m-1} K_I) s^1 \\
 & + (b_{m+2} K_D + b_{m+1} K_P + b_m K_I) s^0.
 \end{aligned} \tag{71}$$

A forma polinomial geral do polinômio do numerador de malha fechada é dada por

$$N^{MF}(s) = \sum_{i=0}^{m_{MF}} (b_i K_D + b_{i-1} K_P + b_{i-2} K_I) s^{m_{MF}-i}, \tag{72}$$

sendo $m_{MF} = m + m^{pid}$.

5.4.1.1 Polinômio Característico da Planta ($P_p^{MF}(s)$)

De modo similar o polinômio característico em malha fechada é obtido da Eq. (66). A representação do problema é dada na forma de um produto interno que pondera os coeficientes do polinômio dos zeros no sistema de malha fechada e adicionado à dinâmica da planta por meio da FT (MOURA et al., 2019a). O polinômio característico do sistema de malha fechada pode ser expresso como

$$\begin{aligned}
 P_p^{MF}(s) = & s^{n+1} \\
 & + (a_1 + \langle K^{pid}, \bar{b}_0 \rangle) s^n \\
 & + (a_2 + \langle K^{pid}, \bar{b}_1 \rangle) s^{n-1} \\
 & + (a_3 + \langle K^{pid}, \bar{b}_2 \rangle) s^{n-2} \\
 & \vdots \quad \quad \quad \vdots \\
 & + (a_{n-2} + \langle K^{pid}, \bar{b}_{m-3} \rangle) s^3 \\
 & + (a_{n-1} + \langle K^{pid}, \bar{b}_{m-2} \rangle) s^2 \\
 & + (a_n + \langle K^{pid}, \bar{b}_{m-1} \rangle) s^1 \\
 & + (a_{n+1} + \langle K^{pid}, \bar{b}_m \rangle) s^0.
 \end{aligned} \tag{73}$$

Observe que as diagonais não são repetidas e variam de acordo com a ordem n do polinômio característico do sistema. A propagação dos ganhos são ponderações dos coeficientes do polinômio de zeros. A FT de malha fechada da planta é dada em termos do produto dos ganhos K_D , K_P and K_I com os coeficientes b_i , b_{i-1} e b_{i-2} da FT em malha fechada (MOURA et al., 2019a).

A forma geral do polinômio de denominador de malha fechada é dada por

$$P^{MF}(s) = s^{n_{MF}} + \sum_{i=1}^{n_{MF}-1} (a_i + \langle K^{pid}, \bar{b}_{i-1} \rangle) s^{n_{MF}-i}, \quad (74)$$

sendo $n_{MF} = n + n_{D-pid}$, $n_{D-pid} = 0, 1$ com $n_{D-pid} = 0$, a estrutura do controlador PID tem os termos derivado e proporcional. Quando $n_{D-pid} = 1$, a estrutura do controlador PID tem um termo integrador que aumenta a ordem do sistema em 1, começando com os três termos: proporcional, derivativo e integrativo (MOURA et al., 2019a), K^{pid} é o vetor de ganho que é dado por

$$K^{pid} = \begin{bmatrix} K_D & K_P & K_I \end{bmatrix}, \quad (75)$$

e vetor $\bar{b}_i$ do polinômio de zeros do sistema de malha fechada é dado por

$$\bar{b}_i = \begin{bmatrix} b_i \\ b_{i-1} \\ b_{i-2} \end{bmatrix}. \quad (76)$$

5.4.1.2 Matriz de Propagação

A matriz de propagação $\bar{B}$ é uma consequência da interação entre os ganhos $K^{pid} = (K_D, K_P, K_I)$ controlador PID e os parâmetros (b_i, a_i) da planta (MOURA et al., 2019a). A partir do polinômio do numerador na (71) obtém-se essa matriz que é dada por

$$\bar{B} = \begin{bmatrix} b_0 & 0 & 0 \\ b_1 & b_0 & 0 \\ b_2 & b_1 & b_0 \\ b_3 & b_2 & b_1 \\ \dots & \dots & \dots \\ b_m & b_{m-1} & b_{m-2} \\ 0 & b_m & b_{m-1} \\ 0 & 0 & b_m \end{bmatrix}. \quad (77)$$

Observa-se que a lei de formação da matriz de propagação (77) é regida por $m + 2$ linhas. As linhas representam a ordem do sistema, tendo início com a propagação na dinâmica de ordem $s^{n_{cl}}$ e finalizado na dinâmica de ordem s^0 zero (MOURA et al., 2019a). As colunas representam ação dos ganhos do controlador nos pólos e zeros dinâmica da planta (MOURA et al., 2019a).

5.5 Formulação do Problema Proposto

A partir do sistema de equações que representa as ações do controlador PID na dinâmica da planta, a formulação do problema de ajuste é estabelecida sob o ponto de vista do produto interno dos ganhos e coeficientes do polinômio dos zeros da FT de malha fechada. No caso do polinômio característico, o produto interno é adicionado ao seus coeficientes. Desta forma, o mecanismo de ajuste do ganhos é representado para alocações de zeros ou pólos.

Da Eq. (73), é montado o sistema de equações que tem como vetor de ganhos desconhecido K^{pid} e como especificações de projeto $a_i^s, i = 1, 2, \dots, n + 1$ (MOURA et al., 2019a). Na forma escalar, esse sistema de equações é representado por

$$a_i + \langle K^{pid}, \bar{b}_i \rangle = a_i^s. \quad (78)$$

O sistema escalar dado na Eq. (78) pode ser reescrito na forma matricial que é dado por

$$\bar{B}K^{pid} = \bar{a}, \quad (79)$$

sendo $\bar{a} = [a_1^e \ a_2^e \ \dots \ a_i^e \ \dots \ a_n^e \ a_{n+1}^e]^T$, com $a_i^e = a_i^s - a_i$ (MOURA et al., 2019a).

5.6 Modelos das Plantas

Os modelo das planta foram concebidos por meio de dados reais (intensidade da corrente elétrica dos acionamentos dos ALs e RC, velocidade de rotação dos ALs e Lanças das RPs e fluxo de carga em t/h) coletados durante o processo operacional das mesmas pelo PIMS, foram considerados como sinal de entrada das planta a intensidade da corrente elétrica dos motores dos acionamentos dos alimentadores para as plantas do processo operacional de VV e a intensidade da corrente do motor de acionamento da RC para planta do processo operacional de retomada de minério (MOURA; PINHEIRO,), (LOPES et al., 2012).

As plantas são representadas em modelos matemáticos por meio de suas FTs. São plantas primárias, a Planta I do processo operacional de descarregamento de vagões por VVs com um alimentador, a Planta II do processo de retomada de minério por RP e a Planta III do processo operacional de descarregamento de vagões por VVs com dois ALs. As plantas IV, V, VI e VII são obtidas combinando as plantas primárias, sendo a Planta IV a combinação da Planta I com a

Planta II, a Planta V, a combinação da Planta II com a Planta III, a Planta VI é o processo de retomada de minério com duas RPs simultâneas e a Planta VII refere-se processo operacional de descarregamento de vagões simultâneos por dois VVs com dois ALs.

5.6.1 Planta I

A planta I refere-se ao processo de descarregamento de vagões por VV com capacidade de 4000t/h e que só possui um AL, conforme ilustrado na Figura 21. Apesar do silo de abastecimento ter uma seção cônica, isso não influenciará no fluxo horário, pois a balança dinâmica é instalada na seção transversal de uma correia transportadora. É uma planta de segunda ordem, onde a entrada de referência $R(s)$ é a referência do inversor de frequência do acionamento do AL (intensidade da corrente elétrica do motor) e a saída $Y(s)$ é o sinal de referência da balança dinâmica (carga medida em t/h) que tem sua FT dada por


$$G^{PI}(s) = \frac{0,438s + 0,03861}{s^2 + 0,086096s + 0,04215}. \quad (80)$$

Na Tabela 1 apresenta-se o zero e os pólos da FT representada pela Eq. (82). Esta tem um zero, já que o numerador é de ordem um e dois pólos, visto que o denominador é de ordem 2.

Tabela 1 – Zero e o Pólos da Planta - I.


Zero	Pólos
-0,0882	-0,0430+0,2007i
-	-0,0430-0,2007i

Figura 21 – Planta I



O diagrama de blocos da Planta - I é ilustrado na Figura abaixo.

Figura 22 – Diagrama de blocos da Planta - I.



5.6.2 Planta II

A planta II refere-se ao processo operacional de uma retomadora de granéis com capacidade de 8000 t/h. Ilustra-se na Figura (23) a Planta II. Esta planta é de terceira ordem, onde a entrada de referência $R(s)$ é a referência do inversor de frequência do acionamento do RC (intensidade da corrente elétrica do motor) e a saída $Y(s)$ é o sinal de referência da balança dinâmica (carga medida em t/h), que tem sua FT dada por


$$G^{PII}(s) = \frac{0,1812s + 0,0871}{s^3 + 0,3553s^2 + 0,1117s + 0,01567}. \quad (81)$$

Na Tabela 2 apresenta-se o zero e os pólos da FT representada pela Eq. (81). Esta tem um zero, já que o numerador é de ordem um e três pólos, visto que o denominador é de ordem 3.

Tabela 2 – Zero e pólos da Planta - II.


Zero	Pólos
-0,4807	-0,0802+0,2720i
-	-0,0802-0,2720i
-	-0,1948

Figura 23 – Planta II.



O diagrama de blocos da Planta - II é ilustrado na Figura abaixo.


Figura 24 – Diagrama de blocos da Planta - II.



5.6.3 Planta III

A planta III refere-se ao processo de descarregamento de vagões por VVs com capacidade de 8000 t/h e que possui dois ALs, conforme ilustrado na Figura abaixo.


Figura 25 – Planta III.



A FT da Planta III é obtida pelas FTs em paralelo de cada alimentador, conforme Figura 26, onde $R(s)$ é a referência dos inversores de frequências dos acionamentos dos ALs 1 e 2

(intensidade da corrente elétrica dos motores) e a saída $Y(s)$ é o sinal de referência da balança dinâmica (carga medida em t/h), que tem sua FT representada pela a Eq. (85).

Figura 26 – Diagrama de blocos da Planta - III.



A FT da Planta III é obtida a seguir

$$G_1^{CD}(s) = \frac{0,438s + 0,03861}{s^2 + 0,086096s + 0,04215}, \quad (82)$$

$$G_2^{CD}(s) = \frac{0,521ss + 0,04715}{s^2 + 0,09066s + 0,2964}, \quad (83)$$

$$G^{PIII}(s) = G_1^{CD}(s) + G_2^{CD}(s). \quad (84)$$

Substituindo a Eq. (82) e Eq. (83) na Eq. (84), tem-se

$$G^{PIII}(s) = \frac{0,959s^3 + 0,1698s^2 + 0,1593s + 0,01331}{s^4 + 0,1767s^3 + 0,3463s^2 + 0,0293s + 0,0125}. \quad (85)$$

Na Tabela 3 apresenta-se os zeros e os pólos da FT representada pela Eq. (85).


Tabela 3 – Zeros e pólos da Planta - III.

Zeros	Pólos
-0,447+0,3953i	-0,0454+0,5425i
-0,447+0,3953i	-0,0454-0,5425i
-0,0877	-0,0430+0,2008i
-	-0,0430-0,2008i

5.6.4 Planta IV


A planta IV refere-se ao processo de descarregamento de vagões por VVs com capacidade de 4000 t/h simultâneo com o processo operacional de RP com capacidade de 8000 t/h, conforme ilustrado na Figura abaixo.

Figura 27 – Planta IV.



A FT da Planta IV é obtida pelas FTs em paralelo da Planta I com a Planta II, conforme ilustrado na Figura abaixo.

Figura 28 – Diagrama de blocos da Planta - IV.



$$G^{P_{IV}}(s) = G^{P_I}(s) + G^{P_{II}}(s). \quad (86)$$

Substituindo as Eqs. (80) e (81) na Eq. (86), tem-se que

$$G^{P_{IV}}(s) = \frac{0,438s^4 + 0,4522s^3 + 0,1331s^2 + 0,02924s + 0,001481}{s^5 + 1,806s^4 + 1,048s^3 + 0,2296s^2 + 0,02914s + 0,001031}. \quad (87)$$

Na Tabela 4 apresenta-se os zeros e os pólos da FT representada pela Eq. (87).


Tabela 4 – Zeros e os pólos da Planta - IV.

Zeros	Pólos
-0,5239+0,1861i	-0,8056
-0,5239-0,1861i	-0,7306
0,0077+0,1043i	-0,1088+0,1474i
0,0077-0,1043i	-0,1088-0,1474i
-	-0,0522

5.6.5 Planta V


A planta V refere-se ao processo de retomada de minério por duas RPs simultâneas com capacidade de 8000 t/h cada uma, conforme Figura 29.

Figura 29 – Planta V.



A FT da Planta V é obtida conforme ilustrada na Figura abaixo.

Figura 30 – Diagrama de blocos da Planta - V.



A FT da Planta V é obtida a seguir

$$G^{P_v}(s) = G^{P_{II}}(s) + G^{P_{II}}(s). \quad (88)$$

Substituindo a Eq. (81) na Eq. (88), tem-se que

$$P^V(s) = \frac{\begin{pmatrix} 0,3624s^4 + 0,31383s^3 + 0,1076s^2 \\ +0,025137s + 0,0027297 \end{pmatrix}}{\begin{pmatrix} s^6 + 0,7706s^5 + 0,37186s^4 + 0,11742s^3 \\ +0,024552s^2 + 0,0035007s + 0,00024 \end{pmatrix}}. \quad (89)$$

Na Tabela 5 apresenta-se os zeros e os pólos da FT representada pela Eq. (89).


Tabela 5 – Zeros e os pólos da Planta - V.

Zeros	Pólos
-0,4807	-0,0755+0,2663i
-0,0880+0,2591i	-0,0755-0,2663i
-0,0880-0,2591i	-0,1028+0,2530i
-0,2093	-0,1028-0,2530i
-	-0,2365
-	-0,1775

5.6.6 Planta VI


A planta VI refere-se ao processo de descarregamento de vagões por um VV com dois ALs simultâneo com o processo de retomada de minério por uma RP com capacidade de 8000 t/h cada um, conforme apresentado na Figura 31.

Figura 31 – Planta VI.



A FT da Planta VI é obtida conforme ilustrada na Figura a abaixo.

Figura 32 – Diagrama de blocos da Planta - VI.



A FT da Planta VI é obtida a seguir

$$G^{P_{VI}}(s) = G^{P_{II}}(s) + G^{P_{III}}(s). \quad (90)$$

Substituindo a Eq. (83) na Eq. (92), tem-se que

$$G^{P_{VI}}(s) = \frac{\begin{pmatrix} 0,959s^6 + 0,7205s^5 + 0,45096s^4 + 0,17365s^3 \\ +0,055978s^2 + 0,0073281s + 0,0010908 \end{pmatrix}}{\begin{pmatrix} s^7 + 0,562s^6 + 0,52608s^5 + 0,19814s^4 + 0,06524s^3 \\ +0,013516s^2 + 0,0018554s + 0,00019588 \end{pmatrix}}. \quad (91)$$

Na Tabela 6 apresenta-se os zeros e os pólos da FT representada pela Eq. (91).


Tabela 6 – Zeros e os pólos da Planta - VI.

Zeros	Pólos
-0,0031+0,4310i	-0,0499+0,5403i
-0,0031-0,4310i	-0,0499-0,5403i
-0,3194+0,2746i	-0,0301+0,3100i
-0,3194-0,2746i	-0,0301-0,3100i
-0,0532+0,1780i	-0,1953+0,1473i
-0,0532-0,1780i	-0,1953-0,1473i
-	-0,0115

5.6.7 Planta VII


A planta VII refere-se ao processo de descarregamento de vagões por dois VVs simultâneos com capacidade de 8000 t/h cada um, conforme apresentado na Figura 33.

Figura 33 – Planta VII.



A FT da Planta VII é obtida conforme ilustrada na Figura 34.

Figura 34 – Diagrama de blocos da Planta - VII.



A FT da Planta VII é obtida a seguir

$$G^{P_{VII}}(s) = G^{P_{VII}}(s) + G^{P_{VII}}(s). \quad (92)$$

$$G^{P_{VII}}(s) = \frac{\left(\begin{array}{l} 1,918s^7 + 0,67851s^6 + 1,0428s^5 + 0,23036s^4 \\ +0,1443s^3 + 0,013672s^2 + 0,0039903s + 3,3275 \times 10^{-6} \end{array} \right)}{\left(\begin{array}{l} s^8 + 0,3534s^7 + 0,72382s^6 + 0,18098s^5 + 0,15528s^4 \\ +0,024711s^3 + 0,009516s^2 + 0,0007325s + 0,00015625 \end{array} \right)}. \quad (93)$$

Na Tabela 7 apresenta-se os zeros e os pólos da FT representada pela a Eq. (93).

Tabela 7 – Zeros e os pólos da Planta - VII.

Zeros	Pólos
-0,0454+0,5425i	-0,0472+0,5427i
-0,0454-0,5425i	-0,0472-0,5427i
-0,0881+0,3977i	-0,0435+0,5422i
-0,0881-0,3977i	-0,0435-0,5422i
-0,430+0,2008i	-0,436+0,2009i
-0,430-0,2008i	-0,436-0,2009i
-0,0008	-0,0424+0,2008i
-	-0,0424-0,2008i

Capítulo 6

Sintonia Inteligente de Controladores PID Baseada em Modelo

No contexto de uma arquitetura de controle com algoritmos adaptativos e aprendizado de máquina, o desenvolvimento de uma rede RNA-E associada a sintonia *online* e ótima de controladores PID é apresentada neste capítulo. Os modelos e algoritmos propostos da rede neuronal são associados com estratégias de alocação de pólos para estabelecer novos pontos de operação ou para compensar variações paramétricas na planta que são detectadas por meio de sensores e estimadores.

A formulação proposta permite otimizar, além das especificações técnicas, as especificações de projeto que estão relacionadas com custos da operação e da manutenção do sistema. Além disso, os algoritmos promovem a tomada de decisão de forma autônoma e eficiente contribuindo com a evolução tecnológica. Desta forma, as ações dos controladores PID impõem otimalidade nas figuras de mérito e promovem redução dos custos operacionais. A eficiência dos algoritmos propostos para sintonia *online* e ótima é avaliada para projeto de controladores PID em sistemas industriais do setor de mineração, no controle de vazão de retomadoras de granéis sólidos.

São apresentadas as abordagens de sintonia *online* e ótima de controladores PID baseadas em modelos embasadas em IC, abordando-se dois modelos: o primeiro, trata-se da sintonia *online* e ótima de controladores PID por meio de uma RNA-E e o segundo, faz-se uma combinação da RNA-E com regras *fuzzy*, onde a RNA-E determina os ganhos do controlador PID por meio do ajuste dos parâmetros do polinômio característico e as regras *fuzzy* fazem o escalonamento dos parâmetros do vetor de ganhos K^{pid} ajustando-os *online*.

6.1 RNA-E para Sintonia Online e Ótima de Controladores PID

O desempenho de um sistema de controle é avaliado não só pelo atendimento as especificações técnicas de projeto, tais como: máximo *overshoot*, tempos de acomodação e de subida e

as margens de ganho e de fase, mas também pelos custos operacionais e de manutenção, como também pela capacidade de rejeição às perturbações e de adaptar-se às variações paramétricas da planta inerentes ao processo. Uma maneira de avaliar o desempenho é por meio da relação custo/benefício que pode ser utilizada medindo a produtividade e a eficiência do processo operacional por meio do sistema de controle. Para suprir a demanda de dispositivos de controle que minimizem a relação custo/benefício, são propostos modelos e algoritmos baseados em RNA-E para a sintonia *online* e ótima de controladores PID no plano s , chamado de controlador PID_{RNA-E} , como também, justificativas para implantação destes dispositivos no parque industrial.

Os modelos e algoritmos propostos para sintonia ótima do controlador PID_{RNA-E} possuem os atributos de otimalidade e ajuste *online* dos seus parâmetros. O produto resultante é caracterizado como um dispositivo do tipo *Electronic Intelligent Device* (EID) para ajuste de ganhos de sistemas de controle e seus algoritmos de treinamento (HAYKIN, 1994), desta forma a proposta está alinhada com os requisitos de operação autônoma de equipamentos industriais e de acordo com os conceitos da indústria 4.0 (BECKER et al., 2018) (LEE et al., 2014) (LASI et al., 2014). No caso, o controlador PID_{RNA-E} está inserido nos esquemas adaptativos do tipo *Self Tuning Regulator* (STR) para atuar em plantas industriais (ÅSTRÖM et al., 2012) (ÅSTRÖM et al., 2006). Para problemas que ocorrem devido as incertezas paramétricas na planta de origem, novas estratégias de controle para alocação de pólos e ajuste fino para recuperação de parâmetros da FT da planta por meio da sintonia *online* e ótima dos ganhos do controlador PID_{RNA-E} são apresentadas nesta Tese. Os modelos propostos têm por objetivo, principal, minimizar as variações do coeficiente de amortecimento de pólos dominantes, garantir robustez para variações e perturbações paramétricas na planta, minimizando o esforço de controle.

Dentre as diversas abordagens de aprendizado de máquina, optou-se pelas RNA-E do tipo *feedforward* que representa o controlador PID, e dos algoritmos de treinamentos que baseiam-se em RNA-E e no gradiente que têm a capacidade de executarem cálculos de alto desempenhos com baixo custo computacional. Em termos de contextualização da proposta de sintonia *online* e ótima de controladores PID no universo das RNA, o algoritmo de treinamento da rede neural *feedforward* é desenvolvido como um problema de controle PID. No entanto, as técnicas de otimização de *Linear Matrix Inequalities* (LMI) são utilizadas para obtenção dos parâmetros e garantir robustez nos controladores (JING; CHENG, 2013).

Os principais conceitos das abordagens de RNA, aprendizado supervisionado e identificação de sistemas que estão associados com o desenvolvimento teórico e aplicações do projeto *online* e ótimo de controladores PID são apresentados e discutidos nesta Secção. Os modelos da planta e do controlador PID são descritos na forma de FT no plano s .

Inicialmente, o problema da sintonia de controladores PID é remetido as suas origens que são os estudos a respeito de compensadores polinomiais e com problema, fortemente, relacionado com a especificação de parâmetros projetados para atender as restrições operacionais da planta (ÅSTRÖM; WITTENMARK, 2013). Nesta tese, o controlador PID é apresentado como uma

forma particularizada dos compensadores no plano s .

Em livros e artigos, observa-se uma vasta quantidade de publicações de cunho científico, técnico e didático em torno do problema de sintonia de controladores PID. Várias referências salientam a importância do desenvolvimento de métodos e sistematização de suas aplicações em processos industriais, buscando o atendimento dos avanços tecnológicos com as suas ações PID, o desafio da sintonia que foi iniciado aproximadamente desde 1920 e persiste até os dias atuais, com as mais variadas arquiteturas e técnicas de sintonia que representam as ações PID (O'DWYER, 2009)

Os controladores PID se adaptam as necessidades das citadas ações que podem ser traduzidas como uma combinação de proporcionalidades, atrasos e avanços do sinal de erro. Contudo, ainda existem desafios tecnológicos para serem resolvidos. No que diz respeito a dotar os dispositivos de controle com inteligência, ie, desenvolver modelos e algoritmos para tais dispositivos que são caracterizados como EID, desta forma, a proposta apresentada neste artigo, tende a contribuir para indústria 4.0 com unidades planejadoras e tomadoras de decisão com propriedades de otimalidade, robustez e adaptabilidade (LEE et al., 2014) (LASI et al., 2014). Estas unidades baseiam-se nas tecnologias de controle digital e sistema embarcados em tempo real para implantações confiáveis (MARWEDEL, 2017), (KOPETZ, 2011) e (FADALI; VISIOLI, 2012).

Para atender as citadas demandas de projeto, a solução proposta está relacionada com as abordagens de controle ótimo e adaptativo. Desta forma, as ações de controle além de fornecerem otimalidade para as figuras de mérito, ainda, garantem uma solução ótima, que além de atender os requisitos de projetos, ainda, minimizam os esforços de controle e os custos computacionais.

6.1.1 Algoritmos de Treinamentos

O controlador PID paralelo é associado com a RNA do tipo *feedforward* com função de ativação do tipo linear por partes e o seus algoritmos treinamentos é uma RNA-E e o gradiente do erro. (HAM; KOSTANIC, 2000). Para fins de aplicações no mundo real os limites inferior e superior da função de ativação linear por partes, isto é, as saturações dos dispositivos que implementam o controle.

O algoritmo de treinamento RNA-E para sintonia *online* e ótima de controladores PID no plano s é aplicado no controlador PID paralelo que assume a forma da conexão de nerônios elementares que representam o processamento da estrutura ou topologia para computação dos ganhos e os seus ajustes são guiados pelos algoritmos de treinamento. Os modelos propostos tem por base o aprendizado supervisionados. Estes modelos são desenvolvidos para treinar as máquinas de aprendizado do tipo RNA *feed-forward perceptron*.

6.1.2 Formulação da RNA-E

A RNA-E é formulada para atuar diretamente nos ajustes dos coeficientes a_i e indiretamente nos coeficientes b_i da FT $G_p(s)$ da planta, determinando os parâmetros do vetor de ganhos K^{pid} , sendo o modelo de ordem n com m zeros. A RNA-E dada na Eq. (78) é usada para determinar o vetor de ganho K^{pid} que atende às especificações de projeto. Observando a Eq. (78), vê-se que o procedimento consiste em calcular os elementos do vetor K^{pid} que deve atender aos novos parâmetros a_i^s da FT do estimador. Resolvendo o sistema de equações, onde o número de equações é maior que o número de incógnitas ($n > m$), por meio do método dos mínimos quadrados, tem-se

$$\min_{0 < K^{pid} < \infty} \|e(K^{pid})\|_2^2, \quad (94)$$

sendo $e(K^{pid})$ o erro da função, que é dado por

$$e(K^{pid}) = \bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{a}. \quad (95)$$

Para minimizar o erro da estrutura de otimização dada por (94), a função custo de erro é montada a partir da norma euclidiana da Eq. (95), onde o erro é minimizado pela função de custo que é dada por

$$\mathcal{E}(K^{pid}) = \frac{1}{2} \|\bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{a}\|_2^2. \quad (96)$$

Inspirado pelo método de descida mais íngreme, a solução deste problema é dada pela regra de treinamento de RNA-E (HAM; KOSTANIC, 2000) que é dada por

$$\frac{\partial \mathcal{E}(K^{pid})}{\partial t} = -\mu \nabla \mathcal{E}(K^{pid}). \quad (97)$$

O gradiente $\nabla \mathcal{E}(K^{pid})$ da Eq. (97) é obtido a partir das derivadas da Eq. (96) que é dado por

$$\nabla \mathcal{E}(K^{pid}) = \bar{B}^T \bar{B} (\bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{a}). \quad (98)$$

Substituindo o gradiente da Eq. (97) na Eq. (98), obtém-se a equação da regra de treinamento que governa o cálculo do vetor de ganho K^{pid} para os novos parâmetros $\bar{a}$ do polinômio característico, que é dado por


$$\frac{\partial \mathcal{E}(K^{pid})}{\partial t} = -\mu (\mathbb{A} K^{pid} - \mathbb{B} \bar{a}), \quad (99)$$

sendo $\mathbb{A} = \bar{B}^T \bar{B} \bar{B}^T \bar{B}$ e $\mathbb{B} = \bar{B}^T \bar{B} \bar{B}^T$.

6.1.3 Algoritmo RNA-E

O algoritmo RNA-E é concebido para atuar em um esquema de controle adaptativo do tipo STR. Na Figura 35 ilustra-se a arquitetura do algoritmo RNA-E para determinar os ganhos K^{pid} do controlador resolvendo a Eq. (79).

Figura 35 – Arquitetura de RNA-E para resolver um sistema de equação K^{pid} .



As estratégias para sintonia dos ganhos do controlador PID por uma RNA-E são implementadas de modo que o treinamento do algoritmo da RNA-E determine *online* os ganhos do controlador PID para alterações no comportamento dinâmico da planta. O cálculo do gradiente da Eq. (98) dado por

$$\nabla_{K^{pid}} \varepsilon K^{pid} = \bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{b}_i. \quad (100)$$

O algoritmo do sistema de controle foi dividido em 6 módulos para melhor entendimento, conforme é apresentado no Algoritmo PID_{RNA-E} a seguir

ALGORITMO PID_{RNA-E}

```

1  ▷ - Modulo 0 - Setup (Condições Iniciais)
2  ▷ Taxa de Aprendizado -  $\eta \leftarrow [ \quad ]$ 
3  ▷ Parâmetros da Função de Transferência -  $[b_i, a_i] \leftarrow [ \quad ]$ 

```

```

4  ▷ Processo Iterativo
5  for  $i \leftarrow 0 : N$ 
6      do

```

```

7          ▷ - Modulo 1 - Sensores
8          ▷ a) leituras- u e y
9           $[y, x] \leftarrow ler_{xy}(x, y, p_x y)$ 

```

```

10         ▷ - Modulo 2 - Estimador RLS de parâmetros da planta
11          $b(i) \leftarrow num_{3p}(1, i)$ 
12          $a(i) \leftarrow den_{3p}(1, i);$ 

```

```

13         ▷ - Modulo 3 - Especificações de Projeto
14          $[V_\zeta, V_{\omega_n}] \leftarrow [par_1, ..., par_3]$ 

```

```

15         ▷ - Modulo 4 - Comparador entre os coeficientes
16          $[\Delta(ab)] \leftarrow [(a_i, b_i), (a_i^s, \bar{b}_i), par_{ab}]$ 

```

```

17         ▷ - Modulo 5 - Sintonia Adaptativo e Ótimo
18          $[K^{pid}] \leftarrow f_{RNA}(K_P, K_I, K_D, \Delta(ab))$ 

```

```

19         ▷ - Modulo 6 - Esquemas Transferência dos Ganhos  $K^{pid}$ 
20          $[PID_{cont}] \leftarrow K^{pid}$ 

```

```

21  Fim do Processo Iterativo

```

As estratégias para sintonia dos ganhos do controlador PID por uma RNA-E são implementadas no Módulo 5 do PID_{RNA-E} Algoritmo, neste módulo, se ocorrer divergência entre os parâmetros das FTs especificada e a levantada pelo método RLS, os ganhos são ajustados *online*. Os parâmetros para ajuste da RNA-E, chamados de parâmetros de treinamento da RNA, são os coeficientes de aprendizado μ_{Aprend} .

O limite da quantidade de iterações para obter a aproximação desejada para os novos ganhos K^{pid} é $n_{iter-RNA}$, este limite depende dos prazos da disponibilidade de tempo para apresentar e transferir os novos ganhos. Os ganhos iniciais do processo iterativo são armazenados em x_{pid_0} e Δ_T , que é a constante de integração do treinamento.

O módulo 5 expandido mostra o processo iterativo da da RNA-E para determinar o vetor de ganhos K^{pid} .

MODULO 5 - SINTONIA ADAPTATIVA E ÓTIMA

1 $[K^{pid}] \leftarrow f_{RNA}(K_P, K_I, K_D, \Delta(ab))$

2 $\triangleright$ Processo Iterativo3 **for** $i \leftarrow 0 : N$ 4 **do**5 $\triangleright$ Treinamento6 $\triangleright$ Cálculo de B7 $a_i^s \leftarrow \mu \bar{B}^T \bar{B} \bar{B}^T$ 8 $a_i \leftarrow \mu \bar{B} \bar{B}^T$ 9 $a_i^e \leftarrow a_i^s - a_i$ 10 $e_{int} \leftarrow \int e_i dt + K_0^{pid}$ 11 $K^{pid} \leftarrow \bar{B} \bar{B}^T e_{int}$

12 Fim do Processo Iterativo

13 Fim do Modulo 5

Modulo 6 - Algoritmo de transferência dos ganhos: implementa a transferência dos ganhos K_{PID} para o controlador PID paralelo que é visto como uma RNA *feedforward*. O modulo Esquema de Transferência dos Ganhos K^{pid} implementa a escrita do novo ganho no controlador PID paralelo.

MODULO 6 - ALGORÍTMO DE TRANSFERÊNCIA DOS GANHOS

1 $\triangleright$ - Modulo 6 - Esquema de Transferência dos Ganhos K^{pid}
2 $\triangleright$ - $[PID_{cont}] \leftarrow K^{pid}$

3 End of Modulo 6

ALGORITMO PID-RNA-ESTRUT-STR

```

1  ▷ - Modulo 0 - Setup (Condições Iniciais)
2  ▷ Taxa de Aprendizizado -  $\eta \leftarrow [ \quad ]$ 
3  ▷ Parâmetros da Função de Transferência -  $[b_i, a_i] \leftarrow [ \quad ]$ 

```

```

4  ▷ Processo Iterativo
5  for  $i \leftarrow 0 : N$ 
6      do

```

```

7          ▷ - Modulo 1 - Sensores
8          ▷ a) leituras - u e y
9           $[y, x] \leftarrow ler_{xy}(x, y, p_x y)$ 

```

```

10         ▷ - Modulo 2 - Estimador RLS de parâmetros da planta
11          $b(i) \leftarrow num_{3p}(1, i)$ 
12          $a(i) \leftarrow den_{3p}(1, i);$ 

```

```

13         ▷ - Modulo 3 - Especificações de Projeto
14          $[V_\zeta, V_{\omega_n}] \leftarrow [par_1, ..., par_3]$ 

```

```

15         ▷ - Modulo 4 - Comparador entre os coeficientes
16          $[\Delta(ab)] \leftarrow [(a_i, b_j), (a_i^s, \bar{b}_j), par_{ab}]$ 

```

```

17         ▷ - Modulo 5 - Sintonia Adaptativa e Ótimo
18          $[K^{pid}] \leftarrow f_{RNA}(K_P, K_I, K_D, \Delta(ab))$ 

```

```

19         ▷ - Modulo 6 - Esquemas de Transferência dos Ganhos  $K_{PID}$ 
20          $[PID_{cont}] \leftarrow K^{pid}$ 

```

```

21     im do Processo Iterativo

```

As funcionalidades de sensoriamento das grandezas para levantamento dos parâmetros da planta e da realimentação da saída são implementadas no modulo *Algoritmos dos Sensores*. No caso dos sensores para aquisições: a) ações de controle u , e b) saídas da planta y .

ALGORITMO DO SENSOR

```

1  ▷ - Modulo 1 - Sensores
2  ▷ a) leituras- u e y
3   $[y, x] \leftarrow ler_{xy}(x, y, p_x y)$ 

```

```

4  Fim do Modulo 1

```

O estimador *online* de parâmetros da FT da planta é implementa pelo algoritmo *recursive least squares* (RLS). A entradas para este modulo são os sinais de controle $u(\cdot)$ e saída $y(\cdot)$.

ESTIMADOR RLS

-
- 1 ▷ - Modulo 2 - Estimador RLS de parâmetros da planta
 - 2 $b(i) \leftarrow num_3p(1, i)$
 - 3 $a(i) \leftarrow den_3p(1, i);$
-
- 4 Fim do Modulo 2
-

O *Algoritmo Especificações de Projeto* implementa a leitura do processamento da informação para realizar a comparação entre os novos coeficientes especificados e os coeficientes da FT de malha fechada. Neste caso, esse módulo tem como entrada as frequências naturais não amortecidas e o coeficientes de amortecimento associado com cada pólo.

MODULO 3 E 4 - ALGORÍTMO DE ESPECIFICAÇÃO DE PROJETO

-
- 1 ▷ - Especificações de Projeto
 - 2 $[V_\zeta, V_{\omega_n}] \leftarrow [par_1, \dots, par_3]$
 - 3 $[\bar{b}_j, a_i^s] \leftarrow [V_\zeta, V_{\omega_n}, par(ab)]$
-
- 4 ▷ - Comparador entre os coeficientes
 - 5 $[\Delta(ab)] \leftarrow [(a_i, b_j), (a_i^s, \bar{b}_j), par\Delta(ab)]$
-
- 6 Fim dos Modulos 3 e 4
-

6.1.3.1 Modulo 5 - Algoritmo de Treinamento do K^{pid} Ótimo

Os parâmetros para ajuste da RNA-E, chamados de parâmetros de treinamento da RNA, são os coeficientes de aprendizado μ_{Aprend} . O limite da quantidade de iterações para obter a aproximação desejada para os novos ganhos K^{pid} é $n_{iter-RNA}$, este limite depende dos prazos da disponibilidade de tempo para apresentar transferir os novos ganhos. O ganhos iniciais do processo iterativo são armazenados em x_{pid_0} e Δ_T é a constante de integração do treinamento.

O cálculo da matriz de propagação antecede ao processo iterativo para determinação dos ganhos, observa-se que os elementos desta matriz são determinados a partir dos coeficientes do polinômio do denominador do modelo da planta. Seguido a este cálculo, observa-se, no referido, algoritmo, o cálculo do erro e do gradiente do processo iterativo para sintonia controlador PID via RNA-E.

ALGORITMO PID-RNA-E

```

1  ▷ - Modulo 5 - Sintonia Adaptativo e Ótimo
2   $[K^{pid}] \leftarrow f_{RNA}(K_P, K_I, K_D, \Delta(ab))$ 

```

```

3  ▷ Processo Iterativo
4  for  $i \leftarrow 0 : N$ 
5      do
6          ▷ Treinamento
7          ▷ Cálculo de B
8           $a_i^s \leftarrow \mu \bar{B}^T \bar{B} \bar{B}^T$ 
9           $a_i \leftarrow \mu \bar{B} \bar{B}^T$ 
10          $a_i^e \leftarrow a_i^s - a_i$ 
11          $e_{int} \leftarrow \int e_i dt + K_0^{pid}$ 
12          $K^{pid} \leftarrow \bar{B} \bar{B}^T e_{int}$ 

13  Fim do Processo Iterativo

```

```

14  Fim do Modulo 5

```

6.1.3.2 Modulo 6 - Algoritmo de Transferência de Ganhos

O modulo Algoritmo de transferência de ganhos implementa os parâmetros do novo vetor de ganhos no controlador PID paralelo.

MODULO 6 - ALGORITMO DE TRANSFERÊNCIA DE GANHOS

```

1  ▷ - Modulo 6 - Esquemas Transferência dos Ganhos  $K^{pid}$ 
2  ▷ -  $[PID_{cont}] \leftarrow K^{pid}$ 

```

```

3  Fim do Modulo 6

```

O algoritmo adaptativo para compensação de variações dos parâmetros da planta proposto é apresentado nesta secção. Este algoritmo é guiado pela matriz de propagação das ações PID para trazer o sistema para o ponto de operação especificado em projeto, diferente do problema da determinação dos ganhos PID para um novo ponto de operação da Eq. (73). Para fins de projeto de compensação paramétrica, o polinômio característico com coeficientes a_i^s especificados no projeto é dado por

$$\hat{P}^{CL}(s) = s^{n_{CL}} + \sum_{i=1}^{n_{CL}-1} (a_i^s + \langle K^{pid}, \bar{b}_{i-1} \rangle) s^{n_{CL}-1}. \quad (101)$$

De acordo com Figura 38, no caso de divergência entre os coeficientes das FT, a RNA-E determina novos ganhos PID. Desta forma que as variações do parâmetros da planta são compensados pelo novo projeto. Os coeficientes $(\bar{a}_i, \bar{b}_i)$ são os parâmetros especificados e $(\bar{a}'_i, \bar{b}'_i)$ são os parâmetros da planta com perturbação. Se não houver divergência entre $(\bar{a}_i, \bar{b}_i)$ e $(\bar{a}'_i, \bar{b}'_i)$, saída da RNA-E sintoniza os ganhos K^{pid} que são ajustados *online* via o chaveamento para

1. Caso ocorra divergência, os novos ganhos $\bar{K}^{pid}$ são ajustados *online* via chaveamento para 2, recuperando o comportamento especificado da planta.

Levando em consideração que uma perturbação paramétrica na Eq. (101) que é Δa_i nos parâmetros (a_i, b_j) da planta. Em termos de variações paramétricas aditivas, o polinômio característico da planta perturbada é dado por

$$\hat{P}^{CL}(s) = s^{n_{CL}} + \sum_{i=1}^{n_{CL}-1} (\bar{a}_i + \Delta a_i + \langle K^{pid}, \bar{b}_{i-1} \rangle) s^{n_{CL}-1}. \quad (102)$$

Generalizando os coeficientes $a_i + \Delta a_i = \bar{a}'_i$ da Eq. (102) e para fins de elaboração do algoritmo, todos os seus coeficientes são representados pela relação indexada que é dada por

$$\bar{a}_i + \langle K^{pid}, \bar{b}_i \rangle = \bar{a}'_i, \quad (103)$$

sendo $\bar{a}'_i$ o i -ésimo coeficiente da perturbação paramétrica.

O i -ésimo vetor de erro $\bar{e}_i$ é dada por

$$\bar{e}_i = \bar{a}_i - \bar{a}'_i. \quad (104)$$

O ajuste do ganhos do controlador adaptativo para compensação das variações paramétricas que são detectadas, de forma generalizada, por meio das alterações nos coeficientes do polinômio característico especificado para uma dada operação da planta malha fechada.

A comparação entre os coeficientes dos polinômios característicos da planta em malha fechada dado na Eq. (74) e o polinômio característico especificado dado na Eq. (102), é dado por

$$\varepsilon = P^{CL} - \hat{P}^{CL}, \quad (105)$$

sendo ε o vetor com os erros do coeficientes dos polinômios.

6.1.3.3 Algoritmo de perturbação paramétrica K_{PID}

ALGORITMO PID-RNA-E

```

1  ▷ Setup (Condições Iniciais)
2  ▷ Taxa de Aprendizado -  $\eta \leftarrow [ \quad ]$ 
3  ▷ Parâmetros da Função de Transferência -  $[b_i, a_i] \leftarrow [ \quad ]$ 

```

```

4  ▷ Processo Iterativo
5  for  $i \leftarrow 0 : N$ 
6      do
7          ▷ Controle e Simulador da planta
8          Ação de Controle PID
9           $u_i \leftarrow K_i x_i$ 
10         ▷ Planta
11          $y_{i+1} \leftarrow$ 
12         ▷ Estimação de Parâmetros
13          $\bar{x}_i \leftarrow [x_{1i}^2; x_{1i}x_{2i}; \dots; x_{4i}^2]$ 
14         ▷ Treinamento
15         ▷ Cálculo de B
16          $\bar{a}_i = \mu \bar{B}^T \bar{B} \bar{B}^T$ 
17          $a_i = \bar{\mu} \bar{B} \bar{B}^T$ 
18          $e_i = \bar{a}_i - a_i$ 
19          $e_{int} = \int e_i dt + K_0^{pid}$ 
20          $K^{pid} = \bar{B} \bar{B}^T e_{int}$ 

```

```

21  Fim do Processo Iterativo

```

6.1.4 Algoritmo do Gradiente do Erro

Apresenta-se a regra de aprendizado de gradiente conjugado para resolver sistemas de equações lineares (DAX, 1990) (HIGHAM, 2002). Para o algoritmo de gradiente conjugado *Fletcher-Reeves* com uma capacidade de reinicialização (ou seja, uma etapa de descida mais íngreme após cada n iterações). Portanto, resolve-se o sistema de equação linear, que é dado por

$$Ax = b, \quad (106)$$

sendo $A \in \mathbb{R}^{m \times n}$, $x \in \mathbb{R}^n$ e $b \in \mathbb{R}^m$, com $m \geq n$, isto é, um sistema sobredeterminado ou exatamente determinado. Colocando-se o problema de sintonia do controlador PID abordado nesta Secção na forma da Eq. (106), tem-se que

$$\bar{B}K^{pid} = \bar{b}_i. \quad (107)$$

Primeiramente, para incorporar o método do gradiente conjugado na regra de aprendizado de tempo discreto, deriva-se αK^{pid} na expressão de atualização para a iteração K^{pid} . Na etapa 4 do algoritmo gradiente conjugado de *Fletcher-Reeves*, a atualização da solução é dada por

$$K^{pids} = K^{pid} + \alpha dK^{pid}, \quad (108)$$

sendo

$$\alpha K^{pid} = \min_{K^{pid}} \varepsilon(K^{pid} + \alpha K^{pid} + dK^{pid}) \quad (109)$$

O vetor dK^{pid} é o vetor de direção atual e é a função objetivo. Neste trabalho, a função objetivo é dada na Eq. (96),

sendo $\bar{B}K^{pid} = \bar{b}_i + e$, isolando o erro e , tem-se que

$$e = \bar{B}K^{pid} - \bar{b}_i. \quad (110)$$

Então,

$$\begin{aligned} \mathcal{E}(K^{pid} + \alpha dK^{pid}) &= \frac{1}{2} [\bar{B}(K^{pid} + \alpha K^{pid}) - eK^{pid}]^T \\ &\quad \times [\bar{B}(K^{pid} + \alpha K^{pid}) - eK^{pid}] \\ &= \frac{1}{2} (K^{pid})^T \bar{B}^T \bar{B} K^{pid} \alpha (K^{pid})^T \bar{B}^T \bar{B} dK^{pid} \\ &\quad - (K^{pid})^T \bar{B}^T e K^{pid} + \alpha (K^{pid})^T \bar{B}^T \bar{B} K^{pid} \\ &\quad + \alpha^2 K^{pid} \bar{B}^T \bar{B} K^{pid} - \alpha (K^{pid})^T \\ &\quad \times \bar{B}^T e K^{pid} - (eK^{pid})^T \bar{B} x_k \\ &\quad - \alpha (eK^{pid})^T \bar{B} d_k + (eK^{pid})^T e K^{pid}. \end{aligned} \quad (111)$$

É preciso calcular o gradiente da Eq. (98) em relação a α e definir o resultado igual a zero

$$\begin{aligned} \nabla_{\alpha} \varepsilon(K^{pid} + \alpha K^{pid}) &= \frac{\partial (K^{pid} + \alpha K^{pid})}{\partial \alpha} \\ &= (K^{pid})^T \bar{B}^T \bar{B} K^{pid} + \alpha d(K^{pid})^T \\ &\quad \times \bar{B}^T \bar{B} K^{pid} - d(K^{pid})^T \bar{B}^T e K^{pid} = 0. \end{aligned} \quad (112)$$

Resolvendo para α da Eq. (112) e fazendo $\alpha \rightarrow \alpha K^{pid}$ tem-se que

$$\begin{aligned} \alpha K^{pid} &= \frac{d(K^{pid})^T \bar{B}^T e K^{pid} - d(K^{pid})^T \bar{B}^T \bar{B} K^{pid}}{d(K^{pid})^T \bar{B}^T \bar{B} dK^{pid}} \\ &= \frac{d(K^{pid})^T \overbrace{[\bar{B}^T e K^{pid} - \bar{B}^T \bar{B} K^{pid}]}^{-g_{K^{pid}}}}{d(K^{pid})^T \bar{B}^T \bar{B} dK^{pid}} \\ &= \frac{-d(K^{pid})^T g_{K^{pid}}}{d(K^{pid})^T \bar{B}^T \bar{B} d(K^{pid})}, \end{aligned} \quad (113)$$

ou

$$\alpha K^{pid} = \frac{(-g_{K^{pid}})^T dK^{pid}}{d(K^{pid})^T \bar{B}^T \bar{B} dK^{pid}}, \quad (114)$$

sendo g_k o gradiente da Eq. (96), que é dado por

$$g_{K^{pid}} = \nabla_{K^{pid}} \varepsilon K^{pid} = \bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{b}_i. \quad (115)$$

Portanto, o algoritmo de gradiente conjugado de *Fletcher-Reeves* para resolver $\bar{B} K^{pid} - \bar{b}_i$ é resumido nos seguintes passos

Fletcher-Reeves - ALGORITMO CONJUGADO PARA RESOLVER $\bar{B} K^{pid} = \bar{b}_i$

▷ **Passo 1.** Condição inicial K_0^{pid} .

▷ **Passo 2.** Condição $g_{K_0^{pid}}$

$$\begin{aligned} dg_{K^{pid}}|_{K^{pid}=0} &= g_{K_0^{pid}} \\ &= \bar{B}^T \bar{B} \left(\bar{B}^T \bar{B} K_0^{pid} - \bar{B}^T e K_0^{pid} \right). \end{aligned}$$

▷ **Passo 3.** Condição inicial $dK_0^{pid} = -g_{K_0^{pid}}$.

▷ **Passo 4.** Cálculo de dK_s^{pid}

$$\begin{aligned} dK_s^{pid} &= K^{pid} + \alpha K^{pid} dK^{pid}, \quad \text{where} \\ \alpha K^{pid} &= -g_{K^{pid}}^T - g_{K^{pid}}^T \left(d(K^{pid})^T \bar{B}^T \bar{B} dK^{pid} \right). \end{aligned}$$

▷ **Passo 5.** Cálculo de $g_{K^{pid}}$

$$g_{K^{pid}} = \bar{B}^T \bar{B} K_s^{pid} - \bar{B}^T e K^{pid}.$$

▷ **Step 6.** Cálculo de dK_s^{pid}

$$\begin{aligned} dK_s^{pid} &= -g_{K_s^{pid}} + \beta_{K^{pid}} d_{K^{pid}}, \quad \text{sendo} \\ \beta_{K^{pid}} &= \frac{g_{K_s^{pid}}^T g_{K_s^{pid}}}{(g_{K^{pid}}^T g_{K^{pid}})}. \end{aligned}$$

▷ **Passo 4 até 6.** são realizados para $k = 0, 1, \dots, n-1$.


▷ **Passo 7.** Substitui K_0^{pid} por K_N^{pid} no passo 1.

▷ **Passo 8.** Continua até que a convergência seja alcançada;

Critério de finalização $\|d_k\| < \mathcal{E}$ (sendo $\mathcal{E}$
é um número pequeno predeterminado apropriado).

O algoritmo de treinamento de Eq. (115) determina os parâmetros a_i^s da FT em malha fechada, assegurando que os ganhos K^{pid} são ótimos, conforme ilustrado na Figura 36.

Figura 36 – Arquitetura de RNA-E para o algoritmo conjugado na solução um sistema de equação K^{pid^s} .




6.1.5 Algoritmo de Compensação Paramétrica Adaptativa de Projeto

O algoritmo adaptativo para compensação de variações dos parâmetros da planta proposto é apresentado nesta Seção. Este algoritmo é guiado pela matriz de propagação das ações PID para trazer o sistema para o ponto de operação especificado em projeto, diferente do problema da determinação dos ganhos PID para um novo ponto de operação da Eq. (73), isto é, para fins de projeto de compensação paramétrica, o polinômio característico com coeficientes a_i^s especificados no projeto é dado por

$$P^{MF^s}(s) = s^{n_{MF}} + \sum_{i=1}^{n_{MF}-1} (a_i^s + \langle K^{pid}, \bar{b}_{i-1} \rangle) s^{n_{MF}-1}. \quad (116)$$


No processo de sintonia de controladores PID por meio de uma RNA-E para compensação das variações paramétricas é ilustrado na Figura 37. Os novos ganhos K^{pid} são determinados por meio dos parâmetros da FT da planta. Na ocorrência de perturbações nos parâmetros da planta, estes são comparados com os coeficientes das FTs da planta durante sua operação.

Figura 37 – Arquitetura do controlador PID-RNA e unidade treinamento.



De acordo com o PID_{RNA-E} Algoritmo exibido no Módulo - 0, apresenta-se na Figura 38 a configuração da RNA-E para a recuperação dos coeficientes a_i^s da função de transferência da planta e consequentemente o vetor de ganhos do controlador PID recuperado pelo novo vetor de ganhos K_N^{pid} seguindo o seguinte procedimento: no caso de divergências entre os coeficientes das funções de transferências, a rede neural ajusta os parâmetros a_i da função de transferência e recupera o vetor de ganhos K_R^{pid} , desta forma que as variações do parâmetros da planta são compensados pelo novo projeto. Os coeficientes a_i^s são os parâmetros especificados e a_i^p são os parâmetros da planta com perturbação. Se não houver divergência entre a_i^s e a_i^p a RNA-E sintoniza o vetor de ganhos K^{pid} que são ajustados *online* via o chaveamento para 1. Caso ocorra divergência, os novos ganhos K_N^{pid} são ajustados *online* via chaveamento para 2, recuperando o comportamento especificado da planta.

Figura 38 – Configuração da RNA-E para a recuperação de perturbações paramétricas



Levando em consideração que uma perturbação paramétrica na Eq. (116) que é Δa_i

nos parâmetros (a_i, b_i) da planta. Em termos de variações paramétricas aditivas, o polinômio característico da planta com perturbações é dado por

$$P^{MFp}(s) = s^{n_{MF}} + \sum_{i=1}^{n_{MF}-1} (a_i^s + \Delta a_i + \langle K^{pid}, \bar{b}_{i-1} \rangle) s^{n_{MF}-i}, \quad (117)$$

sendo $P^{MFp}(s)$ o polinômio da planta com perturbações. Generalizando os coeficientes $a_i + \Delta a_i = a_i^p$ para fins de elaboração do algoritmo, tem-se que todos os coeficientes da Eq. (117) são representados pela relação indexada que é dada por

$$a_i^s + \langle K^{pid}, \bar{b}_i \rangle = a_i^p, \quad (118)$$

sendo a_i^p o i -ésimo coeficiente da perturbação paramétrica da Eq. (118), consequentemente, tem-se o i -ésimo vetor de erro a_i^e que é dada por

$$\langle K^{pid}, \bar{b}_i \rangle = a_i^e = a_i^p - a_i^s, \quad (119)$$

O ajuste do ganhos do controlador adaptativo para compensação das variações paramétricas são detectadas, de forma generalizada, por meio das alterações nos coeficientes do polinômio característico especificado para uma dada operação da planta em malha fechada. A comparação entre os coeficientes dos polinômios característicos da planta dado na Eq. (74) e o polinômio característico especificado da Eq. (116), é dado por

$$\varepsilon = P^{MF} - P^{MFs}, \quad (120)$$

sendo ε o vetor com os erros dos coeficientes dos polinômios.

O algoritmo de treinamento do controlador PID_{RNA-E} com perturbações paramétricas a_i^p é similar ao **Módulo 5 - K_{RNA-E}^{pid} Algoritmo ótimo de treinamento**, a diferença, é que com esse algoritmo os parâmetros iniciais, isto é, os parâmetros especificados no projeto são recuperados, de forma que o ponto de operação do sistema de controle seja recuperado durante o processo operacional da planta.

Os parâmetros especificados a_i^s da planta são recuperados, de forma que o ponto de operação do sistema de controle seja mantido durante o processo operacional da planta. Com isso, garante-se a otimalidade do controlador PID_{RNA-E} em todas as situações operacionais em que a planta é submetida.

Módulo 5: implementa o algoritmo de sintonia adaptativo e ótimo que é realizada por meio de RNA-E. Nesta etapa, se ocorrer divergência entre os parâmetros das FTs especificada e a levantada pelo método RLS, os ganhos são ajustados. Caso contrário, isto é, o erro é nulo, não é preciso ajuste para as variações paramétricas não relevantes.

ALGORITMO DE PERTURBAÇÃO PARAMÉTRICA PID_{RNA-E}

```

1  ▷ Setup (Condições Iniciais)
2  ▷ Taxa de Aprendizado -  $\eta \leftarrow [ \quad ]$ 
3  ▷ Parâmetros da Função de Transferência -  $[b_i, a_i] \leftarrow [ \quad ]$ 

```

```

4  ▷ Processo Iterativo
5  for  $i \leftarrow 0 : N$ 
6      do
7          ▷ Controle e Simulador da Planta
8          Ação de Controle PID
9           $u_i \leftarrow K_i x_i$ 
10         ▷ Planta
11          $y_{i+1} \leftarrow$ 
12         ▷ Estimação de Parâmetros
13          $\bar{x}_i \leftarrow [x_{1i}^2; x_{1i}x_{2i}; \dots; x_{4i}^2]$ 
14         ▷ Treinamento
15         ▷ Cálculo de B
16          $a_i^s = \mu \bar{B}^T \bar{B} \bar{B}^T$ 
17          $a_i = \bar{\mu} \bar{B} \bar{B}^T$ 
18          $a_i^e = a_i^s - a_i$ 
19          $e_{int} = \int e_i dt + K_0^{pid}$ 
20          $K^{pid} = \bar{B} \bar{B}^T e_{int}$ 

```

```

21  Fim do Processo Iterativo

```

6.1.6 Estudos de Casos

Os estudos de casos foram aplicados ao processo operacional de uma RP de grânéis sólidos, com o intuito de avaliar a eficiência do sistema de controle proposto.

6.1.7 Experimentos Computacionais

Os procedimentos para avaliações da proposta são orientados para analisar os resultados sob os pontos de vistas de desempenho de controle e dos algoritmos de sintonia. Os resultados de controle e a matriz de desempenho são utilizados para verificar o comportamento do sistema, em face aos sinais exógenos de entrada que são os sinais de referência, perturbação e ruído, tendo como saída da planta, o esforço de controle e o sinal interno que é o erro da realimentação. O desempenho do sistema é avaliado sob o ponto de vista de resposta no domínio do tempo. Ainda neste contexto, avalia-se a complexidade computacional e convergência do algoritmo em relação a quantidade de parâmetros. A seguir descreve-se os procedimentos de avaliação de desempenho.

6.1.7.1 Procedimento de Avaliação

Para avaliar o impacto dos métodos de otimização no ajuste dos parâmetros do controlador PID. Em termos de convergência na obtenção dos ganhos K^{pid} , o desempenho da RNA-E é avaliado em respeito a velocidade de treinamento. Avalia-se também as figuras de méritos para a resposta ao degrau unitário, observando-se o comportamento do sistema para perturbações nos parâmetros da planta.

6.1.8 Estudo de Caso 1

No estudo de caso 1 avalia-se o comportamento do processo operacional de uma RP de granéis em termos de FTs em malha aberta e em malha fechada comparado com o controlador PID com ganhos fixos já existente na planta, que é sintonizado pelo método de tentativa e erro, este é usado como o controle PID de referência PID_{ref} . O modelo geral da planta é dado por

$$G_p(s) = \frac{b_0 s^1 + b_1 s^0}{s^3 + a_1 s^2 + a_2 s^1 + a_3 s^0}, \quad (121)$$

sendo $G_p(s)$ a FT da planta em malha aberta. O polinômio característico do denominador da planta P_{D_p} Eq. (121) é dado por

$$P_{D_p}(s) = s^3 + a_1 s^2 + a_2 s^1 + a_3 s^0. \quad (122)$$

A FT da planta RP de granéis foi obtida baseada em dados reais coletados durante o processo operacional da mesma no intervalo de 30 dias, onde as perturbações e ruídos do modelo geral estão embutidos no modelo matemático do processo operacional da planta, que é dado por

$$G_{p^{MA}}^{RP}(s) = \frac{0,1812s + 0,0871}{s^3 + 0,3853s^2 + 0,1117s + 0,01567}, \quad (123)$$

sendo os parâmetros das FTs em malha aberta do processo operacional da retoma de de granéis, da Eq. (123) dados por $a_i = [1, 0 \ 0,3853 \ 0,1117 \ 0,01567]^T$ e $b_i = [0,1812 \ 0,0871]$.

Os ganhos do controlador PID_{ref} foram determinados por tentativa e erro, onde $K_P = 5,5$; $K_I = 1,76$ e $K_D = 3,92$, que é usado como referência, tendo a FT guiada pelo controlador PID_{Ref} com realimentação unitária $G_{p^{MF}}^{RP}(s)$ que é dada por


$$G_{p^{MF}}^{RP}(s) = \frac{0,7103s^3 + 1,338s^2 + 0,798s + 0,1533}{s^4 + 1,096s^3 + 1,45s^2 + 0,8136s + 0,1533}. \quad (124)$$

As respostas ao degrau unitário da planta e do sistema de controle com PID de referência PID_{Ref} é apresentada na Figura 39. Como pode-se observar, que o PID_{Ref} não atende todas as especificações de projetos para o processo de retomada de granéis, tais como: *overshoot* de 50,9145% e T_s em torno de 20s.

Os valores das figuras de mérito associados com a Figura 39 mostram que o sistema de controle promove a estabilidade, mostrando o comportamento do sistema ao longo do tempo. Enquanto que as figuras de mérito permitem avaliar o comportamento estável, forma qualitativa, por meio dos seus valores que são o tempo de subida (*RiseTime*) é $t_r = 0,9422$, tempo de acomodação (*Settling Time*) é $t_s = 19,0782$ com $SettlingMin = 0,6552$ e $SettlingMax =$

1,5128, o percentual de sobre sinal (*Overshoot*) é $M_p\% = 51,2775\%$ e *Undershoot* e $M_p^{min} = 0$, valor de pico (*Peak*) e $M_p = 1,5128$, tempo de pico (*Peak Time*) $t_p = 2,6078$. Os parâmetros da FT termos de diagrama de pólos e zeros, observa-se dois pólos complexos $s_{p12} = -0,367 \pm 0,116j$ $\zeta = 0,954$ e frequência natural não amortecida $\omega_n = 0,385$. O segundo pólo complexo é $s_{p34} = -0,181 \pm 10,0j$ com coeficiente de amortecimento $\zeta = 0,178$ e frequência natural não amortecida $\omega_n = 1,02$. Ainda, a FT da planta possui três zero de fase mínima em $s_{z1} = -0,4807$, $s_{z3} = -0,9093$, $s_{z3} = -0,4938$.

Figura 39 – Resposta ao degrau unitário do sistema de controle com o PID_{Ref} e o comportamento da planta.



A resposta ao degrau da Figura 39 apresenta-se, os requisitos das figuras de méritos, tais como: o tempo de subida (*RiseTime*) é $t_r = 1,7104$, tempo de acomodação (*Settling Time*) é $t_s = 20,8051$ com $Settling_{Min} = 0,9618$ e $Settling_{Max} = 1,1541$, o sobre sinal (*Overshoot*) $M_p = 50,9145\%$ e *undershoot* = 0.7821 e $M_p^{min} = 0,7821$, valor de pico (*Peak*) e $M_p = 1,509145$, tempo de pico (*Peak Time*) $t_p = 2,5361$. Os parâmetros da FT em termos de diagrama de pólos e zeros, observa-se dois pólos complexos $s_{p12} = -0,0802 \pm j0,2720$. Ainda, a FT da planta possui um zero de fase mínima em $s_z = -0,4807$. O ganho K é dado por 0.1812.

6.1.9 Estudo de Caso 2

No estudo de caso 2 faz-se a análise da eficiência para controle em termos de alocação de pólos para o desempenho da RNA-E para alocação que deve atender as especificações que são armazenadas nos módulos 3 e 4 do Algoritmo de especificação de projeto. Este tem como entrada especificada em projeto, as frequências naturais (ω_n) e coeficientes de amortecimento (ζ) associado com cada pólo. As especificações de projeto são especificadas em termos de pares

ordenados do tipo (ζ, ω_n) que são dadas por

$$\begin{aligned}(\zeta_{12}, \omega_{n12}) &= (0, 725; 0, 27); \\(\zeta_3, \omega_{n3}) &= (1, 0; 0, 5147); \\(\zeta_4, \omega_{n4}) &= (1, 0; 1, 99).\end{aligned}\tag{125}$$

Após manipulações com os parâmetros especificados no projeto, obtém-se os novos polos do sistema, que são: $p_{12} = 0, 1958 \pm j0, 6981$, $p_3 = 0, 5140$ e $p_4 = 1, 99$. A partir desse polos, o novo polinômio característico é montado com os novos coeficientes $a_i^N = [2, 896 \quad 2, 528 \quad 1, 717 \quad 0, 5381]^T$, resultando na FT para as novas especificações de projeto, que é dada por

$$G_{a_i^N}(s) = \frac{2, 511s^3 + 2, 417s^2 + 1, 701s + 0, 5381}{s^4 + 2, 896s^3 + 2, 528s^2 + 1, 717s + 0, 5381},\tag{126}$$

Levando-se em consideração as variações que ocorrem nos parâmetros da planta, somado com o impacto destas variações, observa-se, que a atuação do sistema de controle de sintonia ótima é dependente dessas variações que são detectadas nos parâmetros da FT em malha fechada. A diferença entre os novos coeficientes a_i^N da FT em malha fechada dados na Eq. (126) e os coeficientes a_i^V da FT em malha fechada antiga dados na Eq. (124) é o resíduo $\tilde{a}_i = [1, 800 \quad 1, 0788 \quad 0, 9034 \quad 0, 3848]^T$, sendo $\tilde{a}_i = a_i^N - a_i^V$ o resíduo da correção para a alocação de pólos e os coeficientes da operação atual são $a_i^A = a_i^V = [1, 096 \quad 1, 45 \quad 0, 8136 \quad 0, 1533]^T$, sendo a_i^V são os parâmetros a_i da função de transferência da planta em malha aberta dados na Eq. (123).

O resultado da sintonia ótima do controlador PID via algoritmo RNA-E é avaliado em termos do alvo de controle por meio da alocação de polos e em respeito ao desempenho da complexidade computacional. Ainda neste contexto, a saída do algoritmo RNA-E para sintonia *online* do controlador PID_{RNA-E} fornece, numericamente, o vetor de ganhos do K_{RNA-E}^{pid} que é dado por

$$K_{RNA-E}^{pid} = [16, 7965 \quad 7, 5026 \quad 2, 6372].\tag{127}$$

O cálculo para fornecer, numericamente, o vetor de ganhos do gradiente do erro para sintonia *online* do controlador $PID_{Gradient}$ está associado com a Eq. (115) fornece, numericamente, o vetor de ganhos do $K_{Gradient}^{pid}$ que é dado por.

$$K_{Gradient}^{pid} = [16, 7952 \quad 7, 5031 \quad 2, 6381],\tag{128}$$

A comparação entre os métodos de obtenção dos ganhos do controlador PID_{RNA-E} e $PID_{Gradient}$ mostra uma diferença muito pequena entre os ganhos K^{pid} , na ordem de 10^{-4} .

Como os resultados dos algoritmos RNA-E e do gradiente do erro são muito próximo, as análises a partir daqui, serão feitas, somente, para o algoritmo RNA-E, visto que os resultados devem se comportar com o mesmo desempenho.

Os valores especificados para o projeto em (125) são comparados com os resultados da Tabela 8. Nesta, observa-se que, em termos de alvo de controle o PID_{RNA-E} realizou a alocação de pólos de acordo com a especificação de projeto. Ainda, em termos de alvo de controle, o cálculo dos pólos de malha fechada da FT com os ganhos determinados pelo algoritmo RNA-E, mostra que, a alocação de pólos foi realizada de forma satisfatória. Além do mais, o cálculo do algoritmo do gradiente do erro é mais complexo, utilizando mais operações matemática para obter resultados similares ao algoritmo RNA-E. Com isso, o algoritmo RNA-E é mais interessante, visto que as aplicações são em tempo real.

Tabela 8 – Figuras de mérito com RNA-E para alocação de pólos.

Pólos	ζ	$\omega_n(\text{rd/s})$	$\tau(\text{s})$
-0,514	1,0	0,514	1,94
-1,99	1,0	1,99	0,502
-0,195 +j 0,698	0,269	0,725	5,12
-0,195 -j 0,698	0,269	0,7251	5,12

Em respeito às variações dos seus parâmetros, tais como: condições iniciais, taxa de aprendizado e quantidade de buscas do processo, o desempenho da RNA-E é avaliado de forma sistemática por meio dos 6 (seis) cenários apresentados com taxa de aprendizagem μ variando de 0,6 a 0,98 com η constante (100 interações) e o vetor das condições iniciais K_0^{pid} apresentadas na Tabela 9. Ainda, neste contexto, para determinar os ganhos do controlador PID, a variação na taxa de aprendizado μ e nas condições iniciais promovem um impacto direto na velocidade de resposta dos algoritmos da RNA-E. Consequentemente, a seleção destes parâmetros desempenha um papel fundamental para aplicações *online*, no caso da sintonia *online* e ótima do controlador PID.

Tabela 9 – Ganhos PID para variações na taxa de aprendizado.

Caso	μ	n_{iter}	K_0	K_D	K_P	K_I
RNA-E 1	0,98	100	1	16,3310	7,2872	2,7880
			2	13,8128	6,7937	6,0590
			3	16,8536	7,7093	2,1350
RNA-E 2	0,95	100	2	16,8135	7,8003	2,0495
			3	16,8553	7,7110	2,1311
RNA-E 3	0,925	100	1	16,2606	7,3457	2,7527
			2	16,8146	7,8061	2,0410
			3	16,8569	7,7125	2,1276
RNA-E 4	0,90	100	1	16,2248	7,3734	2,7357
			2	16,8159	7,8123	2,0318
			3	16,8587	7,7140	2,1238
RNA-E 5	0,80	100	1	16,0517	7,4902	2,6607
			2	16,8264	7,8402	2,9870
			3	16,8692	7,7211	2,1045
RNA-E 6	0,60	100	1	16,4770	7,7113	2,4584
			2	16,8896	7,9194	2,8407
			3	16,9148	7,7409	2,0376


O setup para o algoritmo RNA-E determinar os ganhos *online* K^{pid} , são as condições iniciais do vetor de ganhos $K_0^{pid} = [K_{D_0} \ K_{P_0} \ K_{I_0}]$ dos cenários exibidos na Tabela 9, que estão ilustrados na Tabela 10.

Tabela 10 – Condições iniciais para sintonia do PID_{RNA-E} .

K_0	K_{D_0}	K_{P_0}	K_{I_0}
1	0,0	0,0	0,0
2	16	8,0	4,0
3	15	7,0	5,0

A convergência dos erros do processo iterativo dos algoritmos RNA-E e do gradiente do erro associado com o vetor de ganhos K_{RNA-E}^{pid} em (127) e com o vetor de ganhos K_{Grad}^{pid} em (128) para $\mu = 0,3$; $\mu = 0,6$ e $\mu = 0,9$ são analisados, onde pôde se observar que, para $\mu = 0,3$, a convergência dos ganhos deu-se em torno de 500 iterações, para $\mu = 0,6$, a convergência deu-se com um número menor de iterações, em torno de 200 iterações e por fim com $\mu = 0,9$ a convergência ocorreu, ainda, em um número menor de iterações, em torno de 100 iterações, sendo que é observada uma ligeira vantagem para o algoritmo RNA-E, conforme apresentado na Figura 40 o resultado para fator de aprendizagem de $\mu = 0,9$.


Figura 40 – Comportamento dos ganhos do gradiente do erro $\nabla \varepsilon(K^{pid})$ com o comportamento dos ganhos do erro $e(K^{pid})$.



Para concluir a análise do caso 2, faz-se uma comparação do comportamento da resposta ao degrau unitário do controlador PID sintonizado pelo algoritmo RNA-E para o erro $e(K^{pid}) = \bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{a}$ e para o gradiente do erro $\nabla \varepsilon(K^{pid}) = \bar{B}^T \bar{B} (\bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{B} e(K^{pid})) \bar{B}^T \bar{a}$ do controlador PID respectivamente, com 100 iterações e com fator de aprendizagem de 0,9. Onde pode se observar uma pequena vantagem do controlador PID_{RNA-E} usando, somente, o $e(K^{pid})$ em comparação com o uso do $\nabla \varepsilon(K^{pid})$, conforme Figura 41¹

¹ Sendo a parte destacada em azul o erro do vetor de ganhos eK^{pid} e em vermelho o gradiente do erro $\nabla \varepsilon(K^{pid})$.

Figura 41 – Resposta ao degrau unitário do controlador PID_{RNA-E} para o $e(K^{pid})$ e para $\nabla\epsilon(K^{pid})$ em comparação com o controlador PID_{Ref} .



6.1.10 Estudo de Caso 3

O caso 3 refere-se as especificações para alocação de pólos especificados na Tabela 11 no intuito de modificar a dinâmica do sistema para resposta ao degrau apresentada na Figura 39 promovida pela ações do controlador PID_{Ref} .

Tabela 11 – Pólos especificados para alocação.

Sintonia RNA-E	Pólos Especificados		
	p_{12}	p_3	p_4
PID_{ref}	$-0,3581 \pm j0,1415$	$-1,0$	$-2,0$
S_1	$0,1958 \pm j0,698$	$-0,5$	$-2,0$
S_2	$-0,1856 \pm j1,003$	$-0,5$	$-5,0$
S_3	$-0,1814 \pm j0,5$	$-1,0$	$-2,0$

Após a sintonia feita pelo algoritmo RNA-E os resultados são exibidos na Tabela 12, onde pode-se observar que a alocação de pólos foi feita para posições, bem próximas, das especificadas apresentas na Tabela 11.

Tabela 12 – Pólos alocado pelo PID_{RNA-E}

Sintonia RNA-E	Pólos Alocados		
	p_{12}	p_3	p_4
PID_{ref}	$-0,357 \pm j0,145$	$-1,0$	$-2,0$
S_1	$-0,197 \pm j0,698$	$-0,514$	$-1,99$
S_2	$-0,191 \pm j1,001$	$-0,487$	$-5,0$
S_3	$-0,182 \pm j0,499$	$-4,99$	$-5,0$

Tabela 13 – Zeros depois da alocação de pólos pelo PID_{RNA-E} .

Sintonia RNA-E	Zeros da planta	
	z_{12}	z_3
P_{ref}	$-0,3878 \pm j0,1882$	$-0,4807$
S_1	$-0,2418 + 0,6220$	$-0,4807$
S_2	$-0,2579 \pm j0,9482$	$-0,4807$
S_3	$-0,1861 \pm j0,4829$	$-0,4807$

Confrontando a localização dos pólos e zeros para cada alocação nas Tabelas 12 e 13, respectivamente, dos pólos e dos zeros destacados em azul, com os polos especificados na Tabelas 11. Observa-se, que os zeros estão muito próximos dos pólos. Esta situação, acontece porque o foco é alocação dos pólos. A localização dos zero é livre, depende das escolha dos ganhos K^{pid} que satisfazem o polinômio característico.

Concluindo a análise do caso 3, observa-se que os zeros reais permanecem constantes para todas as alocações e os zero complexos tendem a eliminar os pólos. Este evento pode ser explicado, devido a forte dependência que existem entre as ações PID e suas iterações com os coeficientes b_i dos zeros do polinômio da Eq. (71), isto é, os coeficientes dos zeros da FT de malha fechada são explicitados em termos do produto interno do vetor de ganhos K^{pid} e dos coeficientes do referido polinômio. Por meio da Eq. (73), observa-se que o polinômio característico depende da matriz de propagação $\bar{B}$ em (77).

6.1.11 Estudo de Caso 4

Neste estudo de caso são propostas 4 (quatro) situações para avaliar a recuperação dos parâmetros a_i^s depois de sofrerem perturbações aleatórias no processo operacional do sistema dinâmico de uma RP de granéis que é representado pelo diagrama de blocos canônico do sistema de controle em malha fechada da Figura 20. A partir da Eq. (70) a propagação dos ganhos K^{pid}

com os coeficientes b_i é dada por

$$\begin{aligned} K^{pid}(s) &= (K_D s^2 K_P s^2 K_I)(b_0 s + b_1) \\ &= K_D s^3 + (K_P b_1 + K_I b_0) s^2 + K_I b_1 s. \end{aligned} \quad (129)$$

A função de transferência do estimador $\bar{G}(s)$ com os ganhos K^{pid} propagados com os coeficientes b_i , isto é, sem perturbação no vetor a_i é dada por

$$\bar{G}(s) = \frac{b_0 K_D s^3 + (b_1 K_P + b_0 K_I) s^2 + K_I b_1 s}{s^4 + a_1^s s^3 + a_2^s s^2 + a_3^s s + a_4^s}. \quad (130)$$

As 4 (quatro) situações são propostas para os coeficientes a_i da Eq. (123), da seguinte forma: adicionada uma variação brusca e de considerável magnitude nos coeficientes a_1 , a_2 e a_3 alternadamente das situações S_1 , S_2 e S_3 respectivamente, destacado em vermelho. Depois essa mesma variação foi adicionada em todos os coeficientes a_i , simultaneamente da situação S_4 , conforme destacado, também, em vermelho na Tabela 14. sendo S_0 a situação original.

Tabela 14 – Coeficientes com perturbações para S_1 , S_2 e S_3 da função de transferência da Planta em malha aberta.

Situações	Coeficientes		
	a_1	a_2	a_3
S_0	0,3853	0,1117	0,01562
S_1	1,3853	0,1117	0,01562
S_2	0,3853	1,1117	0,01562
S_3	0,3853	0,1117	1,01562
S_4	1,3853	1,1117	1,01562

O algoritmo proposto na Subsecção 6.1.5 é aplicado para recuperação do comportamento especificado da planta por meio do polinômio de recuperação que é dado por

$$G_p^{BW^R}(s) = s^n + \sum_{i=1}^{n-1} (a_i^p + \langle K_{pid}^R, \bar{b}_{i-1} \rangle) s^{n-1}, \quad (131)$$

sendo $a_i^p = a_i^s + \Delta a_i^s$ e $K_{pid}^R (K_D^R, K_P^R, K_I^R)$ o vetor de ganhos da recuperação. Da Eq. (126) obteve-se, a recuperação dos coeficientes a_i alterados na Tabela 14 destacados em vermelho, que são ilustrados em azul na Tabela 15.

Tabela 15 – Coeficientes a_i da função de transferência da planta em malha aberta.

Situações	Coeficientes		
	a_1	a_2	a_3
S_0	0,3853	0,1117	0,01562
S_1	0,3872	0,1117	0,01562
S_2	0,3853	0,1134	0,01562
S_3	0,3853	0,1117	0,01587
S_4	0,3867	0,1119	0,01562

Na Tabela 16 apresenta-se os erros dos coeficientes $a_i^s - a_i^p$ dos S_1 , S_2 , S_3 e S_4 em relação ao S_0 . Observa-se, que houve um pequeno erro na variação dos coeficientes Δa_i^s com os Δa_i^R .

Tabela 16 – Coeficientes do polinômio característico para variações paramétricas na planta.

Erro ($a_i^s - a_i^p$)	Erros entre os coeficiente $a_i^s - a_i^p$		
	$a_1^s - a_1^p$	$a_2^s - a_2^p$	$a_3^s - a_3^p$
$S_0 - S_1$	-0,0019	0,0000	0,0000
$S_0 - S_2$	0,0000	-0,0017	0,0000
$S_0 - S_3$	0,0000	0,0000	-0,0002
$S_0 - S_4$	-0,0014	-0,0002	0,0000

Os ganhos da recuperação ou compensação são apresentados na Tabela 17 destacados em azul. Onde pode se observar que os ganhos foram recuperados, praticamente, em sua totalidade, ficando muito próximo dos valores do PID com os parâmetros dos ganhos determinados pelo algoritmo RNA-E da situação S_0 destacados em negrito.


Tabela 17 – Ganhos da recuperação K^{pid} para variações nos parâmetros especificados a_i^s via algoritmo RNA-E.

Sintonia	Ganhos		
	K_D	K_P	K_I
S_0	16,7965	7,5026	2,6372
S_1	16,8202	7,4432	2,2121
S_2	16,5642	7,6831	2,4572
S_3	16,6891	7,3572	2,3132
S_4	16,3452	7,2366	2,8872

Para finalizar a análise do caso 4, apresenta-se na Figura 42 o comportamento dos controladores PID para 4 situações S_1 , S_2 , S_3 e S_4 com os parâmetros a_i^s alterados e recuperados

pelo algoritmo RNA-E com fator de aprendizagem 1 (um) e para 100 iterações, em comparação com a situação S_0 com os parâmetros a_i^s especificados e com os ganhos K^{pid} determinados pelo algoritmo RNA-E. Onde, pode-se observar que o comportamento das 4 situações em que os parâmetros a_i^s foram alterados e depois recuperados pelo algoritmo RNA-E, foi bem, próximo do comportamento da situação S_0 , mantendo-se o sistema controlado, com pequenas variações no tempo de resposta ao erro estacionário, que estão associados com os dados apresentados na Tabela 16. Com isso, mostra que os modelos baseados em algoritmos RNA-E, além de possuírem propriedades importantes, como: otimalidade, estabilidade do erro estacionário, rejeição à perturbação, ainda são adaptáveis por meio da recuperação dos pólos especificados.

Figura 42 – Resposta ao degrau unitário para o PID_{RNA-E} da situação S_0 em que os parâmetros a_i^s são especificados x resposta ao degrau unitário para o PID_{RNA-E} de 4 situações em que os parâmetros a_i^s foram alterados e depois recuperados pelo algoritmo RNA-E x resposta ao degrau unitário do controlador PID_{Ref} .



6.1.12 Considerações Gerais

No contexto de RNA-E, os modelos e os algoritmos desenvolvidos para alocação de pólos e recuperação das variações paramétricas foram formulados como um problema de otimização. A RNA-E foi avaliada em termos de tempo de resposta e exatidão com que atingiu o alvo de controle, os resultados mostram-se promissores para uma dada seleção dos parâmetros que inferem no desempenho da rede, tais como, taxa de treinamento, condições iniciais e tempo limite para alocar os ganhos da lei de controle no dispositivo PID.

Um outro tipo de avaliação consistiu, em avaliar o desempenho da RNA-E para atingir o alvo de controle, este tipo de teste apresentou resultados para alocação de pólos para conduzir o sistema de forma, a manter o mesmo ponto de operação, sem que haja perdas significativas

devido á variações paramétricas. Ainda neste contexto, avaliou-se o comportamento do sistema de controle PID_{RNA-E} para os requisitos das figuras de méritos, tais como: o tempo de subida (*Rise Time*), tempo de acomodação (*Settling Time*), o sobre sinal (*Overshoot*), valor de pico (*Peak*) e tempo de pico (*Peak Time*).

O foco do trabalho apresentado foi a alocação de pólos por meio de ajustes nos parâmetros a_i^s da planta do processo operacional de uma RP de grânéis sólidos via RNA-E com os coeficientes b_i fixos, com isso, os ganhos ótimos do controlador PID foram determinados *online*, onde pôde-se observar que, o vetor de ganhos K^{pid} calculado nas situações com variações nos parâmetros a_i da planta foram muito próximo do vetor de ganhos K^{pid} especificados em projeto, isso pode ser explicado pelo fato de que os coeficientes b_i são mantidos constantes, o que justifica a pouca influência nos parâmetros a_i .

Tendo em vistas melhorar o desempenho operacional dos equipamentos industriais, modelos e algoritmos adaptativos baseados em RNA-E para sintonia ótima e *online* de controladores PID foram apresentados neste capítulo desta Tese. Observou-se por meio de experimentos computacionais que os modelos e os algoritmos propostos de sintonia atendem as especificações de projeto de controle para avaliar a eficiência na imposição de um novo ponto de operação, via uma nova alocação de pólos, ou compensação das perturbações paramétricas nas plantas. De forma geral, a associação de treinamento da RNA-E com os métodos de alocação de pólos e esquemas adaptativos para sintonia de controladores PID mostrou-se uma alternativa em consonância com sistemas inteligentes e a evolução tecnológica contribuindo de forma significativa para a indústria 4.0.

6.2 Modelo PID-Neuro-Fuzzy


Plantas na indústria de mineração são muito complexas, e não é comum o uso de controladores de alto desempenho. o modelo PID-Neuro-Fuzzy é uma proposta inovadora que pode ser estendidas para outras plantas com alto grau de complexidades.

O controlador *Fuzzy* mede as saídas do controlador Neuro-PID e ajusta-as para reduzir os erros de saída. O controlador *fuzzy* pode tomar decisões precisas para melhorar o controle da vazão de minério com base no conhecimento da operação e experiência humana (TAO et al., 2015).

De forma generalizada apresenta-se em diagrama de blocos a topologia do sistema de controle proposto neste trabalho. O sistema de controle para ajuste *online* e ótimo dos parâmetros de ganho do controlador via RNA-E é ilustrada na Figura 43. Onde $R(s)$ é o valor de referência, $E(s)$ é o erro do sistema, K^{pid} os ganhos do controlador PID, $U(s)$ a entrada da planta, $G(s)$ a planta, $\hat{G}(s)$ o estimador, RNA a rede neural estrutura, $G_W(s)$ a perturbação nos parâmetros da planta, $G_V(s)$ o ruído dos sensores, $Y_m(s)$ a saída medida pelos sensores e $Y(s)$ a saída da planta. Os ganhos do K^{pid} são determinados *offline* pela a RNA já mencionado anteriormente e

são ajustados *online* por regras *fuzzy*, mantendo-se o sistema autoajustável.

Figura 43 – Topologia do controlador PID-Neuro-Fuzzy.



O projeto do controlador PID com os ganhos ótimos determinados por uma RNA-E e ajustado por regras *fuzzy*, apresentado nesta tese, foi desenvolvido com base na norma euclidiana para atuar da seguinte maneira: a ação proporcional ajusta a saída do controlador de acordo com a variação do erro, a ação integral elimina o deslocamento do estado estacionário e a tendência futura é antecipada pela ação derivativa.

6.2.1 Simulações

Os resultados simulados são apresentados na Planta - I de segunda ordem, na Planta - II de terceira ordem, na Planta - III de quarta ordem, na Planta - IV de quinta ordem, na Planta - V de sexta ordem, Planta - VI de sétima ordem e na Planta - VII de oitava ordem.

Na Tabela 18, apresenta-se os ganhos K_P , K_I e K_D determinados pelo segundo método de Ziegler-Nichols e pela RNA-E. Depois dos ganhos determinados pela RNA-E, faz-se a sintonia dos controladores PID-Neuro-Fuzzy e compara com os controladores PID convencionais sintonizados pelo segundo método de Ziegler-Nichols.

Tabela 18 – Método usados para determinar os ganhos dos controladores propostos.

Planta	Ordem	Método	K_P	K_i	K_d
I	2	ZN	0,0066	$4,3277 \times 10^{-4}$	0,0252
		RNA-E	0,1966	$0,0962 \times 10^{-4}$	2,2831
II	3	ZN	0,9300	0,1853	1,1668
		RNA-E	2,0646	0,2717	0,0241
III	4	ZN	0,0029	$2,8848 \times 10^{-4}$	0,0071
		RNA-E	2,0735	0,7376	0,0000
IV	5	ZN	0,0056	$4,9391 \times 10^{-4}$	0,0160
		RNA-E	2,6060	0,2943	0,3369
V	6	ZN	0,4194	0,0804	0,5472
		RNA-E	1,6322	0,0609	0,2446
VI	7	ZN	0,0014	$1,209 \times 10^{-4}$	0,0041
		RNA-E	2,2135	0,7901	0,0309
VII	8	ZN	0,0014	$3,8387 \times 10^{-4}$	0,0014
		RNA-E	2,9949	1,1611	2,7045

Na Tabela 19, apresenta-se os parâmetros dos controladores PID-Neuro-Fuzzy, PID-Fuzzy e PID-ZN respectivamente, fazendo uma comparação entre eles para cada planta.


Tabela 19 – Parâmetros dos controladores PID-Neuro-Fuzzy, PID-Fuzzy e PID-ZN.

Planta	Ordem	Controlador	Tr	Mt/Mv	Ts	E(s)
I	2	PID-Neuro-Fuzzy	5	4270	20	6,7%
		PID-Fuzzy	10	-	60	6,7%
		PID-ZN	10	-	100	27%
II	3	PID-Neuro-Fuzzy	1	8700	5	8,75 %
		PID-Fuzzy	5	10100	5	26,25 %
		PID-ZN	2	11500	30	43,75 %
III	4	PID-Neuro-Fuzzy	5	8300	10	3,75%
		PID-Fuzzy	15	-	20	6,75%
		PID-ZN	30	-	40	12,50%
IV	5	PID-Neuro-Fuzzy	5	12700	30	5,83%
		PID-Fuzzy	3	13800	40	15,00%
		PID-ZN	5	14600	40	21,67%
V	6	PID-Neuro-Fuzzy	3	18100	15	13,13%
		PID-Fuzzy	5	18000	15	12,50%
		PID-ZN	5	21900	25	36,88 %
VI	7	PID-Neuro-Fuzzy	5	16900	30	5,63%
		PID-Fuzzy	8	16700	50	4,38%
		PID-ZN	8	18100	50	13,13%
VII	8	PID-Neuro-Fuzzy	5	16100	10	0,63%
		PID-Fuzzy	10	-	15	1,88%
		PID-ZN	20	-	35	9,38%

Para melhor entendimento das plantas em estudos, apresenta-se os arranjos mecânicos dos VVs e das RPs com suas principais dimensões.


Na Figura 44 representa o esquemático do VV, dos silos com os ALs de esteiras ilustrando as dimensões de altura do VV e dos silos para os ALs.

Figura 44 – Fluxo de carga do AL até a pilha no pátio de estocagem.



De acordo com o arranjo mecânico de uma RP de granel sólido mostrado na Figura 45, destacando seus principais componentes e suas dimensões (20000 t de massa, 102 m de comprimento, 36 m de altura e 22 m largura).

Figura 45 – Arranjo mecânico de uma RP.



Nota: O controlador usando o modelo Fuzzy-Neuro-PID atua na variação de velocidade da

rotação dos ALs dos VVs e de rotação da lança das RPs, com um valor máximo de 4,5 m/s, visto que a velocidade é relativamente alta para a massa a ser movimentada, essa variação de velocidade não pode ser muito abrupta.

6.2.2 Avaliação dos Resultados

Nesta Subseção são apresentadas as figuras com os resultados simulados, primeiro apresenta-se o comportamento das plantas, em seguida apresenta-se a resposta ao degrau da planta com os controladores representadas pelas linha contínuas e o comportamento do erro do sistema, representado pelas linhas tracejadas.

6.2.3 Setup

Os experimentos iniciam-se com a identificação dos modelos matemáticos das plantas, em seguida determina-se os ganhos K^{pid} pelo segundo método de *Ziegler-Nichols* e pela RNA-E, na sequência, o controlador *fuzzy* foi concebido, continuando, faz-se o ajuste *online* dos ganhos K^{pid} que foram determinados pelo segundo método de *Ziegler-Nichols* e pela RNA-E. Por fim faz-se as análises comparativas dos desempenhos dos controladores apresentados neste capítulo desta Tese.

6.2.4 Seguidor de Referência

Cada planta tem uma carga desejada, que é a capacidade nominal de cada processo. Essa carga nominal foi considerada o valor de referência a ser alcançado pelos controladores.

Na Figura 46 representa-se o comportamento de resposta ao degrau do modelo matemático em FT da Planta - I e na Figura 47 o comportamento da Planta I com o modelo de controlador PID-Neuro-Fuzzy, com um controlador PID sintonizado por regras *fuzzy* e com um controlador PID convencional sintonizado pelo segundo método de *Ziegler-Nichols* versus seus respectivos erros, onde pode-se observar que a planta controlada pelo modelo proposto, obtém o melhor desempenho, tanto em respeito a seguir o valor de referência que é de 4000 t/h, quanto ao menor erro do sistema em comparação com os outros controladores analisados.

Figura 46 – Planta - I.





Figura 47 – Planta I com os controladores.



Na Figura 48 representa-se o comportamento de resposta ao degrau do modelo matemático em FT da Planta - II e na Figura 49 o comportamento da Planta II com o modelo de controlador PID-Neuro-Fuzzy, com um controlador PID sintonizado por regras *fuzzy* e com um controlador convencional sintonizado pelo segundo método de *Ziegler-Nichols* versus seus respectivos erros. Também, pode-se observar que a planta controlada pelo modelo proposto, obtém o melhor desempenho, tanto em respeito a seguir o valor de referência que é de 8000 t/h, quanto ao menor erro do sistema em comparação com os outros controladores analisados.

Figura 48 – Comportamento da Planta - II.





Figura 49 – Planta II com os controladores.



Na Figura 50 representa-se o comportamento de resposta ao degrau do modelo matemático em FT da Planta - III e na Figura 51 o comportamento da Planta III com o modelo de controlador PID-Neuro-Fuzzy, com um controlador PID sintonizado por regras *fuzzy* e com um controlador convencional sintonizado pelo segundo método de *Ziegler-Nichols* versus seus respectivos erros, constata-se também, que a planta controlada pelo modelo proposto, obtém o melhor desempenho, tanto em respeito a seguir o valor de referência que é de 8000 t/h, quanto ao menor erro do sistema em comparação com os outros controladores analisados.

Figura 50 – Planta - III em malha aberta.





Figura 51 – Plant III com os controladores.



Na Figura 52 representa-se o comportamento de resposta ao degrau do modelo matemático em FT da Planta - IV e na Figura 53 o comportamento da Planta IV com o modelo de controlador PID-Neuro-Fuzzy, com um controlador PID sintonizado por regras *fuzzy* e com um controlador convencional sintonizado pelo segundo método de *Ziegler-Nichols* versus seus respectivos erros, nesta, constata-se também, que a planta controlada pelo modelo proposto, obtém o melhor desempenho, tanto em respeito a seguir o valor de referência que é de 12000 t/h, quanto ao menor erro do sistema em comparação com os outros controladores analisados.

Figura 52 – Comportamento da Planta - IV.





Figura 53 – Plant IV com os controladores.



Na Figura 54 representa-se o comportamento de resposta ao degrau do modelo matemático em FT da Planta - V e na Figura 55 o comportamento da Planta V com o modelo de controlador PID-Neuro-Fuzzy, com um controlador PID sintonizado por regras *fuzzy* e com um controlador convencional sintonizado pelo segundo método de *Ziegler-Nichols* versus seus respectivos erros, onde se constata também, que a planta controlada pelo modelo proposto, obtém o melhor desempenho, tanto em respeito a seguir o valor de referência que é de 16000 t/h, quanto ao menor erro do sistema em comparação com os outros controladores analisados.

Figura 54 – Comportamento da Planta - V.





Figura 55 – Plant V com os controladores.



Na Figura 56 representa-se o comportamento de resposta ao degrau do modelo matemático em FT da Planta - VI e na Figura 57 o comportamento da Planta VI com o modelo de controlador PID-Neuro-Fuzzy, com um controlador PID sintonizado por regras *fuzzy* e com um controlador convencional sintonizado pelo segundo método de *Ziegler-Nichols* versus seus respectivos erros, sendo que a planta controlada pelo modelo proposto, obtém o melhor desempenho, tanto em respeito a seguir o valor de referência que é de 16000 t/h, quanto ao menor erro do sistema em comparação com os outros controladores analisados.

Figura 56 – Comportamento da Planta - VI.





Figura 57 – Plant VI com os controladores.



Na Figura 58 representa-se o comportamento de resposta ao degrau do modelo matemático em FT da Planta - VII e na Figura 59 o comportamento da Planta VII com o modelo de controlador PID-Neuro-Fuzzy, com um controlador PID sintonizado por regras *fuzzy* e com um controlador convencional sintonizado pelo segundo método de *Ziegler-Nichols* versus seus respectivos erros, onde observa-se que a planta controlada pelo modelo proposto, obtém o melhor desempenho, tanto em respeito a seguir o valor de referência que é de 16000 t/h, quanto ao menor erro do sistema em comparação com os outros controladores analisados.

Figura 58 – Comportamento da Planta - VII.





Figura 59 – Plant VII com os controladores.



6.2.5 Rejeição a Perturbações

Foram aplicados os mesmos sinais de perturbação na planta e analisados quanto ao comportamento de rejeição de estabilidade e perturbação para os três controladores. O sinal de perturbação aplicado foi de 50% e 100% nos parâmetros da planta, onde observa-se que os controladores PID e PID-Fuzzy foram mais sensíveis aos sinais de perturbação aplicados, enquanto que o controlador PID-Neuro-Fuzzy apresentou maior robustez para todas as plantas avaliadas.

Na Figura 60 e na Figura 61 representa-se o comportamento de resposta ao degrau do modelo em FT da Planta - I com um sinal de perturbação de 50% e 100% aplicado nos parâmetros do polinômio característico da da planta, respectivamente, para os três controladores.

Figura 60 – Plant I - com sinal de 50% de perturbação na planta.





Figura 61 – Plant I - com sinal de 100% de perturbação na planta.



Na Figura 62 representa-se o comportamento de resposta ao degrau do modelo em FT da Planta - II com um sinal de perturbação de 50%, e na Figura 63 com um sinal de perturbação de 100% para os três controladores.

Figura 62 – Plant II - com sinal de 50% de perturbação na planta.





Figura 63 – Plant II - com sinal de 100% de perturbação na planta.



Na Figura 64 representa-se o comportamento de resposta ao degrau do modelo em FT da Planta - III com um sinal de perturbação de 50%, e na Figura 65 com um sinal de perturbação de 100% para os três controladores.

Figura 64 – Plant III - com sinal de 50% de perturbação na planta.





Figura 65 – Plant III - com sinal de 100% de perturbação na planta.



Na Figura 66 representa-se o comportamento de resposta ao degrau do modelo em FT da Planta - IV com um sinal de perturbação de 50%, e na Figura 67 com um sinal de perturbação de 100% para os três controladores.

Figura 66 – Plant IV - com sinal de 50% de perturbação na planta.





Figura 67 – Plant IV - com sinal de 100% de perturbação na planta.



Na Figura 68 representa-se o comportamento de resposta ao degrau do modelo em função de transferência da Planta - V com um sinal de perturbação de 50%, e na Figura 69 com um sinal de perturbação de 100% para os três controladores.

Figura 68 – Plant V - com sinal de 50% de perturbação na planta.





Figura 69 – Plant V - com sinal de 100% de perturbação na planta.



Na Figura 70 representa-se o comportamento de resposta ao degrau do modelo em função de transferência da Planta - VI com um sinal de perturbação de 50%, e na Figura 71 com um sinal de perturbação de 100% para os três controladores.

Figura 70 – Plant VI - com sinal de 50% de perturbação na planta.





Figura 71 – Plant VI - com sinal de 100% de perturbação na planta.



Nas Figs. 72 e 73 apresenta-se o comportamento de resposta ao degrau e ao erro do sistema do modelo matemático em função de transferência da Planta - VII com um sinal de perturbação de 50% e 100% para os controladores PID-Neuro-Fuzzy, PID-Fuzzy e PID respectivamente. Observa-se que o comportamento da planta com o controlador proposto têm menores oscilações em torno do sinal de referência de 16000 t/h sem perdas significativas da trajetória alcançada. O mesmo comportamento, também é observado para o erro do sistema em comparação com os outros controladores analisados.

Figura 72 – Plant VII - com sinal de 50% de perturbação na planta.





Figura 73 – Plant VII - com sinal de 100% de perturbação na planta.



Capítulo 7

Sintonia Ótima de Controladores Independente de Modelos

Neste Capítulo, apresenta-se uma nova abordagem para o projeto de sistemas de controle ótimos *online* aplicados ao processo de retomada de minério de ferro por RP. Esta abordagem baseia-se em paradigmas de aprendizagem por reforço, mais especificamente, à PDHDA, que aprende *online* a solução ótima de controle por meio de RLQ em tempo discreto (RLQD) com ação integral que é denominado de controlador ADHDP-DLQR-IA.

7.1 Projeto do Controlador ADHDP-DLQR-IA para Processos Operacionais de RP de Caçambas

A retomada de minério de ferro é realizada dividindo-se a pilha em bancadas, cada bancada tem aproximadamente 4 m de altura e as bancadas são divididas em camadas com até 12 m de comprimento. Para retomar uma camada, são necessárias vários passos de translação (penetração na pilha). o passo de translação varia de 0 a 1 m. Para manter o fluxo de minério desejado ao longo do processo, a velocidade da lança da RP deve ser ajustada periodicamente. A principal vantagem do método de controle proposto é que, além da regra de decisão ser totalmente independente do modelo da planta, os ganhos do controlador resultante são auto-ajustáveis. O sistema de controle foi projetado de tal forma que o controlador ADHDP-DLQR-IA atua em tempo real no controle da planta, usando-se apenas os sinais de estados de entrada e de saídas medidos ao longo da trajetória do sistema.

Especificamente, a retomada em massa por RP é um processo industrial complexo para lidar com equipamentos grandes, que sofrem muitas interferências externas, como desgaste de componentes mecânicos, imprecisão de variáveis de processo e variação nas características físicas e químicas do material para ser tratado. Esse processo consiste em levantar o material armazenado em forma de pilha do pátio e colocá-lo em correias transportadoras para serem

transportadas para o carregador de embarque.

O controle de fluxo atual via RP é feito por um controlador PI para atuar diretamente na variação da velocidade da lança. Este controlador foi projetado com base na experiência do operador, que observou através de instrumentos instalados para medir a intensidade da corrente elétrica do motor da RC da RP, uma grande semelhança com a carga medida por uma balança dinâmica instalada na lança da RP, o que motivou a concepção de um projeto de controle baseado nos sinais dos sensores da planta. No entanto, uma grande desvantagem deste controlador é que os parâmetros de ganhos K_P e K_I são determinados por um método de tentativa e erro. Além disso, esses parâmetros são constantes, depois de serem determinados, se houver variação na dinâmica da planta, é necessário determinar-se novos parâmetros K_P e K_I para atender a nova dinâmica.

7.1.1 Processo de Retomada de Minério


O processo de retomada do minério consiste em retomar o material armazenado em pilhas e transportá-lo por meio de CTs para o embarque de navios. As RPs têm uma capacidade nominal de 8000 t/h. As rotas operacionais são compostas por RPs, CTs e CNs, que têm uma capacidade nominal de transporte de até 16000 t/h, então duas RPs podem fazer a retomada simultânea para uma rota de 16000 t/h ou uma RP para fazer a retomada para uma rota de 8000 t/h (MOURA et al.,). A retomada do minério é feita por equipamentos grandes, sua estrutura é constituída de duas partes, uma fixa em relação ao movimento de rotação e outra móvel (WILLIAMS et al., 2000). Na parte fixa, os *trucks* de translação estão instalados e na parte móvel (movimento de rotação da lança), a lança e o contrapeso estão instalados, na ponta da lança está a RC, dispositivo que faz a retomada de minério (LOPES et al., 2012). Conforme mostrado na Figura 74, à esquerda uma RP, e à direita a RC é destacada, este é o dispositivo que ataca a pilha para fazer a retomada.

Figura 74 – Retomadora - em destaque a roda de caçambas.



Os três principais eventos que ocorrem durante o processo operacional da planta são apresentados no diagrama de blocos da Figura 75. A etapa de translação é o primeiro evento a ocorrer e simultaneamente, ocorrem os eventos de rotação da lança e rotação da RC. Os eventos, velocidade de rotação da lança da RP, velocidade de rotação da RC e do tamanho do passo de translação não são controlados, o único evento controlado é a velocidade de rotação da lança na busca do fluxo desejado. O evento passo de translação varia de 0 a 1 m e ocorre isolado dos outros eventos, isto é, ocorre no início de cada estágio. Uma camada para ser retomada requer várias etapas de translação, que são os estágios, estes ocorrem primeiro e após cada estágio, os eventos velocidade de rotação da lança e velocidade de rotação da RC ocorrem simultaneamente. A intensidade da corrente elétrica do motor da RC gera uma estimativa de fluxo em t/h, o fluxo estimado é comparado ao fluxo medido pela balança e a diferença entre o fluxo estimado e o fluxo medido é o erro, que por sua vez, é tratado para garantir o melhor desempenho do sistema.

Figura 75 – Diagrama de blocos do processo de retomada de minério.




7.1.2 Caracterização do Problema

O processo de retomada de minério por RP apresenta uma certa complexidade, porque os eventos ocorrem de forma discreta, ou seja, um evento só tem alteração em seu comportamento se houver uma mudança na ação do mesmo. Os principais eventos do processo de retomada de minério são o tamanho do passo de translação, a corrente elétrica do motor da RC e a velocidade de rotação da lança.

O fluxo do processo de retomada do minério é cíclico, começando com o posicionamento da máquina na pilha onde o minério é armazenado, a definição da altura das camadas, o tamanho do passo de translação, sentido de rotação da lança e o comprimento da bancada a ser retomada. Este fluxo total é mostrado na Figura 76. Para uma melhor compreensão, o sistema de controle deve ser implementado para atuar sobre a velocidade da rotação da lança da RP, de modo a manter a carga desejada ao longo do processo de retomada. O sistema de controle com base no

RLQD resolvido por PDHDA com ação integral atua diretamente no controle da velocidade de rotação da lança, mas é influenciado pelo tamanho do passo de translação e pela intensidade da corrente elétrica do motor da RC, ou seja, de acordo com os três eventos mostrados na Figura 75.


Figura 76 – Fluxograma do processo de retomada.



No desenvolvimento da metodologia proposta neste trabalho, o modelo de planta não é utilizado. Essa metodologia é concebida com base na abordagem PDHDA para projetar uma lei de controle ótima que é estimada *on-line* em tempo real diretamente a partir dos dados observados ao longo das trajetórias dos estados de entrada e saída do sistema. O conjunto de dados consiste basicamente em intensidade de corrente elétrica do motor da RC, a velocidade de rotação da lança da RP medida por um *encoder* e a carga medida na balança ou volume retornado.

A retomada do minério é feita da seguinte forma: a pilha é dividida em n camadas e m bancadas, sendo $L_{i,j}$ representa a camada i -esima e a bancada j -iesima, com $i = 1, \dots, n$ e $j = 1, \dots, m$. Na Figura 77 apresenta uma pilha com $i = 1, \dots, 20$ e $j = 1, \dots, 5$. As linhas verdes representam o fluxo convencional do processo, que começa com $q(t)$ carga inicial, depois para a camada $L_{1,1}$ seguindo uma sequência consecutiva até atingir a carga total armazenada na pilha $q(T)$. As linhas vermelhas representam as outras possibilidades da sequência do fluxo, ou seja, o fluxo não convencional. Caso seja impossível seguir o fluxo convencional, é assegurado que qualquer decisão tomada é ótima, independente de decisões anteriores. O controlador proposto neste trabalho atua apenas com base nos sinais medidos pelos sensores, sem a necessidade do modelo da planta. Se a pilha tiver uma variação em suas características físicas e químicas, isso afetará diretamente os sinais medidos e com base nessas informações, o controlador tomará a decisão.

Figura 77 – Fluxo de uma retomada de uma pilha.




Os dados apresentados na Tabela 20 referem-se as informações do processo de retomada da camada L_{1_1} (destacada na Figura 77) composto por 12 passos de translação indicados na coluna 1 ($S_1, \dots, S_{12}$). A variação média da intensidade da corrente elétrica (I) do motor de acionamento da RC é exibida na coluna 2. Na coluna 3, o comprimento de cada passo de translação (S) é ilustrado. A coluna 4 mostra a variação média da velocidade de rotação da lança (G). As informações restantes são o fluxo da carga retomada (F) e o tempo de avanço (T) mostrado nas colunas 6 e 7, respectivamente. Tais dados foram usados para a construção de um simulador via *MATLAB/SIMULINK* retratando o processo operacional da RP para a validação do projeto de controle ótimo baseado em PDHDA. A é apresentada e destaca-se em cinza uma camada, o mesmo procedimento foi seguido para as outras camadas. Os dados apresentados foram coletados durante doze passos de translação do processo de retomada de uma camada, com intervalo de amostragem de 0,005 s. A planta foi instrumentada com um amperímetro para medir a variação da corrente elétrica do motor da RC, dois *encoders*, um para medir o tamanho do passo de translação e outro para medir a velocidade de rotação da lança e uma balança dinâmica para medir o fluxo horário do minério em toneladas por hora. Na lógica de controle, um temporizador para contar o tempo de cada estágio foi inserido. Todos os sensores mencionados foram registrados no PIMS para coletar os dados *online*.

Tabela 20 – Comportamento de fluxo em toneladas por hora (t/h) da camada L_{11} no passo (S) de 1 até 12 (S_1 até S_{12}).

L_{11}	I (A)	S_L (m)	G (m/s)	F (t/h)	T(s)
S_1	50	1,00	4,00	5600	40
S_2	65	0,80	4,30	6030	42
S_3	69	0,70	4,50	4840	38
S_4	80	0,60	4,50	6700	41
S_5	78	0,60	4,40	6500	43
S_6	67	1,00	3,90	6500	45
S_7	65	0,80	4,20	7210	43
S_8	75	0,70	4,40	6530	48
S_9	82	0,60	4,50	5340	50
S_{10}	55	0,90	4,50	6510	56
S_{11}	60	1,00	4,40	5200	51
S_{12}	65	1,00	4,30	6150	54

As referências de dados obtidas nas colunas dois e cinco da Tabela 20 foram usados para gerar a Figura 78. Nota-se que o comportamento dos dados da corrente elétrica do motor da RC em comparação com o comportamento dos dados de fluxo do minério medido pela balança, apresentaram o mesmo comportamento. A curva em azul representa o fluxo de minério em toneladas por hora e a curva em vermelho representa a intensidade da corrente elétrica do motor da RC durante o processo de retomada do minério. Observou-se também que a variação do fluxo é proporcional à variação da velocidade de rotação da lança da RP. Com isso em mente, o sistema de controle foi concebido para agir diretamente no controle de velocidade da rotação da lança da RP.

Figura 78 – Comportamento da corrente elétrica do motor da RC x vazão de minério durante a retomada nas cinco camadas iniciais de uma pilha.



7.1.3 Q-Learning

A concepção do método com base na PDHDA para o projeto de RLQ (LANDELIUS, 1997) é baseada em sinais de entrada e estado *online* da planta. A PDHDA, baseia-se no aprendizado Q – *learning*, que será denotado por Q_L , e consiste em um método para estimar a função- Q_L para qualquer política ótima ou não ótima (NETO; RÊGO,) e (ZHANG et al., 2012). A formulação PDHDA requer apenas amostras da função de recompensa instantânea r (NI et al., 2015). A abordagem PDHDA é apresentada em duas instâncias. Em primeiro lugar, o Q_L é formulado em termos da equação *Bellman* e formas de política de decisão ótima (LEWIS; LIU, 2013). Em segundo lugar, a aproximação da função- Q_L para obter a política de controle ótimo é abordada.

A política de controle é dada pelo mapeamento $g : X \rightarrow U$ que produz a ação u a ser tomada em cada etapa k , onde X é o espaço de estado e U é a ação de controle. Para uma determinada política de controle $g(x) = u$, a função- V de ação $Q_L^g : X \times U \rightarrow \mathbb{R}$ é dada como a soma descontada das recompensas de longo prazo obtidas a partir de um determinado estado x , tomando uma determinada ação u , e usando g para gerar ações futuras. A função- V Q_L^g é dada por

$$Q_L^g(x, u) = \sum_{k=0}^{\infty} \gamma^k r(x_k, u_k), \quad (132)$$

sendo γ o fator de desconto que é definido em $0 \leq \gamma \leq 1$. Na forma da equação de *Bellman*, segue-se que a função ação-valor, Eq. (132) na forma de equação a diferença é dada por

$$Q_L^g(x, u) = r(x, u) + \gamma Q_L^g(f(x, u), g(f(x, u))), \quad (133)$$

sendo f a função de transição de estado (modelo do sistema dinâmico).

De acordo com a equação de otimalidade de *Bellman*, a função de ação-valor ótima, denotada por Q_L^* , deve satisfazer a seguinte condição

$$Q_L^*(x, u) = r(x, u) + \gamma Q_L^*(f(x, u), g^*(f(x, u))). \quad (134)$$

O lado direito da Eq. (133) é usado como o valor alvo para aproximar Q_L por um modelo parametrizado

$$d(r, f, g(f), \theta) = r(x, u) + \gamma Q_L(f(x, u), g(f(x, u)), \theta). \quad (135)$$

Os erros quadráticos entre o valor estimado $Q_L(x, u, \theta)$ e o valor medido $d(\cdot)$ são minimizados, com vista a melhorar com a política gulosa da estimativa ótima de parâmetros. Os novos

parâmetros geram novas metas, mostrando que o processo é executável computacionalmente. Que é obtido por

$$\theta_{j+1} = \arg \min_{\theta} E \left\{ |Q_L(x, u, \theta) - d(r, f, g(f), \theta_j)|^2 \right\}, \quad (136)$$

sendo $E(\cdot)$ o valor esperado

A iteração gulosa é a política utilizada para determinar a função- Q_L ótima. A política é parametrizada como $g(x) = g(x, u)$. A lei de controle é obtida pela equação da otimalidade *Bellman* para a função- Q_L , Eq. (134), que é dada por

$$u^* = g^*(x) = \arg \max_u Q_L^*(x, u). \quad (137)$$

Essa política permite a determinação de políticas ótimas que não fazem referência a um modelo do ambiente f .

7.1.4 DLQR com Base em Sensores

Nesta Subsecção apresenta-se a base para a construção de uma metodologia baseada em dados guiados por sensores (*data-driven*) para um sistema de controle independente de modelo aplicado ao processo operacional de uma RP.

7.1.4.1 Parametrização DLQR

Para o DLQR, as funções parametrizadas são classificadas nos parâmetros Q_L e R do custo instantâneo (função de utilidade) e nos parâmetros A e B do sistema dinâmico (ambiente). As parametrizações do ambiente são dadas pelo sistema dinâmico que é representado por

$$f(x, g(x)) = A_d x + B_d u, \quad (138)$$

sendo $A_d \in \mathbb{R}^{n \times n}$, n a ordem do sistema, $B_d \in \mathbb{R}^{n \times n_e}$ e n_e é o número de entradas do sistema. A política de controle, formada a partir da combinação linear de estados, é dada por

$$g(x) = -K(\cdot)x, \quad (139)$$

sendo $K(\cdot) \in \mathbb{R}^{n_e \times n}$ a matriz de ganhos de realimentação do estado.

A parametrização do custo instantâneo é a função de utilidade em k , representando os desvios de estado e a energia da política de controle em $k - 1$ para o estado em k , que é dado por

$$r(x, u) = x^T Q x + u^T R u, \quad (140)$$

sendo $Q_L \in \Re^{n_e \times n_e} \geq 0$ a matriz de ponderação do estado e $R \in \Re^{n \times n} > 0$ é a ponderação da matriz de controle.

A parametrização da função de utilidade da Eq. (140) é substituído na Eq. (132) para obter a função de custo DLQR parametrizada, onde a política de controle é dada por uma matriz de ganho de retorno constante K , Eq. (139), (HE et al., 2015). A solução ótima do custo Q_L da Eq. (133) é uma forma quadrática que é dada por

$$Q_L(x, u) = \begin{bmatrix} x \\ u \end{bmatrix}^T \begin{bmatrix} H_{xx} & H_{xu} \\ H_{ux} & H_{uu} \end{bmatrix} \begin{bmatrix} x \\ u \end{bmatrix} \triangleq z^T H z, \quad (141)$$

sendo $H_{xx} = Q + \gamma A_d^T P A_d$, $H_{xu} = \gamma A_d^T P B_d$, $H_{ux} = \gamma B_d^T P A_d$, $H_{uu} = R + \gamma B_d^T P B_d$, para alguma matriz $P \in \Re^{n \times n} > 0$, e $z = \begin{bmatrix} x & u \end{bmatrix}$.

A minimização da função- Q_L parametrizada fornece os meios para determinar a política ótima u . O gradiente $\partial Q_L / \partial u$ é dado por

$$\frac{\partial Q_L}{\partial u} = \frac{\partial}{\partial u} \begin{bmatrix} x \\ u \end{bmatrix}^T \begin{bmatrix} H_{xx} & H_{xu} \\ H_{ux} & H_{uu} \end{bmatrix} \begin{bmatrix} x \\ u \end{bmatrix}. \quad (142)$$

A equação de gradiente $\partial Q_L / \partial u = 0$, quando resolvido por u , fornece a política ótima. Consequentemente, o controle ótimo é dado por

$$u = -H_{uu}^{-1} H_{ux} x = K(H) x. \quad (143)$$

A forma quadrática do custo ótimo, Eq. (141), é aproximado por uma transformação que usa o produto *Kronecker* para obter um sistema de equação linear em Q_L . Ao aplicar as definições de *Kronecker* e vetorizações (BREWER, 1978), (LOAN; PITSIANIS, 1993), (BJÖRCK, 2015), é que o valor de custo ótimo é representado por

$$Q_L^K(x_k, u_k) = z_k^T H^K z_k = \bar{z}_k^T \text{vec}(H^K), \quad (144)$$

sendo $\text{vec}(H^K)$ a vetorização da matriz de aprendizagem H^K , e $\bar{z}_k \in \Re^{(n+n_e)(n+n_e+1)/2}$ é definida de acordo com o produto *Kronecker* que é dado por

$$\bar{z}_k^T = z_k^T \otimes z_k^T = [x_{1k} z_k^T \dots x_{nk} z_k^T \ u_{1k} z_k^T \dots u_{n_e k} z_k^T]. \quad (145)$$

A função $vec(H^K) \in \mathbb{R}^{(n+n_e)(n+n_e+1)/2}$ é um vetor que contém $n + n_e$ elementos diagonais da matriz H^K e a $\frac{(n+n_e)(n+n_e+1)}{2} - n$ somas não repetidas $H_{ij}^K + H_{ji}^K$.

Substituindo a vetorização da Eq. (144) na equação de *Bellman* (133), em termos de recompensa instantânea para o projeto DLQR, obtém-se a relação de recompensa estimada que é dada por

$$r(x_k, u_k) + \gamma \bar{z}_{k+1}^T vec(H^K) = \bar{z}_k^T vec(H^K) = \phi_k^T \theta^K. \quad (146)$$

7.1.5 Projeto de Controle Online e Ótimo

Apresenta-se o desenvolvimento da metodologia do controle ADHDP-DLQR-IA para otimização e adaptação do projeto de controle de fluxo de minério. O projeto de controle é concebido levando-se em consideração possíveis variações da dinâmica da planta que podem mudar o ponto de operação do sistema, uma vez que os controladores PI convencionais não atendem satisfatoriamente a todos os aspectos da variação da dinâmica da planta. Tendo em vista que esses controladores são sintonizados por um método de tentativa e erro, dificultando a determinação de novos parâmetros de ganhos K_P e K_I cada vez que a dinâmica da planta passa por variações.

O método ADHDP-DLQR-IA foi implementado para garantir o controle ótimo da planta. Enquanto o controlador ADHDP-DLQR-IA atua na dinâmica da planta garantindo a otimização do desempenho do sistema, a ação integral atua para reduzir o erro no estado estacionário. O controle ADHDP-DLQR-IA garante a convergência de todas as variáveis controladas. No projeto ADHDP-DLQR-IA, o método RLS é usado para estimar os parâmetros da função de custo RLQD (FERREIRA et al., 2017). Em seguida, apresenta-se a descrição matemática do controle do sistema ADHDP-DLQR-IA aplicada ao processo de retomada do minério via RP.

7.1.5.1 Formulação do Problema ADHDP-DLQR-IA

Seja a planta ser representada por

$$x_{k+1} = A_d x_k + B_d u_k, \quad (147)$$

$$y_k = C_d x_k, \quad (148)$$

sendo $x_k \in \mathbb{R}^n$ é o estado, $u_k \in \mathbb{R}^{n_e}$ é a entrada de controle, e $y_k \in \mathbb{R}^{n_s}$ é a saída.

Para formular o desempenho do sistema ADHDP-DLQR-IA, uma nova variável de estado baseada em medidas é definida por

$$\varepsilon_k = \varepsilon_{k-1} + u_{ref} - y_k, \quad (149)$$

sendo u_{ref} é a entrada de referência. A Eq. (149) é adicionado para reduzir erros de estado estacionário correspondentes ao erro de regulação acumulada para a saída y_k . Cosequentemente, a partir da Eq. (147), tem-se que o novo sistema de equações dado por


$$\begin{bmatrix} x_{k+1} \\ \varepsilon_{k+1} \end{bmatrix} = \begin{bmatrix} A_d & 0 \\ -C_d A_d & 1 \end{bmatrix} \begin{bmatrix} x_k \\ \varepsilon_k \end{bmatrix} + \begin{bmatrix} B_d \\ -C_d B_d \end{bmatrix} u_k + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u_{ref}. \quad (150)$$

Um diagrama do sistema de controle ADHDP-DLQR-IA é mostrado na Figura 79, que compreende os blocos atores e críticos que realizam as avaliações e melhorias das políticas de decisão. Um integrador é inserido no *loop* de controle para que a lei de controle seja dada por (OGATA, 2009)

$$u_k = -Kx_k + K_I \varepsilon_k = - \begin{bmatrix} K & -K_I \end{bmatrix} \begin{bmatrix} x_k \\ \varepsilon_k \end{bmatrix}, \quad (151)$$

sendo $\tilde{K} = \begin{bmatrix} K & -K_I \end{bmatrix}$ é uma matriz de blocos de ganhos, composta pelas matrizes de ganho de realimentação K e ganho integral K_I .

Figura 79 – Sistema de controle com aprendizado de crítico aplicado ao processo operacional de RP.



Agora, a política ótima de controle é parametrizada pela relação linear dos estados x_k e ε_k que é dado por

$$u_k = \tilde{K}(\tilde{H}_k) \tilde{x}_k, \quad (152)$$

sendo $\tilde{K}(\tilde{H}) = -\tilde{H}_{uu}^{-1} \tilde{H}_{ux}$ e $\tilde{H}_{uu}$ e $\tilde{H}_{ux}$ são blocos da matriz de aprendizagem expandida $\tilde{H}$ que está associada à função- V definida por

$$\tilde{Q}_L(\tilde{x}_k, u_k) = \tilde{z}_k^T \tilde{H} \tilde{z}_k, \quad (153)$$

sendo $\tilde{x}_k^T = \begin{bmatrix} x_k^T & \varepsilon_k^T \end{bmatrix}$ and $\tilde{z}_k^T = \begin{bmatrix} \tilde{x}_k^T & u_k^T \end{bmatrix}$.

Assim, o problema de controle é reduzido para encontrar a matriz $\tilde{K}$ para que a função- $\tilde{Q}_L$ seja minimizada. A estimativa de parâmetros da função- $\tilde{Q}_L$ é baseada no mesmo esquema iterativo apresentado na Eq. (146) para estimar a função- Q_L , então na etapa de avaliação de política, tem a estrutura paramétrica que é dada por

$$\tilde{z}^T \tilde{\theta}_{k+1} = \tilde{z}^T d(\tilde{z}, \tilde{r}, g(f, \varepsilon), \tilde{K}^\theta), \quad (154)$$

sendo $d(\cdot)$ é o modelo de função- V para todo o sistema que é dado por

$$d(\tilde{z}, \tilde{r}, g(f, \varepsilon), \tilde{K}^\theta) = \tilde{x}_k^T \tilde{Q} \tilde{x}_k + u_k^T \tilde{R} u_k + \tilde{z}_{k+1}^T \tilde{H} \tilde{z}_{k+1}. \quad (155)$$

As atualizações do parâmetro $\tilde{H}$ da função- V , bem como o parâmetro $\tilde{K}$ da política de controle são simplesmente baseados em informações provenientes da interação entre o ator (controlador) e o processo (planta) e inclui observações dos estados x_k e ε_k , ações de controle u_k e custos instantâneos $\tilde{r}_k$.


Para a planta processo operacional de RP em particular, o sistema de controle possui variáveis de estado x_k correspondentes a x_1, x_2 e x_3 , onde x_1 é a corrente elétrica do motor da RC medida por um amperímetro, x_2 é a velocidade de rotação da lança da RP medida por um codificador, x_3 , que é igual a y_k , é a carga medida por uma escala dinâmica instalada na lança RP, u_k é a frequência elétrica f_k (Hz) do motor de rotação da lança medido pelo inversor de frequência e Δ é o operador de atraso.

7.1.5.2 Algoritmo ADHDP-DLQR-IA

As principais etapas para determinar a política de controle ideal são apresentadas no seguinte algoritmo. Neste algoritmo, uma implementação recursiva de mínimos quadrados é usada para encontrar $\text{vec}(\tilde{H})$. Neste caso, o algoritmo tem uma reposição de persistência (condição de revitalização do estado) devido a problemas de estado nulo que levam a matriz de regressão a ter *rank* nulo. Nesse caso, a revitalização é aplicada no final de cada intervalo de revitalização.

Para uma melhor compreensão, o algoritmo é dividido em dois blocos, como mostrado na Figura 80.

Figura 80 – Blocos de algoritmo.



Os blocos do algoritmo com os respectivos passos mostrados na Figura 80 estão descritos abaixo

1) Primeiro bloco - Parâmetros do processo iterativo e condições iniciais: No primeiro bloco, as condições iniciais e os parâmetros do processo iterativo para a configuração do algoritmo são definidos.

- 1 ▷ Setup (Parâmetros do processo iterativos e condições iniciais)
- 2 ▷ Matrizes de Ponderação da Dinâmicas do Sistema: $\tilde{Q}, \tilde{R}, A_d, B_d$
- 3 ▷ Fator de Desconto: $0 < \gamma \leq 1$
- 4 ▷ Parâmetros RLS: μ, Φ_0, θ_0
- 5 ▷ Redefinição de Estados: $x_{revit}, \varepsilon_{revit}$
- 6 ▷ Estados Iniciais: x_0, ε_0
- 7 ▷ valores Iniciais de $\tilde{H}, \tilde{K}$: $\tilde{H}_0$ e $\tilde{K}_0 = [K_0 \ K_{I_0}]$
- 8 ▷ Número de Iterações: N
- 9 ▷ $m \leftarrow n + n_e$
- 10 ▷ $n_\theta \leftarrow \frac{(n+n_e)(n+n_e+1)}{2}$
- 11 ▷ $n_{revit} \leftarrow n_\theta$

2) Segundo bloco - Processo iterativo: O segundo bloco do algoritmo ADHDP-DLQR-IA implementa as atualizações da função- V na etapa b) (montagem de destino), bem como o vetor de regressão (produto *Kronecker*) na etapa c) para cada leitura das amostras da transição do estado. Ele também implementa as atualizações do parâmetro θ vector no passo d), a matriz de recuperação $\tilde{H}$ do vetor θ no passo e) eo ganho de computação $\tilde{K}$ no passo f).

- 1 ▷ Processo Iterativo
- 2 para $\leftarrow 0:N$

a) Simulator: nesta etapa, as simulações de estado e sinais de entrada medidos por sensores são realizadas.

- 1 ▷ Ambiente de Simulação
- 2 Implementação de Ruído de Controle
- 3 $\xi_i \leftarrow []$
- 4 Ação de Controle
- 5 $u_{(:,i)} = -K_i x_{(:,i)} + K_{I_i} \varepsilon_i + \xi_i$
- 6 ▷ Estados
- 7 $x_{i+1} \leftarrow A_d x_{(:,i)} + B_d u_i$
- 8 $\varepsilon_{i+1} \leftarrow \varepsilon_k + u_{ref} - C_d x_{(:,i+1)}$
- 9 $\tilde{x}_{(:,i)} \leftarrow [x_{(:,i)}; \varepsilon_{(:,i)}]$

b) Objetivo: nesta etapa, o alvo que será usado como função objetivo na estimativa RLS será montado.

- 1 ▷ Cálculo do Alvo
- 2 $d_i \leftarrow \tilde{x}_{(:,i)}^T \tilde{Q} \tilde{x}_{(:,i)} + u_i^T \tilde{R} u_i + [\tilde{x}_{(:,i+1)}; \tilde{K} \tilde{x}_{(:,i+1)}]^T \tilde{H} [\tilde{x}_{(:,i+1)}; \tilde{K} \tilde{x}_{(:,i+1)}]$

c) Produto Kronecker: nesta etapa, as variáveis de estado do produto *Kronecker* são realizadas.

- 1 ▷ Conjunto Básico - Produto Kronecker
- 2 $\tilde{\tilde{z}}_{(:,i)} \leftarrow [\tilde{x}_{(1,i)}^2; \tilde{x}_{(1,i)} \tilde{x}_{(2,i)}; \tilde{x}_{(1,i)} \tilde{x}_{(3,i)}; \tilde{x}_{(1,i)} \tilde{x}_{(4,i)}; \tilde{x}_{(1,i)} u_i; \tilde{x}_{(2,i)}^2; \tilde{x}_{(2,i)} \tilde{x}_{(3,i)}; \tilde{x}_{(2,i)} \tilde{x}_{(4,i)}; \tilde{x}_{(2,i)} u_i; \tilde{x}_{(3,i)}^2; \tilde{x}_{(3,i)} \tilde{x}_{(4,i)}; \tilde{x}_{(3,i)} u_i; \tilde{x}_{(4,i)}^2; \tilde{x}_{(4,i)} u_i; u_i^2]$

d) Busca RLS: nesta etapa, as atualizações dos parâmetros RLS de saídas são realizadas.

- 1 ▷ Atualização de vetores θ_i por meio dos Mínimos Quadrados Recursivos (RLS)
- 2 $\varphi \leftarrow \tilde{\tilde{z}}_{(:,i)}$
- 3 $e \leftarrow d_i - \varphi^T \theta$
- 4 $\theta_{i+1} \leftarrow \theta_i + ((\Phi_i \phi_i) / \mu + \phi_i^T \Phi_i \phi_i) e$
- 5 $\Phi_{i+1} \leftarrow (1/\mu) [\Phi_i - (\Phi_i \phi_i \phi_i^T \Phi_i) / (\mu + \phi_i^T \Phi_i \phi_i)]$

e) Matriz $\tilde{H}$ Recuperação de Vector θ : nesta etapa, a associação do vetor θ com a matriz $\tilde{H}$ é realizada.

- 1 ▷ Matriz $\tilde{H} \leftarrow \begin{bmatrix} \theta_1 & \theta_2/2 & \theta_3/2 & \dots & \theta_m/2 \\ \theta_2/2 & \theta_{m+1} & \theta_{m+2}/2 & \dots & \theta_{2m-1}/2 \\ \theta_3/2 & \theta_{m+2}/2 & \theta_{2m} & \dots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \theta_{n_\theta-1}/2 \\ \theta_m/2 & \theta_{2m-1}/2 & \dots & \theta_{n_\theta-1}/2 & \theta_{n_\theta} \end{bmatrix}$

f) Computação do ganho ótimo de realimentação: finalmente, nesta etapa, o ganho ótimo de realimentação é atualizado.

- 1 $\triangleright$ Ganhos ótimos de realimentação $\tilde{K}$
- 2 $\tilde{K}_{i+1} \leftarrow \tilde{H}_{uu}^{-1} \tilde{H}_{ux}$

g) Revitalização de estado: nesta etapa, a revitalização dos estados é realizada para ignorar problemas de estado nulo que levam à matriz de regressão com classificação nula. A revitalização é aplicada a cada intervalo n_{revit} .

- 1 $if \text{ mod } (i, n_{revit}) = 0$
- 2 $x(:, i+1) \leftarrow x_{revit}$
- 3 $\varepsilon(:, i+1) \leftarrow \varepsilon_{revit}$
- 4 Fim (Processo Iterativo)

7.1.6 Resultados de Simulações

Os experimentos são realizados para avaliar a política ótima da Eq. (152) que é obtida sem a computação direta da solução da equação HJB. A realização da estratégia PDHDA é orientada por algoritmo ADHDP-DLQR-IA *online*. Para tal algoritmo, a computação de ganho $\tilde{K}$ é realizada em duas etapas: a) a solução HJB para a função- $\tilde{Q}_L$ e b) a política ótima $\tilde{K}_{ADHDP}^{final}$.

As matrizes de ponderação $\tilde{Q}$ e $\tilde{R}$ são usadas para penalizar os desvios das variáveis de estado e o custo da política de controle. Os métodos de pesquisa das matrizes $\tilde{Q}$ e $\tilde{R}$ são orientados a impor um objetivo de controle especificado. A classificação desses métodos é baseada em suas características de busca, como pesquisa heurística (BRYSON, 1975), busca empírica (NETO et al., 2010) e pesquisa baseada em inteligência computacional (NETO et al.,). Neste trabalho, essas matrizes foram definidas pelo método de busca empírica (por tentativa e erro).

O desempenho do controlador proposto é avaliado para o processo operacional de um RP de minério de ferro, que é um equipamento de grande porte de acordo com o arranjo mecânico de uma RP mostrado na Figura 45, destacando seus principais componentes e suas dimensões (20000 t de massa, 102 m de comprimento, 36 m de altura e 22 m de largura). O controlador que usa o método ADHDP-DLQR-IA atua na variação de velocidade da rotação da lança, com um valor máximo de 4,5 m/s, como a velocidade de rotação da lança é relativamente alta para a massa a ser movimentada, essa variação de velocidade também não pode ser abrupta.

Os resultados obtidos pelo algoritmo ADHDP-DLQR-IA aplicado ao processo operacional de uma retomadora de minério foram analisados de acordo com a convergência de seus parâmetros com a solução do método de *Schur* (true), onde foi possível observar a convergência de todos os elementos da matriz $\tilde{H}_{ADHDP}$ e o vetor de ganhos $\tilde{K}_{ADHDP}$ para os elementos da matriz $\tilde{H}_{Schur}$ e o vetor de ganhos $\tilde{K}_{Schur}$, respectivamente.

7.1.7 Setup da Simulação

A configuração do Algoritmo ADHDP-DLQR-IA consiste nas informações relacionadas aos parâmetros do sistema dinâmico, ponderações de recompensas instantâneas, condições iniciais e parâmetros de processo iterativo, conforme apresentado no primeiro bloco do algoritmo ADHDP-DLQR-IA. Essa informação é estabelecida tendo como referência o empirismo do especialista do projeto ou as relações entre as variáveis do sistema relacionadas aos métodos e consiste nos seguintes elementos: matrizes de modelos discretos (A_d, B_d) , matrizes de ponderação de estado e controle $(\tilde{Q}, \tilde{R})$, tempo de amostragem t_{samp} , fator de desconto λ , condições iniciais do ganho do controlador $\tilde{K}$ e matriz $\tilde{H}$ estimativas de parâmetros $(K_0, K_{I_0}, \tilde{H}_0)$, condições iniciais do sistema (x_0, ε_0) , e número de iterações N . Quanto ao estimador RLS, tem-se: intervalo de revitalização do estado n_{revit} com relação à condição de excitação persistente, condições iniciais (Φ_0, θ_0) , fator de esquecimento μ , e revitalização de estado $(x_{revit}, \varepsilon_{revit})$.

7.1.8 Estimativa da Lei de Controle Ótimo

Os valores ótimos dos parâmetros $\tilde{H}$ e $\tilde{K}$ pelo método de *Schur* são comparados com aqueles obtidos a partir da abordagem PDHDA. Estes valores são usados para avaliar a precisão das soluções aproximadas pelo método PDHDA, levando em conta que os valores de *Schur* são os valores verdadeiros. A solução de *Schur* para $\tilde{H}_{Schur}$ associada com Eq. (141) é dada por

$$\tilde{H}_{Schur} = \left[\begin{array}{cccc|c} 4,7041 & 1,4787 & 0,4637 & 3,0962 & -0,1400 \\ 1,4787 & 2,3612 & 0,2310 & 1,3292 & -0,0813 \\ 0,4637 & 0,2310 & 1,7220 & 0,2873 & -0,0657 \\ 3,0962 & 1,3292 & 0,2873 & 2,6337 & -0,1034 \\ \hline -0,1400 & -0,0813 & -0,0657 & -0,1034 & 0,1068 \end{array} \right], \quad (156)$$

e $\tilde{K}_{Schur}$ associada com a Eq. (143) é dada por

$$\tilde{K}_{Schur} = \begin{bmatrix} -1,3663 & 0,7608 & -0,6151 & -0,9674 \end{bmatrix}. \quad (157)$$

A solução $\tilde{H}_{\infty}^{ADHDP}$ é dada por

$$\tilde{H}_{\infty}^{ADHDP} = \left[\begin{array}{ccccc} 4,7041 & 1,4787 & 0,4637 & 3,0962 & -0,1400 \\ 1,4787 & 2,3612 & 0,2310 & 1,3292 & -0,0813 \\ 0,4637 & 0,2310 & 1,7220 & 0,2873 & -0,0657 \\ 3,0962 & 1,3292 & 0,2873 & 2,6337 & -0,1034 \\ -0,1400 & -0,0813 & -0,0657 & -0,1034 & 0,1068 \end{array} \right], \quad (158)$$

e a solução $\tilde{K}_{\infty}^{ADHDP}$ é dada por

$$\tilde{K}_{\infty}^{ADHDP} = \begin{bmatrix} -1,3663 & 0,7608 & -0,6151 & -0,9674 \end{bmatrix} \quad (159)$$

O comportamento do processo de estimação paramétrica dos ganhos ótimos é apresentado nas Figuras 81-85, onde é possível observar o tempo de acomodação, a severidade do processo e o *overshoot*. A convergência dos parâmetros θ_i da matriz $\tilde{H}_{\infty}^{ADHDP}$ para os parâmetros da solução *Schur* $\tilde{H}_{Schur}$ ocorreu em torno de 180 s. Aos 120 s, no entanto, uma tendência de convergência de todos os parâmetros analisados é observada. Pode-se também observar um comportamento suave dos estados transitórios, não apresentando problemas de possíveis perdas das trajetórias de estabilização do sistema.

Figura 81 – Comportamento de convergência dos parâmetros θ_1 , θ_2 e θ_3 para o processo operacional da RP.




Figura 82 – Comportamento de convergência dos parâmetros θ_4 , θ_5 e θ_6 para o processo operacional da RP.




Figura 83 – Comportamento de convergência dos parâmetros θ_7 , θ_8 e θ_9 para o processo operacional da RP.




Figura 84 – Comportamento de convergência dos parâmetros θ_{10} , θ_{11} e θ_{12} para o processo operacional da RP.






Figura 85 – Comportamento de convergência dos parâmetros θ_{13} , θ_{14} e θ_{15} para o processo operacional da RP.



A comparação do valor de estado estacionário dado pela Eq. (158) com a solução *Schur* de Eq. (156) mostra uma boa precisão na aproximação do PDHDA, mostrando que o estimador PDHDA baseado em RLS é consistente. Tendo em conta que a fusão PDHDA e RLS atinge o estimador, a convergência pode ser melhorada em termos de ajustes nos parâmetros RLS do algoritmo ADHDP-DLQR-IA.


Do ponto de vista dos sistemas de controle, mostra-se a trajetória dos estados x_k e o sinal de controle u_k que é aplicado ao sistema no ajuste dos parâmetros do PDHDA para o modelo de terceira ordem (Retomadora de minério) para efeito da análise do desempenho do algoritmo ADHDP-DLQR-IA. Os comportamentos dos estados do sistema x_k e ε_k para o modelo de terceira ordem são apresentados na Figura 86. Para manter a condição de excitação do problema de mínimos quadrados recursivos, a reconfiguração de estado é executada com $\tilde{x}_{revit} = \begin{bmatrix} 4 & 2 & 5 & 10 \end{bmatrix}^T$, após cada intervalo de recorrência, para evitar problemas de singularidade com a matriz regressora $\Gamma = \Phi^{-1}$. Observa-se que a revitalização dos estados e o erro do sistema durante os experimento para o projeto DLQR baseado em PDHDA estão excitados em torno de zero.

Figura 86 – Trajetórias dos estados e do erro do sistema com atualização durante o experimento para o processo operacional da RP.



O comportamento do sinal de controle u_k associado ao sinal de ruído n_k é mostrado na Figura 87. Observa-se que os esforços de controle oscilam após serem revitalizados, reagindo abruptamente para atender as especificações do projeto frente às variações na dinâmica do processo.

Figura 87 – Sinal de controle com ruído para o processo operacional da RP.




7.1.9 Resultados do Processo de Controle

Os resultados do processo recuperador de minério são apresentados e analisados a partir do ponto de vista de controle em duas instâncias. Em primeira instância, o desempenho do controlador é avaliado sem levar em conta perturbações aleatórias nos estados da planta. Em segunda instância, a rejeição às perturbações aleatórias no sistema é testada.

7.1.9.1 Avaliação do Objetivo de Controle


Os valores correspondentes são apresentados na Figura 88, representando a influência de cada autovalor no traço da matriz da planta em malha fechada para o processo iterativo. Em termos de meta de controle, os traços e os autovalores associados mostram oscilações que representam o comportamento de estabilidade global do sistema dinâmico (durante o processo de busca da política de controle ótima). Os traços podem ser vistos como uma boa métrica para avaliar a convergência do algoritmo e para guiar as heurísticas de inteligência computacional, a fim de avaliar a convergência sem computar os autovalores do sistema de malha fechada, evitando o alto custo computacional do cálculo de autovalores em aplicações em tempo real.

Figura 88 – O comportamento do traço da matriz H e os autovalores associados com o modelo de malha fechada.



O comportamento da matriz de ganho é apresentado na Figura 89, onde o estado estacionário do valor estimado de K é alcançado em torno de 200 iterações, ilustrando a evolução do algoritmo ADHDP-DLQR-IA em relação ao vetor de ganhos $\tilde{K}_{\infty}^{ADHDP}$ convergindo para o vetor de ganho ótimo $\tilde{K}_{Schur}$, tendo seus componentes representados por linhas tracejadas. É importante enfatizar, observando a Figura 89, que a primeira atualização é executada após trigésima iteração, devido à condição necessária de inicialização do algoritmo ADHDP-DLQR-IA baseado no produto de *Kronecker*, Eq. (145). A atualização dos estados é realizada após cada 30 intervalos de recorrências.

Figura 89 – Ganhos do controlador ADHDP-DLQR-IA para o processo operacional do RP.



7.1.9.2 Avaliação de Rejeição as Perturbações

Para avaliar a robustez do sistema de controle em relação à rejeição a perturbações na planta, um vetor de perturbação aleatória foi inserido variando as condições dos estados da planta, simulando as variações físicas da pilha de minério, o que influencia o comportamento do fluxo horário da carga retomada. Das Figuras 90-94, pode-se observar que o sistema comporta-se satisfatoriamente mesmo com perturbações na planta, tanto para as avaliações paramétricas quanto para os resultados do controle. Ou seja, após a perturbação, o sistema tende a seguir a solução ótima (método de *Schur*). Todos os componentes da matriz $\tilde{H}_{ADHDP}$ e o vetor $\tilde{K}_{ADHDP}$ tendem-se para a convergência da matriz $\tilde{H}_{Schur}$ e para o vetor $\tilde{K}_{Schur}$.

Figura 90 – Comportamento de convergência dos parâmetros θ_1 , θ_2 e θ_3 com sinal de perturbação na planta para o processo operacional da RP.




Figura 91 – Comportamento de convergência dos parâmetros θ_4 , θ_5 e θ_6 com sinal de perturbação na planta para o processo operacional da RP.




Figura 92 – Comportamento de convergência dos parâmetros θ_7 , θ_8 e θ_9 com sinal de perturbação na planta para o processo operacional da RP.




Figura 93 – Comportamento de convergência dos parâmetros θ_{10} , θ_{11} e θ_{12} com sinal de perturbação na planta para o processo operacional da RP.






Figura 94 – Comportamento de convergência dos parâmetros θ_{13} , θ_{14} e θ_{15} com sinal de perturbação na planta para o processo operacional da RP.



O vetor de ganhos $\tilde{K}_{ADHDP}$ após a perturbação inserida na planta, oscilam em torno da solução ótima (verdadeira). Portanto, o algoritmo ADHDP-DLQR-IA, além de garantir uma solução ótima, garante robustez aos sinais de perturbação e variações paramétricas da planta, conforme Figura 95.

Figura 95 – Ganhos do controlador DLQR baseado em PDHDA com sinal de perturbação na planta para o processo operacional RP.

Políticas de Controle




7.1.9.3 Avaliação do método ADHDP-DLQR-IA

Para avaliar a eficiência do ajuste do controlador pelo método ADHDP-DLQR-IA, o desempenho deste foi comparado com os desempenhos dos controladores ajustados pelos seguintes métodos: PID sintonizado pelo segundo método *Ziegler-Nichols*, PID ajustado por regras fuzzy e por controle de modo deslizante (SMC).


O desempenho do comportamento em resposta ao degrau dos controladores foi comparado, onde foi possível observar a evolução dos desempenhos dos métodos analisados. O controlador sintonizado pelo método ADHDP-DLQR-IA, obteve uma convergência mais rápida para o valor de referência, atendendo às especificações do projeto. Note que a carga de referência de 8000 t/h é alcançada mais rapidamente e com pequenas oscilações conforme Figura 96

Figura 96 – Resposta ao degrau - Algoritmo ADHDP-DLQR-AI x PID-Fuzy x PID-ZN x SMC x Modelo de planta.



O desempenho do comportamento em resposta ao impulso dos controladores também é comparado e é observado que o controlador sintonizado pelo método ADHDP-DLQR-IA obteve menor *overshoot*, menor tempo de acomodação e menor erro estacionário.

Figura 97 – Resposta ao impulso - Algoritmo ADHDP-DLQR-AI x PID-Fuzzy x SMC x Modelo de planta.



7.1.10 Considerações Gerais

Considerações finais deste capítulo, de acordo com os resultados em experimentos simulados do sistema de controle DLQR baseado em PDHDA com ação integral, comparados aos resultados práticos do sistema de controle com o controlador PI implementado no processo de controle de retomada de minério, e observando que ambas as matrizes $\tilde{H}_{\infty}^{ADHDP}$ e $\tilde{H}_{Schur}$, quanto os ganhos $\tilde{K}_{\infty}^{ADHDP}$ e $\tilde{K}_{Schur}$ são iguais, garante a convergência de todos os parâmetros da planta em estudo. Dessa forma, foi assegurado que o desempenho alcançado pelos resultados simulados do sistema de controle proposto garante que o sistema seja viável para ser implementado no controle do processo industrial.

Tendo em vista a complexidade de identificar modelos de plantas reais, o método ADHDP-DLQR-IA pode ser uma alternativa para muitos problemas, já que não depende de modelos, e sim de sinais de entrada e estado que podem ser medidos com a instalação de sensores para capturar esses sinais. Portanto, conclui-se que um sistema de controle com controlador PI com os ganhos K_P e K_I constantes funciona bem apenas para a dinâmica da planta em que esses parâmetros são ajustados, alterando a dinâmica da planta, o sistema de controle não atende mais. Por outro lado, o sistema de controle DLQR baseado em PDHDA com ação integral mostra-se mais eficiente, pois os parâmetros de ganho são ajustados automaticamente de acordo com a dinâmica atualizada da planta em tempo real e os resultados são ótimos.

A comparação do controlador ADHDP-DLQR-IA com o controlador PID ajustado por regras fuzzy é mais justa, já que os dois não dependem do modelo da planta, mas a comparação foi estendida para o controlador PID convencional, sintonizado pelo segundo método *Ziegler-*

Niehols. e o controlador de modo deslizante, sintonizado por uma RBF. Após comparar os resultados dos controladores avaliados, conclui-se que o controlador ADHDP-DLQR-IA é mais eficiente, tanto para as avaliações paramétricas quanto para as avaliações de controle.

Capítulo 8

CONCLUSÃO

Novos métodos de sintonia de sistemas de controle são propostos nesta tese de doutorado, onde foram apresentados métodos de sintonia *online* e ótimos para ajustes do vetor de ganhos K^{pid} de controladores PID com base em IC para sistemas MBC e sistemas DDC. Em primeira instância, desenvolveu-se um modelo de sintonia de controladores PID, sendo o vetor de ganhos K^{pid} determinado *offline* por uma RNA-E e ajustados *online* por regras *fuzzy*, em segunda instância foi desenvolvido um método para ajuste *online* e ótimo de controladores PID, tendo o vetor de ganhos K^{pid} determinado e ajustado *online* por uma RNA-E. Também, foi concebido um método de sintonia de controladores com ação integral independente de modelos matemáticos, avaliado e simulado com dados reais de uma planta industrial do processo operacional de uma RP de caçambas. Onde foi observada a eficiência do desempenho do sistema de controle com base em PDHDA de acordo com os sinais medidos por sensores. Diante dos resultados apresentados, chegou-se as seguintes conclusões:

- Sintonia de controladores PID dependente de modelos matemáticos representados por FTs com o vetor de ganhos K^{pid} determinado por uma RNA-E e ajustado *online* por regras *fuzzy*, como também, com o vetor de ganhos K^{pid} determinado e ajustado *online* por uma RNA-E, apresentaram bons desempenhos, tanto para a avaliação de resultados de controle como para rejeição às variações paramétricas nas dinâmicas das plantas avaliadas;
- Sintonia de controladores PID independente de modelo (*model free*) matemático da planta com base em PDHDA com ação integral tendo os sinais de entradas/saídas medidos por sensores, também alcançou bom desempenho atendendo as especificações de projetos. Portanto, conclui-se que os métodos apresentados nesta tese de doutorado conseguiram desempenhos satisfatórios e são factíveis de serem implementados em CLPs industriais. Pois os CLP mais novos já têm embutidos em sua estrutura módulos de programação PID, módulo de programação em *fuzzy* e blocos de funções que podem ser usados para implementações de modelos matemáticos mais complexos.

8.1 Produção Científica

Nesta Secção apresenta-se os trabalhos desenvolvidos relacionados com o tema da tese.

- Trabalhos publicados em periódicos:

1. Online Discrete-Time LQR Controller Design with Integral Action for Bulk Bucket Wheel Reclaimer Operational Processes via Action-Dependent Heuristic Dynamic Programming - ISA Transactions. ISATRA3058. ISSN 0019-0578, **(Qualis A1)**;
2. Models for Optimal Online Tuning Based on Computational Intelligence of PID Controllers Applied in Operational Processes of Bulk Reclaimers, (2018) - Journal of Control, Automation and Electrical Systems. Springer. DOI: 10.1007/s40313-018-00438-7. ISSN 2195-3899, **(Qualis B1)**;
3. Event Discrete Control Strategy Design of Overhead Crane Embedded In Programmable Logic Controller - American journal of Engineering Research - (AJER 2017), **(Qualis B5)**;
4. Dynamic System Model Identification And Estimation for the Control of Solid Flow Applied To Car Dumpers - International Journal of Modern Engineering Research (IJMER 2017), **(Qualis C)**;
5. PID Controller Embedded in Industrial PLC Applied to Level Control in Tanks - International Journal Of Modern Engineering Research - (IJMER 2016), **(Qualis C)**;
6. Fuzzy Controller Embedded in PLC for Multivariable Systems Using a Discrete Event System Approach - International Journal of Advanced Research in Computer Science and Software Engineering - (IJARCSSE 2016), **(Qualis C)**.

- Trabalhos Submetidos em periódicos:

1. On the Design and Analysis of Structured-ANN for Online PID-Tuning to Bulk Resumption Process in Ore Mining System (Essevier - NEUROCOMPUTING, 0925-2312, **(Qualis A1)**)
2. A Neuro-Fuzzy Model for Online Optimal Tuning of PID Controllers in Industrial Systems Applications to the Mining Sector (IEEE - TRANSACTIONS ON FUZZY SYSTEMS – 1063-6706 , **(Qualis A1)** (Este foi aceito e publicado depois da defesa da tese);

- Trabalhos publicados em conferências:

1. Controlador PID para o Controle de Vazão de Sólidos em Sistemas Industriais com Aplicação em Viradores de Vagões - (CBA 2018);

2. Sintonia online de Controladores PID Sintonizado por Regras Fuzzy em Sistemas Industriais com Aplicação em Processo Operacional de Viradores de Vagões - (CBA 2018);
 3. Modelo de um Controle de Nível de Sólidos em Silos Usando Sistemas Fuzzy Aplicados em PLC Industrial - Congresso Brasileiro de Automática - (CBA 2016);
 4. Fuzzy Controller in the Cargo Control Wagons Dump - The 2016 IEEE Conference on Evolving and Adaptive Intelligent Systems - (IEEE EAIS 2016)
 5. Lógica Fuzzy no Controle de Embarque de Navios no Terminal Marítimo de Ponta da Madeira - XI Simósio Brasileiro de Automação Inteligente - (SBAI 2013).
 6. Control of Productivity in Car Dumpers Using Fuzzy Logic - 10th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD 2013).
- Trabalhos em Andamentos:
 1. Neuro Controller Model for Optimal Online Tuning of PID Controllers In High Order System.

8.2 Trabalhos Futuros

A proposta para trabalhos futuros, consiste em dar continuidade nas pesquisas desenvolvidas e simuladas apresentada nesta Tese, tais como:

- Desenvolver blocos de funções com técnicas de IC e PDA para serem implementados em CLP;
- Desenvolver algoritmos baseado em PDHDA para sistemas dinâmicos aplicados em plantas industriais;
- Desenvolver um algoritmo adaptativo para determinar os parâmetros a_i *online* e ótimos do estimador do sistema de controle.

Referências

NETO, João V Da Fonseca and Abreu, Ivanildo Silva and Rêgo, Patrícia Helena Moraes and de Melo, Marlon Paulo. [S.l.: s.n.]. Citado na página [44](#).

ABRAMOWITZ, M.; STEGUN, I. A. et al. **Handbook of mathematical functions with formulas, graphs, and mathematical tables**. [S.l.]: Dover, New York, 1972. v. 9. Citado na página [31](#).

AKAZAWA, M. Quantum hopfield network using single-electron circuits. In: **Extended abstracts of the... Conference on Solid State Devices and Materials**. [S.l.: s.n.], 1997. v. 1997, p. 306–307. Citado na página [30](#).

ANDREWS, R.; DIEDERICH, J.; TICKLE, A. B. Survey and critique of techniques for extracting rules from trained artificial neural networks. **Knowledge-based systems**, Elsevier, v. 8, n. 6, p. 373–389, 1995. Citado na página [30](#).

ARNOLD, W. F.; LAUB, A. J. Generalized eigenproblem algorithms and software for algebraic riccati equations. **Proceedings of the IEEE**, IEEE, v. 72, n. 12, p. 1746–1754, 1984. Citado na página [24](#).

ASSAREH, E.; BIGLARI, M. A novel approach to capture the maximum power from variable speed wind turbines using pi controller, rbf neural network and gsa evolutionary algorithm. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 51, p. 1023–1037, 2015. Citado na página [43](#).

ÅSTRÖM, K. J.; GOODWIN, G. C.; KUMAR, P. R. **Adaptive control, filtering, and signal processing**. [S.l.]: Springer Science & Business Media, 2012. v. 74. Citado na página [62](#).

ÅSTRÖM, K. J.; HÄGGLUND, T. New tuning methods for pid controllers. In: **Proceedings of the 3rd European control conference**. [S.l.: s.n.], 1995. p. 2456–62. Citado 4 vezes nas páginas [2](#), [7](#), [21](#) e [22](#).

ÅSTRÖM, K. J.; HÄGGLUND, T. The future of pid control. **Control engineering practice**, Elsevier, v. 9, n. 11, p. 1163–1175, 2001. Citado na página [44](#).

ÅSTRÖM, K. J.; HÄGGLUND, T. **Advanced PID control**. [S.l.]: ISA-The Instrumentation, Systems and Automation Society, 2005. Citado na página [43](#).

ÅSTRÖM, K. J.; HÄGGLUND, T.; ÅSTRÖM, K. J. **Advanced PID control**. [S.l.]: ISA-The Instrumentation, Systems, and Automation Society Research Triangle ..., 2006. v. 461. Citado 2 vezes nas páginas [2](#) e [62](#).

- ÅSTRÖM, K. J.; WITTENMARK, B. On self tuning regulators. **Automatica**, Elsevier, v. 9, n. 2, p. 185–199, 1973. Citado na página 7.
- ÅSTRÖM, K. J.; WITTENMARK, B. **Computer-controlled systems: theory and design**. [S.l.]: Courier Corporation, 2013. Citado na página 62.
- BÄCK, T.; FOGEL, D. B.; MICHALEWICZ, Z. **Evolutionary computation 1: Basic algorithms and operators**. [S.l.]: CRC press, 2018. Citado na página 33.
- BAI, Q. Analysis of particle swarm optimization algorithm. **Computer and information science**, v. 3, n. 1, p. 180, 2010. Citado na página 44.
- BANKER, R. D.; BARDHAN, I. R.; CHANG, H.; LIN, S. Plant information systems, manufacturing capabilities, and plant performance. **MIS quarterly**, JSTOR, p. 315–337, 2006. Citado na página 43.
- BECKER, A.; SCHNEIDER, A.; ERCICO, J.; WERLANG, R. Os conceitos da indústria 4.0 associados a abordagem da capacidade dinâmica. **Anais da Engenharia de Produção/ISSN 2594-4657**, v. 2, n. 1, p. 123–136, 2018. Citado na página 62.
- BEHRMAN, E. C.; NIEMEL, J.; STECK, J. E.; SKINNER, S. R. A quantum dot neural network. In: CITESEER. **Proceedings of the 4th Workshop on Physics of Computation**. [S.l.], 1996. p. 22–24. Citado na página 30.
- BELLMAN, R. **The theory of dynamic programming**. [S.l.], 1954. Citado na página 25.
- BELLMAN, R.; DREYFUS, S. Functional approximations and dynamic programming. **Mathematical Tables and Other Aids to Computation**, JSTOR, p. 247–251, 1959. Citado na página 4.
- BJÖRCK, Å. **Numerical methods in matrix computations**. [S.l.]: Springer, 2015. Citado na página 117.
- BRADTKE, S. J. **Incremental dynamic programming for on-line adaptive optimal control**. Tese (Doutorado) — Citeseer, 1994. Citado na página 4.
- BREWER, J. Kronecker products and matrix calculus in system theory. **IEEE Transactions on circuits and systems**, IEEE, v. 25, n. 9, p. 772–781, 1978. Citado na página 117.
- BRYSON, J. A. e and y.-c. ho. **Applied Optimal Control: Optimization, Estimation and Control**, 1975. Citado na página 123.
- BUSONI, L.; BABUSKA, R.; SCHUTTER, B. D.; ERNST, D. **Reinforcement learning and dynamic programming using function approximators**. [S.l.]: CRC press, 2010. Citado na página 26.
- CHEN, C.-W.; CHIANG, W.-L.; TSAI, C.-H.; CHEN, C.-Y.; WANG, M. H. Fuzzy lyapunov method for stability conditions of nonlinear systems. **International Journal on Artificial Intelligence Tools**, World Scientific, v. 15, n. 02, p. 163–171, 2006. Citado na página 35.
- CHOPRA, V.; SINGLA, S. K.; DEWAN, L. Comparative analysis of tuning a pid controller using intelligent methods. **ACTA Polytechnica hungarica**, v. 11, n. 8, p. 235–249, 2014. Citado na página 43.

CLARKE, D.; GAWTHROP, P. Self-tuning control. In: IET. **Proceedings of the Institution of Electrical Engineers**. [S.l.], 1979. v. 126, n. 6, p. 633–640. Citado na página 7.

DAX, A. The convergence of linear stationary iterative processes for solving singular unstructured systems of linear equations. **SIAM review**, SIAM, v. 32, n. 4, p. 611–635, 1990. Citado na página 72.

FACCIN, F. Abordagem inovadora no projeto de controladores pid. 2004. Citado 2 vezes nas páginas 5 e 6.

FADALI, M. S.; VISIOLI, A. **Digital control engineering: analysis and design**. [S.l.]: Academic Press, 2012. Citado na página 63.

FERREIRA, E. F.; RÊGO, P. H.; NETO, J. V. Numerical stability improvements of state-value function approximations based on rls learning for online hdp-dlqr control system design. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 63, p. 1–19, 2017. Citado na página 118.

FILATOV, N. M.; KEUCHEL, U.; UNBEHAUEN, H. Dual control for an unstable mechanical plant. **Control Systems, IEEE**, IEEE, v. 16, n. 4, p. 31–37, 1996. Citado na página 22.

FREDERIK, J.; KRÖGER, L.; GÜLKER, G.; WINGERDEN, J.-W. van. Data-driven repetitive control: Wind tunnel experiments under turbulent conditions. **Control Engineering Practice**, Elsevier, v. 80, p. 105–115, 2018. Citado na página 1.

GAIDHANE, P. J.; NIGAM, M. J.; KUMAR, A.; PRADHAN, P. Design of interval type-2 fuzzy precompensated pid controller applied to two-dof robotic manipulator with variable payload. **ISA transactions**, Elsevier, 2018. Citado na página 2.

GARPINGER, O. **Analysis and Design of Software-Based Optimal PID Controllers**. [S.l.]: Department of Automatic Control, Lund Institute of Technology, Lund University, 2015. Citado na página 43.

GARPINGER, O.; HÄGGLUND, T.; ÅSTRÖM, K. J. Performance and robustness trade-offs in pid control. **Journal of Process Control**, Elsevier, v. 24, n. 5, p. 568–577, 2014. Citado na página 43.

GOLNARAGHI, B. C. K. F. **Automatic Control Systems**. 9th. ed. [S.l.]: Wiley, 2009. ISBN 0470048964,9780470048962. Citado na página 43.

GOLUB, G. H.; LOAN, C. F. V. **Matrix computations**. [S.l.]: JHU Press, 2012. v. 3. Citado na página 31.

HAM, F. M.; KOSTANIC, I. **Principles of neurocomputing for science and engineering**. [S.l.]: McGraw-Hill Higher Education, 2000. Citado 2 vezes nas páginas 63 e 64.

HAMPEL, F. R.; RONCHETTI, E. M.; ROUSSEUW, P. J.; STAHEL, W. A. **Robust statistics: the approach based on influence functions**. [S.l.]: John Wiley & Sons, 2011. v. 114. Citado na página 31.

HAYKIN, S. **Neural networks: a comprehensive foundation**. [S.l.]: Prentice Hall PTR, 1994. Citado 2 vezes nas páginas 30 e 62.

- HE, S.; SONG, J.; DING, Z.; LIU, F. Online adaptive optimal control for continuous-time markov jump linear systems using a novel policy iteration algorithm. **IET Control Theory & Applications**, IET, v. 9, n. 10, p. 1536–1543, 2015. Citado na página 117.
- HIGHAM, N. J. **Accuracy and stability of numerical algorithms**. [S.l.]: Siam, 2002. v. 80. Citado na página 72.
- HUBER, P. J. **Robust statistics**. 1981. [S.l.]: Wiley, New York. Citado na página 31.
- HUBER, P. J. **Robust statistical procedures**. [S.l.]: SIAM, 1996. Citado na página 31.
- JAMMES, F.; SMIT, H. Service-oriented paradigms in industrial automation. **IEEE Transactions on Industrial Informatics**, IEEE, v. 1, n. 1, p. 62–70, 2005. Citado na página 2.
- JANG, J.-S. R.; SUN, C.-T.; MIZUTANI, E. Neuro-fuzzy and soft computing-a computational approach to learning and machine intelligence [book review]. **Automatic Control, IEEE Transactions on**, IEEE, v. 42, n. 10, p. 1482–1484, 1997. Citado na página 33.
- JING, X.; CHENG, L. An optimal pid control algorithm for training feedforward neural networks. **IEEE Transactions on Industrial Electronics**, v. 60, n. 6, p. 2273–2283, June 2013. ISSN 0278-0046. Citado na página 62.
- KALAIARASSAN, G.; SOMANADH, M.; THIRUMALAI, C.; KUMAR, M. S. et al. One-dimension force balance system for hypersonic vehicle an experimental and fuzzy prediction approach. **Materials Today: Proceedings**, Elsevier, v. 5, n. 5, p. 13547–13555, 2018. Citado na página 35.
- KALMAN, R. E. Design of self-optimizing control system. **Trans. ASME**, v. 80, p. 468–478, 1958. Citado na página 7.
- KECHRIS, A. S.; KECHRIS, A. S. **Classical descriptive set theory**. [S.l.]: Springer-Verlag New York, 1995. v. 156. Citado na página 33.
- KOPETZ, H. **Real-time systems: design principles for distributed embedded applications**. [S.l.]: Springer Science & Business Media, 2011. Citado na página 63.
- KUC, T.-Y.; HAN, W.-G. An adaptive pid learning control of robot manipulators. **Automatica**, Elsevier, v. 36, n. 5, p. 717–725, 2000. Citado 2 vezes nas páginas 7 e 21.
- LANDELIUS, T. Reinforcement learning and distributed local model synthesis. Linköping University Electronic Press, 1997. Citado na página 115.
- LASI, H.; FETTKE, P.; KEMPER, H.-G.; FELD, T.; HOFFMANN, M. Industry 4.0. **Business & Information Systems Engineering**, Springer, v. 6, n. 4, p. 239–242, 2014. Citado 3 vezes nas páginas 2, 62 e 63.
- LEE, J.; KAO, H.-A.; YANG, S. Service innovation and smart analytics for industry 4.0 and big data environment. **Procedia Cirp**, Elsevier, v. 16, p. 3–8, 2014. Citado 2 vezes nas páginas 62 e 63.
- LEWIS, F. L.; LIU, D. **Reinforcement learning and approximate dynamic programming for feedback control**. [S.l.]: John Wiley & Sons, 2013. v. 17. Citado 2 vezes nas páginas 25 e 115.

- LEWIS, F. L.; SYRMOS, V. L. **Optimal control**. [S.l.]: John Wiley & Sons, 1995. Citado na página 22.
- LI, L. China's manufacturing locus in 2025: With a comparison of "made-in-china 2025" and "industry 4.0". **Technological Forecasting and Social Change**, Elsevier, v. 135, p. 66–74, 2018. Citado na página 2.
- LJUNG, L.; SÖDERSTRÖM, T. **Theory and practice of recursive identification**. [S.l.]: JS-TOR, 1983. v. 5. Citado na página 23.
- LOAN, C. F. V.; PITSIANIS, N. Approximation with kronecker products. In: **Linear algebra for large scale and real-time applications**. [S.l.]: Springer, 1993. p. 293–314. Citado na página 117.
- LOPES, B. E.; MOURA, J. P. de; RIBEIRO, D. A.; BORGES, F. H. C. e; SOUZA, M. A. de. Flow optimization for iron ore reclaiming process. In: **ICINCO (1)**. [S.l.: s.n.], 2012. p. 425–432. Citado 3 vezes nas páginas 16, 50 e 110.
- LORENZINI, C.; BAZANELLA, A. S.; PEREIRA, L. F. A.; SILVA, G. R. G. da. The generalized forced oscillation method for tuning pid controllers. **ISA transactions**, Elsevier, 2018. Citado na página 2.
- MAREN, A. J.; HARSTON, C. T.; PAP, R. M. **Handbook of neural computing applications**. [S.l.]: Academic Press, 2014. Citado na página 2.
- MARLER, R. T.; ARORA, J. S. Survey of multi-objective optimization methods for engineering. **Structural and multidisciplinary optimization**, Springer, v. 26, n. 6, p. 369–395, 2004. Citado na página 4.
- MARTINS, G. M. Princípios de automação industrial. **Universidade Federal de Santa Maria, Santa Maria-RS**, 2007. Citado na página 20.
- MARWEDEL, P. **Embedded System Design: Embedded Systems Foundations of Cyber-Physical Systems, and the Internet of Things**. [S.l.]: Springer, 2017. Citado na página 63.
- MOOD, A.; GRAYBILL, F.; BOES, D. **Introduction to the theory of statistics. 3rd mcgraw-hill**. [S.l.]: Singapore, 1974. Citado na página 31.
- MOURA, J. P.; SERRA, G. L. de O.; FONSECA, J. V. Fuzzy logic in the control of shipping of ships in the maritime terminal of tip of the wood. **Brazilian Symposium on Intelligent Automation, 2013**. Citado 2 vezes nas páginas 16 e 110.
- MOURA, J. P. de; NETO, J. V. da F.; RÊGO, P. H. M. Models for Optimal Online Tuning Based on Computational Intelligence of PID Controllers Applied to Operational Processes of Bulk Reclaimers. **Journal of Control, Automation and Electrical Systems**, Jan 2019a. ISSN 2195-3899. Disponível em: <<https://doi.org/10.1007/s40313-018-00438-7>>. Citado 12 vezes nas páginas 1, 3, 7, 37, 40, 42, 43, 44, 47, 48, 49 e 50.
- MOURA, J. P. de; PINHEIRO, B. L. Dynamic system model identification and estimation for the control of solid flow applied to car dumpers. *international journal of modern engineering research (ijmer)*, 2017. Citado na página 50.

MOURA, J. P. de; REGO, P. H. M.; NETO, J. V. da F. Online discrete-time lqr controller design with integral action for bulk bucket wheel reclaimer operational processes via action-dependent heuristic dynamic programming. **ISA Transactions**, 2019b. ISSN 0019-0578. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0019057819300096>>. Citado 7 vezes nas páginas 2, 3, 4, 7, 37, 40 e 43.

NETO, J. V. D. F.; ABREU, I. S.; RÊGO, P. H. M.; MELO, M. P. de. Modelos e convergência de um algoritmo genético para alocação de auto-estrutura via rlq. Citado na página 123.

NETO, J. V. d.-F.; LOPES, L. R. On the convergence of dlqr control system design and recurrences of riccati and lyapunov in dynamic programming strategies. 2011. Citado na página 2.

NETO, J. V. da F.; ABREU, I. S.; SILVA, F. N. D. Neural-genetic synthesis for state-space controllers based on linear quadratic regulator design for eigenstructure assignment. **Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on**, IEEE, v. 40, n. 2, p. 266–285, 2010. Citado na página 123.

NETO, J. V. da F.; FERREIRA, E. F.; REGO, P. H. M. Online optimal dlqr-dfig control system design via recursive least-square approach and state heuristic dynamic programming for approximate solution of the hjb equation. p. 3174–3179, 2013. Citado na página 2.

NETO, J. V. F.; RÊGO, P. H. M. Qr-tuning and approximate-ls solutions of the hjb equation for online dlqr design via state and action-dependent heuristic dynamic programming. **International Journal of Innovative Computing, Information and Control**, v. 10. Citado na página 115.

NGUYEN, H. T.; WALKER, C. L.; WALKER, E. A. **A first course in fuzzy logic**. [S.l.]: CRC press, 2018. Citado na página 35.

NI, Z.; HE, H.; ZHAO, D.; XU, X.; PROKHOROV, D. V. Grdhp: A general utility function representation for dual heuristic dynamic programming. **IEEE transactions on neural networks and learning systems**, IEEE, v. 26, n. 3, p. 614–627, 2015. Citado na página 115.

O'DWYER, A. **Handbook Of Pi And Pid Controller Tuning Rules**. 3. ed. [S.l.]: Imperial College Press, 2009. ISBN 1848162421,9781848162426. Citado na página 63.

OGATA, K. Modern control engineering 5th edition. lugar: Upper saddle river, new jersey 07458. ed: **Prentice Hall**, p. 55, 2009. Citado na página 119.

OVERSCHEE, B. D. M. a. P. V. **Subspace Identification for Linear Systems: Theory - Implementation - Applications**. 1. ed. [S.l.]: Springer US, 1996. ISBN 978-1-4613-8061-0,978-1-4613-0465-4. Citado na página 37.

OVERSCHEE, P. V.; MOOR, B. D. **Subspace identification for linear systems: Theory—Implementation—Applications**. [S.l.]: Springer Science & Business Media, 2012. Citado na página 37.

PEDRO, J.; DAHUNSI, O. Neural network based feedback linearization control of a servo-hydraulic vehicle suspension system. **International Journal of Applied Mathematics and Computer Science**, Versita, v. 21, n. 1, p. 137–147, 2011. Citado na página 35.

PEDRYCZ, W.; GOMIDE, F. **Fuzzy systems engineering: toward humancentric computing**. [S.l.]: Wiley, 2007. Citado na página 34.

- PEPPER, I. A.; CAGNEY, A.; PRYLOWSKI, A. **Plant information management system**. [S.l.]: Google Patents, 2006. US Patent 7,155,450. Citado na página [43](#).
- REGO, P. H. M. **Tese de doutorado: Aprendizagem por reforço e programação dinâmica aproximada para controle ótimo: uma abordagem para o projeto online do regulador linear**. Orientador: João Viana da Fonseca Neto. [S.l.]: UFMA, MA, 2014. Citado na página [3](#).
- SERRA, G. L. O. **Frontiers in Advanced Control Systems**. [S.l.]: InTech, 2012. Citado na página [34](#).
- SILVA, C. W. D. **Intelligent control: fuzzy logic applications**. [S.l.]: CRC press, 2018. Citado na página [33](#).
- SILVA, M. E. G. et al. Algoritmos da família lms para a solução aproximada da hjb em projetos online de controle ótimo discreto multivariável e aprendizado por reforço. Universidade Federal do Maranhão, 2014. Citado 2 vezes nas páginas [25](#) e [26](#).
- SUTTON, R. S.; BARTO, A. G. **Introduction to reinforcement learning**. [S.l.]: MIT press Cambridge, 1998. v. 135. Citado 2 vezes nas páginas [25](#) e [26](#).
- TAO, Y.; ZHENG, J.; LIN, Y.; WANG, T.; XIONG, H.; HE, G.; XU, D. Fuzzy pid control method of deburring industrial robots. **Journal of Intelligent & Fuzzy Systems**, IOS Press, v. 29, n. 6, p. 2447–2455, 2015. Citado na página [90](#).
- VENTURA, D.; MARTINEZ, T. An artificial neuron with quantum mechanical properties. In: SPRINGER. **Artificial Neural Nets and Genetic Algorithms**. [S.l.], 1998. p. 482–485. Citado na página [30](#).
- VENTURA, D.; MARTINEZ, T. Quantum associative memory. **Information Sciences**, Elsevier, v. 124, n. 1-4, p. 273–296, 2000. Citado na página [30](#).
- WANG, F.-Y.; ZHANG, H.; LIU, D. Adaptive dynamic programming: an introduction. **IEEE Computational Intelligence Magazine**, IEEE, v. 4, n. 2, p. 39–47, 2009. Citado na página [2](#).
- WANG, L.-X. **Adaptive fuzzy systems and control: design and stability analysis**. [S.l.]: Prentice-Hall, Inc., 1994. Citado na página [35](#).
- WANG, L.-X. **A Course in Fuzzy Systems**. [S.l.]: Prentice-Hall press, USA, 1999. Citado na página [35](#).
- WEI, Y.; QIU, J.; KARIMI, H. R. Fuzzy-affine-model-based memory filter design of nonlinear systems with time-varying delay. **IEEE Transactions on Fuzzy Systems**, IEEE, v. 26, n. 2, p. 504–517, 2018. Citado na página [33](#).
- WIERING, M.; OTTERLO, M. V. Reinforcement learning. **Adaptation, learning, and optimization**, Springer, v. 12, p. 51, 2012. Citado na página [25](#).
- WILLIAMS, R.; LUKE, S.; OSTROWSKI, K.; BENNETT, M. Measurement of bulk particulates on belt conveyor using dielectric tomography. **Chemical Engineering Journal**, Elsevier, v. 77, n. 1, p. 57–63, 2000. Citado 2 vezes nas páginas [16](#) e [110](#).
- XU, L. D.; XU, E. L.; LI, L. Industry 4.0: state of the art and future trends. **International Journal of Production Research**, Taylor & Francis, v. 56, n. 8, p. 2941–2962, 2018. Citado na página [2](#).

YOU, K.; WEI, L.; JIANG, K. A fuzzy logic urea dosage controller design for two-cell selective catalytic reduction systems. **ISA transactions**, Elsevier, v. 78, p. 21–30, 2018. Citado na página [1](#).

ZADEH, L. A. Fuzzy sets. In: **Fuzzy Sets, Fuzzy Logic, And Fuzzy Systems: Selected Papers by Lotfi A Zadeh**. [S.l.]: World Scientific, 1996. p. 394–432. Citado na página [34](#).

ZHANG, H.; LIU, D.; LUO, Y.; WANG, D. **Adaptive dynamic programming for control: algorithms and stability**. [S.l.]: Springer Science & Business Media, 2012. Citado na página [115](#).

ZHOU, K.; DOYLE, J. C.; GLOVER, K. et al. **Robust and optimal control**. [S.l.]: Prentice hall New Jersey, 1996. v. 40. Citado na página [22](#).

ZIEGLER, J.; NICHOLS, N. Process lags in automatic control circuits. **Trans. ASME**, v. 65, n. 5, p. 433–443, 1943. Citado 2 vezes nas páginas [2](#) e [21](#).

ZIEGLER, J. G.; NICHOLS, N. B. Optimum settings for automatic controllers. **trans. ASME**, v. 64, n. 11, 1942. Citado 4 vezes nas páginas [2](#), [6](#), [21](#) e [44](#).

ZULU, A. Towards explicit pid control tuning using machine learning. p. 430–433, 2017. Citado na página [44](#).

Apêndice A

Experimentos e Simulações Iniciais

Neste Apêndice, apresenta-se os experimentos e simulações iniciais para a validação da pesquisa desenvolvida nesta tese de doutorado. Os experimentos são iniciados com dados obtidos em tempo real da planta do processo de retomada de granéis por retomadoras, que foram classificados em 4 casos, cada caso com 3 situações possíveis formando-se um sistema com 3 equações oriundas do produto interno $\langle K^{pid}, \bar{b}_i \rangle$.


A.1 Planta Processo de Retomada de Granéis por RP

A planta do processo de retomada de granéis foi utilizada para dar continuidade nos experimentos baseados em dados de plantas industriais coletados durante o processo produtivo.

A.1.1 Diagrama de Blocos do Processo de Retomada de Minério

Os três principais eventos que ocorrem durante o processo operacional da planta são apresentados no diagrama de blocos da Figura 98. A etapa de translação é o primeiro evento a ocorrer e, simultaneamente, ocorrem os eventos de rotação da lança e rotação da RC. Os eventos da velocidade de rotação RC e do tamanho do passo de translação não são controlados, o único evento controlado é a velocidade da rotação da lança na busca de fluxo desejada. O evento do passo translacional varia de 0 a 1 m e ocorre isolado dos outros eventos, isto é, ocorre no início de cada estágio. Uma camada a ser retomada requer vários passos de translação, que são os estágios, estes ocorrem primeiros, e após cada estágio, os eventos da rotação da RC e da rotação da lança ocorrem simultaneamente. A intensidade da corrente elétrica do motor da RC gera uma estimativa de fluxo, que é o fluxo estimado, este é comparado ao fluxo medido pela balança, e a diferença entre o fluxo estimado e o fluxo medido pela balança é o erro. Por sua vez, é tratado para garantir o melhor desempenho do sistema.

Figura 98 – Diagrama de blocos do processo de retomada de minério.



Os eventos discretos são definidos a seguir:

- **Passo de translação** - o passo de translação se refere ao movimento longitudinal da RP sobre o caminho de rolamento, o passo de translação é o ataque direto da RC à pilha de minério;
- **Giro da lança** - o movimento de giro da lança depois da RC ter atacado (penetrado) à pilha é o responsável por manter a carga, isto é, a medida que a lança gira com as caçambas penetradas na pilha a carga é retomada;
- **Corrente da RC** - a RC é constituída de 10 caçambas e gira verticalmente retomando a carga da pilha estocada, no caso de acionamento por motores elétricos, a intensidade da corrente elétrica dos motores do acionamento da RC é usada para estimar o fluxo da carga a ser retomada.

A.1.2 Descrição da Rotina do Processo de Retomada de Minério


O processo de retomada inicia-se da seguinte forma:

- 1) passo - posicionar a RP na pilha;
- 2) passo - ligar os motores da correia da lança;
- 3) passo - ligar os motores da RC;
- 4) passo - definir o *setpoint* (carga desejada);
- 5) passo - avançar (penetrar) na pilha (passo de translação);

- 6) passo - acionar o comando de giro da lança para direita;
- 7) passo - acelerar a velocidade de giro da lanla para a direita até atingir a carga desejada;
- 8) passo - desacelerar a velocidade de giro da lança para a direita até parar;
- 9) passo - acionar o comando de giro da lança para esquerda;
- 10) passo - acelerar a velocidade de giro da lança para a esquerda até atingir a carga desejada;
- 11) passo - desacelerar a velocidade de giro da lança para a esquerda até parar.

Na Figura 99 está ilustrado de forma macro o processo de retomada de minério para uma camada.

Figura 99 – Grafcet em nível descritivo do processo de retomada de minério



A.1.3 Criação das Tabelas de Associação

Definindo os elementos constituintes do sistema. Para tanto, serão criadas s seguintes tabelas:

- Tabela para as receptividades (entradas);
- Tabela para as transições;
- Tabela para as etapas;

- Tabela para as ações (saídas) associadas às etapas.

Para cada elemento de entrada ou saída do processo de retomada de minério, deve ser associada a um endereço físico correspondente no CLP e para cada uma das etapas será atribuído um *bit* de memória auxiliar do CLP. O mesmo deve ser feito para cada uma das transições.

Tabela 21 – Receptividades (entradas).


Nível Comportamental	Nível Tecnológico	Descrição
b_1	I_1	Botão de partida dos motores da translação
b_2	I_2	Botão de partida dos motores da CT
b_3	I_3	Botão de partida dos motores da RC
b_4	I_4	Botão de partida dos motores da translação
s_1	I_5	Sensor de parada direita e esquerda

A FT da planta foi obtida do modelo em espaço de estado apresentado no Capítulo 4 por meio do *software MATLAB* e é representada por

$$FT_{RP}(s) = \frac{200.82s^2 - 20.58s + 56.94}{s^3 + 0.1942s^2 + 1.111s + 0.1275}. \quad (160)$$

Na Figura 100 está ilustrado o comportamento da planta "processo operacional da RP" em resposta ao degrau unitário e em resposta ao impulso.

Figura 100 – Resposta ao degrau unitário x resposta ao impulso do modelo da planta em malha aberta



Os coeficientes $a_1 = 0,1942$, $a_2 = 1,111$; $a_3 = 0,1275$ $b_0 = -200.8$; $b_1 = -20.58$ e $b_2 = 56.94$ do polinômio característico da planta para o processo de retomada de minério são obtidos da FT representada pela Eq. (160).

As FTs são montadas do numerador e do denominador da função de transferência da planta representada na Equação (160). Os numeradores e os denominadores das FTs da planta com os ganhos do controlador PID são obtidos de acordo com os produtos dos vetores a seguir:

$$N_{RP}^{pid} = \begin{bmatrix} 0 & K_P & K_I & K_D \end{bmatrix} \begin{bmatrix} 0 \\ 200.8 \\ 20.58 \\ 56.94 \end{bmatrix}; \quad (161)$$

$$D_{RP}^{pid} = \begin{bmatrix} 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 0.1942 \\ 1.111 \\ 0.1275 \end{bmatrix}. \quad (162)$$

O polinômio característico da planta para o processo de retomada de minério que é dado por

$$\begin{aligned} P_{RP}^{K^{pid}} &= s^4 + (0.1942 \langle K^{pid}, \bar{b}_0 \rangle) s^3 \\ &+ (1.111 + \langle K^{pid}, \bar{b}_1 \rangle) s^2 \\ &+ (0.1275 + \langle K^{pid}, \bar{b}_2 \rangle) s^1 \\ &+ (0 + \langle K^{pid}, \bar{b}_3 \rangle) s^0. \end{aligned} \quad (163)$$

Definindo o vetor $\bar{b}_i$:

$$\begin{aligned} \bar{b}_0 &= \begin{bmatrix} b_0 & b_{-1} & b_{-2} \end{bmatrix}^T = \begin{bmatrix} 200.8 & 0 & 0 \end{bmatrix}^T; \\ \bar{b}_1 &= \begin{bmatrix} b_1 & b_0 & b_{-1} \end{bmatrix}^T = \begin{bmatrix} -20.58 & 200.8 & 0 \end{bmatrix}^T; \\ \bar{b}_2 &= \begin{bmatrix} b_2 & b_1 & b_0 \end{bmatrix}^T = \begin{bmatrix} 56.94 & -20.58 & 200.8 \end{bmatrix}^T; \\ \bar{b}_3 &= \begin{bmatrix} b_3 & b_2 & b_1 \end{bmatrix}^T = \begin{bmatrix} 0 & 56.94 & -20.58 \end{bmatrix}^T. \end{aligned}$$

A.1.4 Cálculos dos Ganhos do Vetor K^{pid}

Os cálculos dos ganhos do vetor K^{pid} são determinados inicialmente pelo produto interno $\langle K^{pid}, \bar{b}_i \rangle$ de acordo com as situações possíveis ilustradas na Tabela 22. Depois dos ganhos do vetor K^{pid} determinados, estes são usados para a montagem das FTs que são usadas nas simulações.

Tabela 22 – Situações Possíveis

Caso 1			Caso 2			Caso 3			Caso 4		
s^0	s^1	s^2	s^1	s^2	s^3	s^0	s^1	s^3	s^0	s^2	s^3
$\neq 0$	$= 0$	$= 0$	$\neq 0$	$= 0$	$= 0$	$\neq 0$	$= 0$	$=$	$\neq 0$	$= 0$	$= 0$
$= 0$	$\neq 0$	$= 0$	$= 0$	$\neq 0$	$= 0$	$= 0$	$\neq 0$	$=$	$= 0$	$\neq 0$	$= 0$
$= 0$	$= 0$	$\neq 0$	$= 0$	$= 0$	$\neq 0$	$= 0$	$= 0$	$\neq 0$	$= 0$	$= 0$	$\neq 0$

A.1.4.1 Caso 1 ($s^0 + s^1 + s^2$)

Montagem da FT com o controlador PID a partir do caso 1 apresentado na Tabela 22.

Tabela 23 – Situação 1 do caso 1

$\langle K^{pid}, \bar{b}_3 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 0 \\ 56.94 \\ -20.58 \end{bmatrix} =$	$56.94K_P - 20.58K_I$	$= 1$
$\langle K^{pid}, \bar{b}_2 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.94 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$56.94K_D - 20.58K_P + 200.8K_I$	$= 0$
$\langle K^{pid}, \bar{b}_1 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} -20.58 \\ 200.8 \\ 0 \end{bmatrix} =$	$-20.58K_D + 200.8K_P$	$= 0$

Da tabela 23, tem-se o sistema de equações

$$K^{pid} = \begin{cases} 56.94K_P - 20.58K_I + 0K_D = 1 \\ -20.58K_P + 200.8K_I + 56.94K_D = 0 \\ 200.8K_P + 0K_I - 20.58K_D = 0 \end{cases} \quad (164)$$

Resolvendo o sistema de equações representado pela Eq. (164) encontra-se os valores dos ganhos $K_P = 0.239$, $K_I = 0.6367$ e $K_D = 2.3311$. Substituindo-se os valores dos ganhos de K^{pid} no polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^1 = \frac{47.98s^4 + 122.9s^3 + 468.5s^2 - 11.73s + 132.7}{47.98s^4 + 123.1s^3 + 469.6s^2 - 11.6s + 132.7}. \quad (165)$$

Tabela 24 – Situação 2 do caso 1

$\langle K^{pid}, \bar{b}_3 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 0 \\ 56.94 \\ -20.58 \end{bmatrix} =$	$56.94K_P - 20.58K_I$	$= 0$
$\langle K^{pid}, \bar{b}_2 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.94 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$56.94K_D - 20.58K_P + 200.8K_I$	$= 1$
$\langle K^{pid}, \bar{b}_1 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} -20.58 \\ 200.8 \\ 0 \end{bmatrix} =$	$-20.58K_D + 200.8K_P$	$= 0$

Da tabela 24, tem-se o sistema de equações

$$K^{pid} = \begin{cases} 56.94K_P - 20.58K_I + 0K_D = 0 \\ -20.58K_P + 200.8K_I + 56.94K_D = 1 \\ 200.8K_P + 0K_I - 20.58K_D = 0 \end{cases} \quad (166)$$

Resolvendo o sistema de equações representado pela Eq. (166) encontra-se os valores dos ganhos $K_P = 9.1726 \times 10^{-4}$, $K_I = 0.025$ e $K_D = 0.008$. Substituindo-se os valores dos ganhos de K^{pid} no polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^2 = \frac{0.1841s^4 + s^3 + 1.144s^2 + 1.259s + 0.4555}{1.184s^4 + 5.194s^3 + 2.255s^2 + 1.386s + 0.4555}. \quad (167)$$

Tabela 25 – Situação 3 do caso 1

$\langle K^{pid}, \bar{b}_3 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 0 \\ 56.94 \\ -20.58 \end{bmatrix} =$	$56.94K_P - 20.58K_I$	$= 0$
$\langle K^{pid}, \bar{b}_2 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.94 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$56.94K_D - 20.58K_P + 200.8K_I$	$= 0$
$\langle K^{pid}, \bar{b}_1 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} -20.58 \\ 200.8 \\ 0 \end{bmatrix} =$	$-20.58K_D + 200.8K_P$	$= 1$

Da tabela 25, tem-se o sistema de equações

$$K^{pid} = \begin{cases} 56.94K_P - 20.58K_I + 0K_D = 0 \\ -20.58K_P + 200.8K_I + 56.94K_D = 0 \\ 200.8K_P + 0K_I - 20.58K_D = 1 \end{cases} \quad (168)$$

Resolvendo o sistema de equações representado pela Eq. (168) encontra-se os valores do ganhos $K_P = 0.0035$, $K_I = 0.0097$ e $K_D = 1.6797 \times 10^{-4}$. Substituindo-se os valores dos ganhos de K^{pid} no polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^3 = \frac{0.1841s^4 + s^3 + 1.144s^2 + 1.259s + 0.4555}{1.184s^4 + 5.194s^3 + 2.255s^2 + 1.386s + 0.4555}. \quad (169)$$

Na Figura 101 está ilustrada o comportamento da curva da resposta ao degrau unitário da FT da Eq. (160) da planta em malha aberta representada pela curva vermelha na e as respostas ao degrau unitário das FTs das Eq. (165), Eq. (167) e Eq. (169) em malha fechada para o caso 1 da Tabela 22 representadas pelas curvas em azul.





Figura 101 – Resposta ao degrau unitário das FTs representadas pelas Eq. (160) x Eqs. (165, 167 e 169).

Na Figura 102 está ilustrada o comportamento da curva da resposta ao impulso da FT da Eq. (160) da planta em malha aberta representada pela curva vermelha e as respostas ao impulso das FTs das Eqs. (165), Eq. (167) e Eq. (169) em malha fechada para o caso 1 da Tabela 22 representadas pelas curvas em azul.

Figura 102 – Resposta ao impulso das FTs representadas pelas Eqs. (160) x Eqs. (165, 167 e 169).



A.1.4.2 Caso 2 ($s^1 + s^2 + s^3$)

Montagem da FT com o controlador PID a partir do caso 2 apresentado na Tabela 22.

Tabela 26 – Situação 1 do caso 2

$\langle K^{pid}, \bar{b}_2 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.94 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$56.94K_D - 20.58K_P + 200.8K_I = 1$
$\langle K^{pid}, \bar{b}_1 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} -20.58 \\ 200.88 \\ 0 \end{bmatrix} =$	$-20.58K_D + 200.8K_I = 0$
$\langle K^{pid}, \bar{b}_0 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 200.8 \\ 0 \\ 0 \end{bmatrix} =$	$200.8K_P = 0$

Da tabela 26, tem-se o sistema de equações

$$K^{pid} = \begin{cases} -20.58K_P + 200.8K_I + 56.94K_D = 1 \\ 200.8K_P + 0K_I - 20.58K_D = 0 \\ 0K_P + 0K_I + 200.8K_D = 0 \end{cases} \quad (170)$$

Resolvendo o sistema de equações representado pela Eq. (172) encontra-se os valores dos ganhos $K_P = 0$, $K_I = 0.005$ e $K_D = 0$. Substituindo-se os valores dos ganhos de K^{pid} no

polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^4 = \frac{s^3 - 0.10s^2 + 0.28}{s^4 + 1.20s^3 + s^2 + 0.41s}. \quad (171)$$

Tabela 27 – Situação 2 do caso 2

$\langle K^{pid}, \bar{b}_2 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.94 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$56.94K_D - 20.58K_P + 200.8K_I = 0$
$\langle K^{pid}, \bar{b}_1 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} -20.58 \\ 200.88 \\ 0 \end{bmatrix} =$	$-20.58K_D + 200.8K_I = 1$
$\langle K^{pid}, \bar{b}_0 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 200.8 \\ 0 \\ 0 \end{bmatrix} =$	$200.8K_P = 0$

Da tabela 27, tem-se o sistema de equações

$$K^{pid} = \begin{cases} -20.58K_P + 200.8K_I + 56.94K_D = 0 \\ 200.8K_P + 0K_I - 20.58K_D = 1 \\ 0K_P + 0K_I + 200.8K_D = 0 \end{cases} \quad (172)$$

Resolvendo o sistema de equações representado pela Eq. (172) encontra-se os valores dos ganhos $K_P = 0.0050$, $K_I = 5.1256 \times 10^{-4}$ e $K_D = 0$. Substituindo-se os valores dos ganhos de K^{pid} no polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^5 = \frac{s^4 - 8.58s^3 + 0.27s^2 + 0.03}{2s^4 + 0.19s^3 + 1.38s^2 + 0.157s}. \quad (173)$$

Tabela 28 – Situação 3 do caso 2

$\langle K^{pid}, \bar{b}_2 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.94 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$56.94K_D - 20.58K_P + 200.8K_I = 0$
$\langle K^{pid}, \bar{b}_1 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} -20.58 \\ 200.88 \\ 0 \end{bmatrix} =$	$-20.58K_D + 200.8K_I = 0$
$\langle K^{pid}, \bar{b}_0 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 200.8 \\ 0 \\ 0 \end{bmatrix} =$	$200.8K_P = 1$

Da tabela 28, tem-se o sistema de equações


$$K^{pid} = \begin{cases} -20.58K_P + 200.8K_I + 56.94K_D = 0 \\ 200.8K_P + 0K_I - 20.58K_D = 0 \\ 0K_P + 0K_I + 200.8K_D = 1 \end{cases} \quad (174)$$

Resolvendo o sistema de equações representado pela Eq. (174) encontra-se os valores dos ganhos $K_P = 5.1256 \times 10^{-4}$, $K_I = 0.0014$ e $K_D = 0.0050$. Substituindo-se os valores dos ganhos de K^{pid} no polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^6 = \frac{0.10s^4 + 0.28s^3 + s^2 - 0.02s + 0.03}{1.10s^4 + 0.46s^3 + 2.12s^2 + 0.10s + 0.28}. \quad (175)$$


Na Figura 103 está ilustrada o comportamento da curva da resposta ao degrau unitário da FT da Eq. (160) da planta em malha aberta representada pela curva vermelha na e as respostas ao degrau unitário das FTs da Eq. (171), da Eq. (173) e da Eq. (175) em malha fechada para o caso 1 da Tabela 22 representadas pelas curvas em azul.

Figura 103 – Resposta ao degrau unitário das FTs representadas pelas Eq. (160) x Eqs. (171, 173 e 175).



Na Figura 104 está ilustrada o comportamento da curva da resposta ao impulso da FT da Eq. (160) da planta em malha aberta representada pela curva vermelha na e as respostas ao degrau unitário das FTs da Eq. (171), da Eq. (173) e da Eq. (175) em malha fechada para o caso 1 da Tabela 22 representadas pelas curvas em azul.

Figura 104 – Resposta ao impulso das FTs representadas pelas Eq. (160) x Eqs. (171, 173 e 175).



A.1.4.3 Caso 3 ($s^0 + s^1 + s^3$)

Montagem da FT com o controlador PID a partir do caso 3 apresentado na Tabela 22.

Tabela 29 – Situação 1 do caso 3

$\langle K^{pid}, \bar{b}_3 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 0 \\ 56.9391 \\ -20.58 \end{bmatrix} =$	$56.94K_P - 20.58K_I$	$= 1$
$\langle K^{pid}, \bar{b}_2 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.93 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$56.94K_D - 20.58K_P + 200.8K_I$	$= 0$
$\langle K^{pid}, \bar{b}_0 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 200.8 \\ 0 \\ 0 \end{bmatrix} =$	$200.8K_D$	$= 0$

Da tabela 29, tem-se o sistema de equações

$$K^{pid} = \begin{cases} +56.94K_P - 20.58K_I + 0K_D = 1 \\ -20.58K_P + 200.8K_I - 56.94K_D = 0 \\ 0K_P + 0K_I + 200.8K_D = 0 \end{cases} \quad (176)$$

Resolvendo o sistema de equações representado pela Eq. (176) encontra-se os valores dos ganhos $K_P = 7 = 0.897$, $K_I = 0.00920$ e $K_D = 0$. Substituindo-se os valores dos ganhos

de K^{pid} no polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^7 = \frac{180.1s^4 - 16.61s^3 + 50.89s^2 + 0.52s}{181.1s^4 - 16.42s^3 + 52s^2 + 0.65s}. \quad (177)$$

Tabela 30 – Situação 2 do caso 3

$\langle K^{pid}, \bar{b}_3 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 0 \\ 56.9391 \\ -20.58 \end{bmatrix} =$	$56.94K_P - 20.58K_I$	$= 0$
$\langle K^{pid}, \bar{b}_2 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.93 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$56.94K_D - 20.58K_P + 200.8K_I$	$= 1$
$\langle K^{pid}, \bar{b}_0 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 200.8 \\ 0 \\ 0 \end{bmatrix} =$	$200.8K_D$	$= 0$

Da tabela 30, tem-se o sistema de equações que é dado por

$$K^{pid} = \begin{cases} +56.94K_P - 20.58K_I + 0K_D = 0 \\ -20.58K_P + 200.8K_I - 56.94K_D = 1 \\ 0K_P + 0K_I + 200.8K_D = 0 \end{cases} \quad (178)$$

Resolvendo o sistema de equações representado pela Eq. (178) encontra-se os valores do ganhos $K_P = 7 = 0.897$, $K_I = 0.00920$ e $K_D = 0$. Substituindo-se os valores dos ganhos de K^{pid} no polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^8 = \frac{102.6s^4 - 9.511s^3 + 28.99s^2 + 0.28s}{103.6s^4 - 9.317s^3 + 30.1s^2 + 0.41s}. \quad (179)$$

Tabela 31 – Situação 3 do caso 3

$\langle K^{pid}, \bar{b}_3 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 0 \\ 56.9391 \\ -20.58 \end{bmatrix} =$	$56.94K_P - 20.58K_I$	$= 0$
$\langle K^{pid}, \bar{b}_2 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.93 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$56.94K_D - 20.58K_P + 200.8K_I$	$= 0$
$\langle K^{pid}, \bar{b}_0 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 200.8 \\ 0 \\ 0 \end{bmatrix} =$	$200.8K_D$	$= 1$

Da tabela 31, tem-se o sistema de equações, que é dado por


$$K^{pid} = \begin{cases} +56.94K_P - 20.58K_I + 0K_D = 0 \\ -20.58K_P + 200.8K_I - 56.94K_D = 0 \\ 0K_P + 0K_I + 200.8K_D = 1 \end{cases} \quad (180)$$

Resolvendo o sistema de equações representado pela Eq. (180) encontra-se os valores do ganhos $K_P = 7 = 0.897$, $K_I = 0.00920$ e $K_D = 0$. Substituindo-se os valores dos ganhos de K^{pid} no polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^9 = \frac{0.11s^4 + 0.29s^3 + s^2 - 0.118s + 0.28}{1.11s^4 + 0.48s^3 + 2.12s^2 + 0.11s + 0.28}. \quad (181)$$


Na Figura 105 está ilustrada o comportamento da curva da resposta ao impulso da função de transferência Eq. (160) da planta em malha aberta representada pela curva destacada em vermelho e as respostas ao degrau unitário das FTs da Eq. (177), da Eq. (179) e da Eq. (181) em malha fechada para o caso 1 da Tabela 22 representadas pelas curvas destacadas em azul.

Figura 105 – Resposta ao degrau das FTs representadas pelas Eq. (160) x Eqs. (177, 179 e 181).



Na Figura 106 está ilustrada o comportamento da curva da resposta ao impulso da FT da Eq. (160) da planta em malha aberta representada pela curva vermelha na e as respostas ao degrau unitário das FTs da Eq. (177), da Eq. (179) e da Eq. (181) em malha fechada para o caso 1 da Tabela 22 representadas pelas curvas em azul.

Figura 106 – Resposta ao impulso das FTs representadas pelas Eq. (160) x Eqs. (177, 179 e 181).



A.1.4.4 Caso 4 ($s^0 + s^2 + s^3$)

Montagem da FT com o controlador PID a partir do caso 4 apresentado na Tabela 22.

Tabela 32 – Situação 1 do caso 4

$\langle K^{pid}, \bar{b}_3 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 0 \\ 56.9391 \\ -20.58 \end{bmatrix} = 56.94K_P - 20.58K_I = 1$
$\langle K^{pid}, \bar{b}_1 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.93 \\ -20.58 \\ 200.8 \end{bmatrix} = -20.58K_P + 200.8K_D = 0$
$\langle K^{pid}, \bar{b}_0 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 200.8 \\ 0 \\ 0 \end{bmatrix} = 200.8K_D = 0$

Da tabela 32, tem-se o sistema de equações, que é dado por

$$K^{pid} = \begin{cases} +56.94K_P - 20.58K_I + 0K_D = 1 \\ 200.8K_P - 20.58K_I = 0 \\ 0K_P + 0K_I + 200.8K_D = 0 \end{cases} \quad (182)$$

Resolvendo o sistema de equações representado pela Eq. (182) encontra-se os valores do ganhos $K_P = 7 = 0$, $K_I = 0.0486$ e $K_D = 0$. Substituindo-se os valores dos ganhos de K^{pid} no

polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^{10} = \frac{0.11s^4 + 0.29s^3 + s^2 - 0.18s + 0.28}{1.11s^4 + 0.48s^3 + 2.12s^2 + 0.11s}. \quad (183)$$

Tabela 33 – Situação 2 do caso 4

$\langle K^{pid}, \bar{b}_3 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 0 \\ 56.9391 \\ -20.58 \end{bmatrix} =$	$56.94K_P - 20.58K_I = 0$
$\langle K^{pid}, \bar{b}_1 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.93 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$-20.58K_P + 200.8K_D = 1$
$\langle K^{pid}, \bar{b}_0 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 200.8 \\ 0 \\ 0 \end{bmatrix} =$	$200.8K_D = 0$

Da tabela 33, tem-se o sistema de equações, que é dado por

$$K^{pid} = \begin{cases} +56.94K_P - 20.58K_I + 0K_D = 0 \\ 200.8K_P - 20.58K_I = 1 \\ 0K_P + 0K_I + 200.8K_D = 0 \end{cases} \quad (184)$$

Resolvendo o sistema de equações representado pela Eq. (186) encontra-se os valores dos ganhos $K_P = 0.0050$, $K_I = 0.0138$ e $K_D = 0$. Substituindo-se os valores dos ganhos de K^{pid} no polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT 185

$$F_{MF}^{11} = \frac{s^4 + 2.67s^3 + 0.0007s^2 + 0.79s}{2s^4 + 2.87s^3 + 1.11s^2 + 0.91s}. \quad (185)$$

Tabela 34 – Situação 3 do caso 4

$\langle K^{pid}, \bar{b}_3 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 0 \\ 56.9391 \\ -20.58 \end{bmatrix} =$	$56.94K_P - 20.58K_I = 0$
$\langle K^{pid}, \bar{b}_1 \rangle = 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 56.93 \\ -20.58 \\ 200.8 \end{bmatrix} =$	$-20.58K_P + 200.8K_D = 0$
$\langle K^{pid}, \bar{b}_0 \rangle \neq 0$	$\begin{bmatrix} K_D & K_P & K_I \end{bmatrix} \begin{bmatrix} 200.8 \\ 0 \\ 0 \end{bmatrix} =$	$200.8K_D = 1$

Da tabela 34, tem-se o sistema de equações que é dado por


$$K^{pid} = \begin{cases} +56.94K_P - 20.58K_I + 0K_D = 0 \\ 200.8K_P - 20.58K_I = 0 \\ 0K_P + 0K_I + 200.8K_D = 1 \end{cases} \quad (186)$$

Resolvendo o sistema de equações representado pela Eq. (186) encontra-se os valores do ganhos $K_P = 5.1256 * 10^{-4}$, $K_I = 0.0014$ e $K_D = 0.0050$. Substituindo-se os valores dos ganhos de K^{pid} no polinômio característicos representado pela Eq. (163) que foi obtido da Eq. (160), encontra-se a FT que é dada por

$$F_{MF}^{12} = \frac{0.1s^4 + 0.27s^3 + s^2 - 0.023s + 0.28}{1.1s^4 + 0.46s^3 + 2.12s^2 + 0.1s + 0.28}. \quad (187)$$


Na Figura 107 está ilustrada o comportamento da curva da resposta ao degrau unitário da FT da Eq. (160) da planta em malha aberta representada pela curva vermelha na e as respostas ao degrau unitário das FTs da Eq. (183), da Eq. (185) e da Eq. (187) em malha fechada para o caso 1 da Tabela 22 representadas pelas curvas em azul.

Figura 107 – Resposta ao degrau das FTs representadas pelas Eq. (160) x Eqs. (183, 185 e 187).



Na Figura 108 está ilustrada o comportamento da curva da resposta ao impulso da FT da Eq. (160) da planta em malha aberta representada pela curva vermelha na e as respostas ao impulso das FTs da Eq. (183), da Eq. (185) e da Eq. (187) em malha fechada para o caso 1 da Tabela 22 representadas pelas curvas em azul.

Figura 108 – Resposta ao impulso das FTs representadas pelas Eq. (160) x Eqs. (183, 185 e 187).



A.1.4.5 Sintonia pelo Método de Tentativa e Erro

Nesta Subseção, faz-se a sintonia dos controladores PID das FTs apresentadas na Subseção A.1.4 feita pelo método de tentativas e erros, de forma que os ganhos K_P , K_I e K_D encontrados estabilizem os sistemas, desta forma determina-se os limites, ou seja, as restrições para os valores dos ganhos K^{pid} que serão utilizados nas metodologias de autoajustes de ganhos de controladores PID.

A.1.4.6 Caso 1 ($s^0 + s^1 + s^2$)


De acordo com os valores de $K_P = 0.239$, $K_I = 0.6367$ e $K_D = 2.331$ obtidos do sistema de equações representado pela Eq. (164) que resultou na FT representado pela Eq. (165). Observou-se nas Figura (101) b e (102) b de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 10^{-2}$, $K_I = 0.06367$ e $K_D = 0.95$, que gerou uma nova FT que é dada por

$$F_{MF}^{1.1} = \frac{2.008s^4 + 12.58s^3 + 190s^2 - 15.93s + 54.09}{3.008s^4 + 12.77s^3 + 191.1s^2 - 15.8s + 54.09}. \quad (188)$$

Na Figura 109 observa-se os desempenhos dos controlador PIDs para as Eqs. (165) e (188) respectivamente. Conforme Figura 109 a) e 109 c); 109 b) e 109 d), pode-se observar

a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (188).

Figura 109 – Controlador PID da planta representada pela Eq. (165) x Eq. (188).




De acordo com os valores de $K_P = 9.1726 \times 10^{-4}$, $K_I = 0.025$ e $K_D = 0.008$ obtidos do sistema de equações representado pela a Eq. (164) que resultou na FT representado pela Eq. (167). Observou-se nas Figura (101) c e (102) d de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 1 = 10^{-3}$, $K_I = 10^{-6}$ e $K_D = 10^{-3}$, que gerou uma nova FT que é dada por

$$F_{MF}^{2.1} = \frac{0.2008s^4 - 0.02038s^3 + 0.2577s^2 - 0.2052s + 0.05694}{1.201s^4 + 0.1738s^3 + 1.369s^2 + 0.107s + 0.5694}. \quad (189)$$

Na Figura 110 observa-se os desempenhos dos controlador PIDs para as Eqs. (167) e (189) respectivamente. Conforme Figura 110 c) e 110 d); 110 b) e 110 d), pode-se observar a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (189).

Figura 110 – Controlador PID da planta representada pela Eq. (167) x Eq. (189).




De acordo com os valores de $K_P = 0.0035$, $K_I = 0.0097$ e $K_D = 1.6797 \times 10^{-4}$ obtidos do sistema de equações representado pela Eq. (168) que resultou na FT representado pela Eq. (167). Observou-se nas Figura (101) c e (102) d de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 0.5 \times 10^{-5}$, $K_I = 0.5 \times 10^{-3}$ e $K_D = 10^{-4}$, que gerou uma nova FT que é dada por

$$F_{MF}^{3.1} = \frac{0.001004s^4 + 0.1003s^3 + 0.01007s^2 + 0.02641s + 0.005694}{1.001s^4 + 0.2945s^3 + 1.121s^2 + 0.1539s + 0.005694}. \quad (190)$$

Na Figura 111 observa-se os desempenhos dos controlador PIDs para as Eqs. (167) e (190) respectivamente. Conforme Figura 111 a) e 111 b); 111 c) e 111 d), pode-se observar a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (190).

Figura 111 – Controlador PID da planta representada pela Eq. (169) x Eq. (190).


A.1.4.7 Caso 2 ($s^1 + s^2 + s^3$)

De acordo com os valores de $K_P = 0$, $K_I = 0.0050$ e $K_D = 0$ obtidos do sistema de equações representado pela Eq. (170) que resultou na FT representado pela Eq. (171). Observou-se nas Figura 101) c) e 102 d) de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 10^{-4}$, $K_I = 1$ e $K_D = 1$, que gerou uma nova FT que é dada por

$$F_{MF}^{4.1} = \frac{0.02008s^4 + 200.8s^3 + 180.2s^2 + 36.36s + 56.94}{1.02s^4 + 200.9s^3 + 181.3s^2 + 36.48s + 56.94}. \quad (191)$$


Na Figura 112 observa-se os desempenhos dos controlador PIDs para as Eqs. (171) e (191) respectivamente. Conforme Figura 112 a) e 112 b); 112 c) e 112 d), pode-se observar a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (191).

Figura 112 – Controlador PID da planta representada pela Eq. (171) x Eq. (191).



$$F_{MF}^{5.1} = \frac{0.2008s^4 + 20.06s^3 + 2006s^2 - 200.1s + 569.4}{1.201s^4 + 20.25s^3 + 2007s^2 - 200s + 569.4}. \quad (192)$$

Figura 113 – Controlador PID da planta representada pela Eq. (173) x Eq. (192).




De acordo com os valores de $K_P = 5.1256 \times 10^{-4}$, $K_I = 0.0014$ e $K_D = 0.0050$ obtidos do sistema de equações representado pela Eq. (174) que resultou na FT representado pela Eq. (175). Observou-se nas Figura 101 (c) e 102 (d) de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 10^{-5}$, $K_I = 10^{-3}$ e $K_D = 10^{-4}$, que gerou uma nova FT que é dada por

$$F_{MF}^{6.1} = \frac{2.008 \times 10^{-4}s^4 + 0.2006s^3 + 6.337 \times 10^{-5}s^2 + 0.05488s + 5.694 \times 10^{-4}}{1.002s^4 + 0.3948s^3 + 1.11s^2 + 0.1824s + 0.005694}. \quad (193)$$

Na Figura 114 observa-se os desempenhos dos controlador PIDs para as Eqs. (175) e (193) respectivamente. Conforme Figura 114 a) e 114 b); 114 c) e 114 d), pode-se observar a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (193).

Figura 114 – Controlador PID da planta representada pela Eq. (175) x Eq. (193).




A.1.4.8 Caso 3 ($s^0 + s^1 + s^3$)

De acordo com os valores de $K_P = 0.897$, $K_I = 0.00920$ e $K_D = 0$ obtidos do sistema de equações representado pela Eq. (176) que resultou na FT representado pela Eq. (177). Observou-se nas Figura 101 (c) e 102 (d) de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 10^{-3}$, $K_I = 10^{-5}$ e $K_D = 10^{-3}$, que gerou uma nova FT que é dada por

$$F_{MF}^{7.1} = \frac{0.2008s^4 - 0.01857s^3 + 0.2575s^2 - 0.02001s + 0.05694}{1.201s^4 + 0.1756s^3 + 1.369s^2 + 0.1075s + 0.05694}. \quad (194)$$

Na Figura 115 observa-se os desempenhos dos controlador PIDs para as Eqs. (177) e (194) respectivamente. Conforme Figura 115 a) e 115 b); 115 c) e 115 d), pode-se observar a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (194).

Figura 115 – Controlador PID da planta representada pela Eq. (177) x Eq. (194).




De acordo com os valores de $K_P = 0.5109$, $K_I = 0.0050$ e $K_D = 0$ obtidos do sistema de equações representado pela a Eq. (178) que resultou na FT representado pela Eq. (179). Observou-se nas Figura 101 (c) e 102 (d) de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 10^{-2}$, $K_I = 10^{-2}$ e $K_D = 10^{-3}$, que gerou uma nova FT que é dada por

$$F_{MF}^{8.1} = \frac{2.008s^4 + 1.802s^3 + 0.5643s^2 + 0.5488s + 0.05694}{3.008s^4 + 1.996s^3 + 1.676s^2 + 0.6763s + 0.05694}. \quad (195)$$

Na Figura 116 observa-se os desempenhos dos controlador PIDs para as Eqs. (179) e (195) respectivamente. Conforme Figura 116 a) Step e 116 b) Impulse; 116 c) Step e 116 d) Impulse, pode-se observar a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (195).

Figura 116 – Controlador PID da planta representada pela Eq. (179) x Eq. (195).




De acordo com os valores de $K_P = 5.4269 \times 10^{-4}$, $K_I = 0.0015$ e $K_D = 0.0050$ obtidos do sistema de equações representado pela Eq. (178) que resultou na FT representado pela Eq. (179). Observou-se nas Figura 101 (c) e 102 (d) de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 10^{-3}$, $K_I = 10^0$ e $K_D = 10^{-4}$, que gerou uma nova FT que é dada por

$$F_{MF}^{9.1} = \frac{0.2008s^4 + 200.7s^3 - 20.5s^2 + 56.94s + 0.005694}{1.201s^4 + 200.9s^3 - 19.39s^2 + 57.06s + 0.005694}. \quad (196)$$

Na Figura 117 observa-se os desempenhos dos controlador PIDs para as Eqs. (179) e (196) respectivamente. Conforme Figura 117 a) Degrau e 117 b) Impulso; 117 c) Degrau e 117 d) Impulso, pode-se observar a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (196).

Figura 117 – Controlador PID da planta representada pela Eq. (181) x Eq. (196).


A.1.4.9 Caso 4 ($s^0 + s^2 + s^3$)

De acordo com os valores de $K_P = 0$, $K_I = 0.0486$ e $K_D = 0$ obtidos do sistema de equações representado pela Eq. (182) que resultou na FT representado pela Eq. (183). Observou-se nas Figura 101 (c) e 102 (d) de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 10^{-1}$, $K_I = 10^2$ e $K_D = 10^0$, que gerou uma nova FT que é dada por

$$F_{MF}^{10.1} = \frac{20.08s^4 + 2.007 \times 10^4 s^4 - 1852s^2 + 5673s + 56.94}{21.08s^4 + 2.007 \times 10^4 s^3 - 1851s^2 + 5673s + 56.94}. \quad (197)$$

Na Figura 118 observa-se os desempenhos dos controlador PIDs para as Eqs. (183) e (197) respectivamente. Conforme Figura 118 a) Degrau e 118 b) Impulso; 118 c) Degrau e 118 d) Impulso, pode-se observar a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (197).

Figura 118 – Controlador PID da planta representada pela Eq. (183) x Eq. (197).




De acordo com os valores de $K_P = 0$, $K_I = 0.0486$ e $K_D = 0$ obtidos do sistema de equações representado pela a Eq. (186) que resultou na FT representado pela Eq. (185). Observou-se nas Figura 101 (c) e 102 (d) de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 10^{-1}$, $K_I = 10^2$ e $K_D = 10^0$, que gerou uma nova FT que é dada por

$$F_{MF}^{11.1} = \frac{20.08s^4 + 2006s^3 + 1807s^2 + 363.6s + 569.4}{21.08s^4 + 2006s^3 + 363.7s + 569.4}. \quad (198)$$

Na Figura 119 observa-se os desempenhos dos controlador PIDs para as Eqs. (185) e (198) respectivamente. Conforme Figura 119 a) Degrau e 119 b) Impulso; 119 c) Degrau e 119 d) Impulso, pode-se observar a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (198).

Figura 119 – Controlador PID da planta representada pela Eq. (185) x Eq. (198).




De acordo com os valores de $K_P = 0$, $K_I = 0.0486$ e $K_D = 0$ obtidos do sistema de equações representado pela Eq. (186) que resultou na FT representado pela Eq. (185). Observou-se nas Figura 101 (c) e 102 (d) de resposta ao degrau e resposta ao impulso respectivamente, que o sistema era não controlado. Então, foi feito um ajuste por tentativa e encontrou-se os seguintes valores para $K_P = 10^{-1}$, $K_I = 10^2$ e $K_D = 10^0$, que gerou uma nova FT que é dada por

$$F_{MF}^{12.1} = \frac{2.008s^4 + 200.6s^3 + 1988s^2 - 148.9s + 569.4}{3.008s^4 + 200.7s^3 + 1989s^2 - 148.8s + 569.4}. \quad (199)$$

Na Figura 120 observa-se os desempenhos dos controlador PIDs para as Eqs. (187) e (199) respectivamente. Conforme Figura 120 a) Degrau e 120 b) Impulso; 120 c) Degrau e 120 d) Impulso, pode-se observar a convergência do controlador PID nas curvas de resposta ao degrau unitário e a resposta ao impulso para a planta representada pela FT da Eq. (199).

Figura 120 – Controlador PID da planta representada pela Eq. (187) x Eq. (199).



A.1.4.10 Considerações Gerais

Analizando os experimentos e análise feitos usando-se a metodologia apresentada neste capítulo, trata-se de modelos de sintonia ótima de controladores PID no plano s de sistemas dinâmicos em plantas industriais, onde se determinou o ganho K^{pid} por meio do produto interno $\langle K^{pid}, \bar{b}_i \rangle$ obtido do polinômio característico representado pela Eq. (163) e feito o refinamento dos ganhos K_P , K_I , K_D por métodos práticos de tentativa e erro. Portanto, a sintonia feita usando-se da metodologia do produto interno $\langle K^{pid}, \bar{b}_i \rangle$ e refinada por métodos práticos de sintonia por tentativa e erro, obteve melhores desempenhos, comparando-se com os resultados da planta apresentados na Figura 100.

ANEXO **A**

Artigos Mais Relevantes Relacionados com o Tema da Tese

Models for Optimal Online Tuning Based on Computational Intelligence of PID Controllers Applied to Operational Processes of Bulk Reclaimers

**José Pinheiro de Moura, João Viana da
Fonseca Neto & Patrícia Helena M. Rêgo**

**Journal of Control, Automation and
Electrical Systems**
formerly CONTROLE & AUTOMAÇÃO


ISSN 2195-3880

J Control Autom Electr Syst
DOI 10.1007/s40313-018-00438-7

Volume 24 • Number 5

**Journal of
Control, Automation
& Electrical Systems**

Formerly Controle & Automação



 Springer
40313 • ISSN 2195-3880
24(5) 585–724 (2013)



Available
online
www.springerlink.com

Your article is protected by copyright and all rights are held exclusively by Brazilian Society for Automatics--SBA. This e-offprint is for personal use only and shall not be self-archived in electronic repositories. If you wish to self-archive your article, please use the accepted manuscript version for posting on your own website. You may further deposit the accepted manuscript version in any repository, provided it is only made publicly available 12 months after official publication or later and provided acknowledgement is given to the original source of publication and a link is inserted to the published article on Springer's website. The link must be accompanied by the following text: "The final publication is available at link.springer.com".



Models for Optimal Online Tuning Based on Computational Intelligence of PID Controllers Applied to Operational Processes of Bulk Reclaimers

José Pinheiro de Moura^{1,2} · João Viana da Fonseca Neto^{1,2} · Patrícia Helena M. Rêgo¹

Received: 10 May 2018 / Revised: 10 December 2018 / Accepted: 26 December 2018
© Brazilian Society for Automatics–SBA 2019

Abstract

This paper considers the development of models for the optimal online tuning of PID controllers based on computational intelligence approaches that are applied to the operational processes of bulk reclaimers. In the first instance, the optimal gains of a PID controller are determined using a structured artificial neural network (ANN), and in the second instance, a fuzzy system is used to carry out online adjustment through a real-time gain scheduling scheme. The bulk resumption process consists of picking up the stored material in stacks and transporting it using conveyor belts for shipment. For the control system, a model based on data pertaining to the electric current in a bucket wheel motor (a device that picks up material) is estimated and compared with the load measured using a scale. The difference between the load estimated by the model and that measured by the scale is the error, and the proposed control system is designed to minimize it. The results of simulations show that the controller models performed better using structured ANNs and fuzzy logic than PID controllers tuned by the second Ziegler–Nichols method, and the PID–fuzzy controller proposed by Zhao and Tomizuka.

Keywords Computational intelligence · PID controllers · Bulk reclaimers · Artificial neural network · Fuzzy system

1 Introduction

Control systems for industrial processes are fundamental for companies in the competitive market, where the main concern is to control such variables as flow, pressure, level, temperature, pH, and density, for efficient control. This is to maintain the variables around their set points. Just as the motor is the main actuator in the industry, a controller with proportional, integral, and derivative actions (PID) is the most important control system for industrial processes. The simplicity of the tuning algorithms of PID controllers as associated with their impressive performance as versatile compensators has led to their acceptance in industry (Lee et al. 2008; Pai et al. 2010).

The structure of equations used in PID controllers in association with the mathematical transformations, e.g., Laplace or the Z transforms, leads to their representation in the form

of polynomials. These representations are in a form suitable for the design, analysis, and implementation of actions arising from a combination of the proportional, integral, and derivative terms.

Since 1942, the tuning methods for PID controllers proposed by Ziegler and Nichols (ZN) (Ziegler and Nichols 1942) have been applied on a large scale in industrial processes (Gopi Krishna Rao et al. 2017). Tuning methods thus play an important role in determining gains in PID controllers, in terms of optimality, adaptability, and robustness (Verma et al. 2017).

The proposed tuning models here are based on approaches of structured artificial neural networks (ANNs) and fuzzy logic, called the PID–neuro-fuzzy model. The performance of the proposed models is evaluated using the operational process of a bulk reclaimer (BR), which is partially represented in Fig. 1. In this context, the position and velocity controls of the BR machine operating in the industry yard are evaluated.

The main objective of the tuning method is to assign properties of optimality, adaptability, and robustness (Pratap and Purwar 2014) to the reclaimer control system. Thus, it aligns the proposal with the autonomous operating requirements

✉ José Pinheiro de Moura
josepinheiro@professor.uema.br

¹ UEMA - Cidade Universitária Paulo VI, São Luís, Brazil

² UFMA - Cidade Universitária Dom Delgado, São Luís, Brazil



Fig. 1 Bulk reclaimer

of industrial equipments, and according to Industry 4.0 precepts (Sanchez et al. 2007; Lasi et al. 2014), with the aim of automation in an effort to reduce input waste and operating costs.

The main approaches that contribute to the development of PID–neuro-fuzzy models are formalized in terms of the state of the art to meet a class of problems where the operation occurs according to a sequence of synchronized events, during their actions. The adaptability property promotes the appropriate solution to a new operational situation, while the optimality property satisfies design requirements at lowest cost to the process, which is an attractive prospect that justifies the development of high-performance PID controllers. Therefore, models and algorithms for control systems for a class of problems that need to act in the process in a sequential and parallel manner are presented. To emphasize the importance of control systems for the essential sectors in the current economy, the timeline and the state of the art of PID controllers are presented.

As shown in Rossomando and Soria (2015), Jeng (2015), and Chu et al. (2013), PID controllers are an intensive focus of development and advanced research in a variety of applications. In Rossomando and Soria (2015), the authors proposed a PID controller with an adaptability property associated with mobile robotics for tracking trajectory.

PID controllers have several important functions, such as providing feedback, the capacity to eliminate steady-state offsets through integral action, and the ability to be anticipatory through derivative action. PID controllers are efficient for many control problems. Consistent and well-grounded applications can be found in Astrom and Hagglund (1995).

Large process industries may have between five and 5000 control loops, and PID controllers are used in around 90–97% of cases. It is known that only approximately 20–30% of the controllers in the process industry are adjusted satisfactorily, as most currently available methods are inefficient in tuning each control system separately. A thesis titled “Analysis and Design of Software-based Optimal PID Controllers” presents

tools for analysis and design of optimal PID controllers and suggests when and how to use them efficiently (Garpinger 2015).

The work in Jeng (2015) presented an adaptive controller that combines fuzzy inference with PID and analyzed the mathematical model of the excitation system of the synchronous generator and the method of inference of the fuzzy excitation PID controller. On the contrary, conventional diffuse control is known for its ability to deal with nonlinearities and uncertainties (Precup and Hellendoorn 2011). Some of the main advantages of these controllers are their robustness against uncertainties and attenuation of disturbance parameters (Brisilla and Sankaranarayanan 2017).

In this paper, a high-performance controller is proposed for the operational process of a BR. Fuzzy control has long been applied to the industry with successful results. It was originally introduced as a free-model approach to design control. In the last few decades, model-based fuzzy control has gained widespread significance and has been proposed for many industrial applications (Dias and de Sousa 2018; Mizuyama et al. 2018). However, fuzzy control combined with structured ANNs for the operational control of bulk rebuilders is a novelty.

The relevance of this paper lies mainly in the technical/scientific contributions to complex industrial processes, such as the operation of a BR with a PID controller, by using parameters of self-adjusting gain.

The remainder of this paper is organized as follows: The preliminaries and state of the art of the theory of PID controllers, as well as the computational intelligence used in the development of the neuro-fuzzy models for optimal online tuning of PID controllers, are presented in Sect. 2. Section 3 presents the PID–neuro-fuzzy models for the operational control of a BR acting as follows: The proportional action adjusts the output of the controller according to the variation in error; the integral action eliminates the offset error in steady state, and future behavior is anticipated through derivative action. Moreover, results that verify the performance of the proposed controller in this work are highlighted in Sect. 4 and are compared with the conventional PID controller tuned by the second Ziegler–Nichols method, and the PID–fuzzy controller proposed by Zhao and Tomizuka is presented in the “Appendices A and B,” respectively. Finally, the conclusion and comments are presented in Sect. 5.

2 Preliminaries

This section describes the bulk resumption process and characterizes the control problem, the state of the art of PID controllers, fuzzy logic associated with the problem of the tuning its gains, and topics in artificial neural networks.

The main issues relating to PID controllers and computational intelligence approaches that help develop the neuro-fuzzy models used here, and proposed for the optimal online tuning of the PID controllers, are presented in an objective and contextualized way. This is done by relating the structure of the PID controllers to the BR machine process, and emphasizing the combination of ANN and fuzzy rules for tuning gains in the control system.

2.1 Description of the Plant's Operational Process

The bulk resumption process consists of picking up the material and transporting it by conveyor belts for shipment (de Moura et al. 2013). The bulk resumption was carried out using large equipment, called the BR. As shown in Fig. 1, these are composed of two moving parts:

- Translation structure:
 - In the translation structure, the trucks and translational movement drives are installed with seven AC motors of 30 hp on each side.
- Rotational structure of the lance:
 - In the rotational structure, the lance and the counterweight are installed. At the tip of the lance is the bucket wheel (BW), a device that facilitates bulk resumption, and is driven by an AC motor.

The rotational structure of the lance was assembled in the translation structure using wheels on rails on a table called the “turning table,” where two 600-hp AC motors were installed, one on each side to the rotation of the lance. The PID controller acted here directly by varying rotational speed to maintain the system's reference value (Lopes et al. 2012). The plant being studied was complex, both in terms of mathematical modeling and process control. The BR operation is most often carried out by means of commands with an embedded operator or remotely from control rooms using commands given in a human machine interface (HMI). The HMI sends the commands to a programmable logic controller, where its logic and the sequencing were developed (de Moura et al. 2003). The following section describes the control problem and the justification for the development of models for a class of problems consisting of events that occur sequentially and in parallel.

2.2 Characterization of the Control Problem

According to field observations, there is a strong relationship between the electric current of the BW motor and the flow measured by the scale. Note that the scale had a delay of 10 s in relation to the BW, as shown in Fig. 2. The models




Fig. 2 Mechanical arrangement of BR




Fig. 3 Load flow of electric motor current of BW $\times$ measured load flow

proposed in this paper acted directly on the estimated model (Lopes et al. 2012; de Moura et al. 2016a). The following method was used: The plant model represented by means of a transfer function was first identified, and the root locus was calculated to develop the PID controller. The structured ANN was represented mathematically to determine the parameters of gains by the PID controller, and a fuzzy controller was developed to make online adjustments to the gains in real time to maintain the adaptive system during operation.

To solve the problem of delay in the resumed load in real time, a model was estimated based on electric current intensity (I) data of the bucket wheel motor and compared with flow measured by the scale, as shown in Fig. 3. As the intensity of the electric current increased, load measured by the scale increased proportionately.

From data concerning the electric current intensity of the BW motor collected in real time, the plant model was identified and is given by the following transfer function:

$$G_{BR}^{LO}(s) = \frac{0.1812s + 0.0871}{s^3 + 0.3553s^2 + 0.1117s + 0.01567}, \quad (1)$$

where $G_{BR}^{LO}(s)$ is the transfer function of the plant in an open loop.

2.3 PID Controller

The conventional PID controller is the most frequently used control strategy in the industry because of its simplicity (Kar and Roy 2018), robust performance, and the availability of several effective and simple adjustment methods for it based on minimum plant knowledge (Ziegler and Nichols 1942; Cohen 1953; Murrill 1967; Parr 1998).

The transfer function of a PID controller is given by

$$G_c(s) = K_P \left(1 + \frac{1}{T_I s} + T_D s \right), \quad (2)$$

$$T_I = \frac{K_P}{K_I}, \quad (3)$$

$$T_D = \frac{K_D}{K_P}, \quad (4)$$

$T_I = \frac{K_P}{K_I}$ and $T_D = \frac{K_D}{K_P}$. T_I and T_D are the integral and derivative time constants, respectively (Zhao et al. 1993).

The discrete-time counterpart of a PID control is given by

$$u(k) = K_P e(k) + K_I T_s \sum_{i=1}^n e(i) + \frac{K_D}{T_s} \Delta e(k), \quad (5)$$

where $u(k)$ is the control signal, $e(k)$ is error between the reference input and the output of the process, T_s is the sampling period of the controller, and $\Delta e(k) \triangleq e(k) - e(k-1)$ (Zhao et al. 1993).

The PID controller can compensate for the effects of delayed and undelayed processes (Zhao et al. 1993). Studies have shown that about 90% of industrial controls belong to the PID controller family: P, PD, PI, or PID (Castillo-Garcia et al. 2013; Lee et al. 2008; Pai et al. 2010; Eris and Kurtulan 2011; Gopi Krishna Rao et al. 2013; Desborough and Miller 2002). These remain the most commonly used in industrial control plants worldwide because of their simple structure. They can be designed easily and deliver good performance for the control system at an acceptable cost (Aström and Hägglund 2001). The performance indices provided by the PID controllers depend not only on the tuning parameters, but also on the implementation of additional functionality, including anti-windup actions, feedforward, and set-point filtering (Aström and Hägglund 1995).

There is no perfect alternative to PID controllers, at least in the bottom layer of the process industry (Alcántara et al. 2013; Shamsuzzoha 2014). However, PI, PD, and PID controllers may not guarantee satisfactory performance of the control system if the mathematical model is highly nonlinear, subject to parameter variations and/or uncertainties. The

three parts of the PID controller can be used separately or combined for controller formulations (Garpinger 2015), such as the proportional controller **P**, proportional and integral controllers **PI**, proportional and derivative controllers **PD**, or the proportional, integral, and derivative controllers **PID** (O'Dwyer 2009).

Plant dynamics directly influence the type of controller to be formulated, as simpler plants require controllers that are easier to tune. In the industry, for example, tuning the PID controller has been rarely explored and, in most cases, there is a P, PI, or PD controller such that tuning one or two parts of the PID controller in complex processes may not be sufficient, thereby compromising controller efficiency.

2.4 Fuzzy Logic

Fuzzy logic is based on the theory of fuzzy sets. Traditionally, a logical proposition has two values: true or false (Farias et al. 2008). However, in fuzzy logic, a premise varies in degrees of membership (truth) from zero to one, which means that it can be partially true or false. A major idea of the traditional fuzzy approach is that as we cannot obtain the degrees of confidence of experts in all possible propositional combinations of a set of original statements $S_1, \dots, S_n$, we can extract degrees of confidence $d(S_i)$ in these statements, and, use the connectives (operators) “**and**” and “**or**” to estimate experts' degrees of membership in different propositional combinations (de Moura et al. 2016b). To make these estimates more precise, one idea is to extract from the expert his or her degrees of confidence in the original statements as well as the degrees of confidence for some propositional combinations of at least the simplest statements (Khayami et al. 2016).

In recent years, many nonlinear control algorithms have been proposed for industrial process systems, such as sliding mode control (Lee et al. 2006; Almutairi and Zribi 2009; Ngo and Hong 2012), feedback linearization control (Park et al. 2007; Le et al. 2012), adaptive control (Yang et al. 2007), energy-based design (Sun and Fang 2012), and the fuzzy logic system. To explore their advantages, these approaches are integrated as a complex control algorithm, such as fuzzy adaptation (Chang 2007; Wang 1993). Some of the main advantages of these controllers are their robustness against uncertainties and attenuation of disturbance parameters.

2.5 Structured Artificial Neural Networks

Structured artificial neural networks are powerful tools for modeling complex multivariable processes. They are more commonly used in the computational field, but are gaining currency in process control engineering as well (Ham and Kostanic 2000). Haykin wrote an important textbook on neural networks that provides comprehensive information from

 Springer

The closed-loop denominator polynomial is given by

$$D^{CL}(s) = N_p(s) N_c(s) + D_p(s) D_c(s), \quad (13)$$

where the term $D_p(s) D_c(s)$ is given by

$$\begin{aligned} D_p(s) D_c(s) &= s \left(s^n + a_1 s^{n-1} + a_2 s^{n-2} \right. \\ &\quad \left. + \cdots + a_{n-1} s + a_n s^0 \right) \\ &= s^{n+1} + a_1 s^n + a_2 s^{n-1} \\ &\quad + \cdots + a_{n-1} s^2 + a_n s^1. \end{aligned} \quad (14)$$

The characteristic polynomial of the closed-loop system is then given by

$$\begin{aligned} P^{CL}(s) &= s^{n+1} \\ &\quad + (b_0 K_D + a_1) s^n \\ &\quad + (b_1 K_D + b_0 K_P + a_2) s^{n-1} \\ &\quad + (b_2 K_D + b_1 K_P + b_0 K_I + a_3) s^{n-2} \\ &\quad + (b_3 K_D + b_2 K_P + b_1 K_I + a_4) s^{n-3} \\ &\quad \vdots \\ &\quad + (b_m K_D + b_{m-1} K_P + b_{m-2} K_I + a_{n-1}) s^2 \\ &\quad + (b_m K_P + b_{m-1} K_I + a_n) s^1 \\ &\quad + b_m K_I s^0 \end{aligned} \quad (15)$$

The gains are given by the propagation of

$$\begin{array}{cccc} & K_D & K_P & K_I \\ s^n & b_0 & 0 & 0 \\ s^{n-1} & b_1 & b_0 & 0 \\ s^{n-2} & b_2 & b_1 & b_0 \\ s^{n-3} & b_3 & b_2 & b_1 \\ \vdots & \vdots & \vdots & \vdots \\ s^2 & b_m & b_{m-1} & b_{m-2} \\ s^1 & 0 & b_m & b_{m-1} \\ s^0 & 0 & 0 & b_m \end{array} \quad (16)$$

Note that the diagonals are not repeated and vary according to the order n of the characteristic polynomial of the system. The propagation of the gains is the weights of the coefficients of the polynomial of zeros. The closed-loop transfer function of the plant is given in terms of the product of the gains K_D , K_P , and K_I with coefficients b_i , b_{i-1} , and b_{i-2} , respectively, of the closed-loop transfer function.

The general form of the closed-loop denominator polynomial is given by

$$\begin{aligned} D^{CL}(s) &= s^{n+n_{D-pid}} \\ &\quad + \sum_{i=0}^{n+n_{D-pid}-1} \left(b_i K_D + b_{i-1} K_P \right. \\ &\quad \left. + b_{i-2} K_I + a_{i+1} \right) s^{n-i}, \end{aligned} \quad (17)$$

where $n_{D-pid} = 0, 1$. When $n_{D-pid} = 0$, the structure of the PID controller had derivative and proportional terms. When $n_{D-pid} = 1$, the structure of the PID controller had an integrator term that increased the order of the system by one, starting with three terms: proportional, derivative, and integrative.

The equation describing the problem is given in the form of an internal product that weighs the coefficients of the polynomial of zeros in the closed loop and adds them to the dynamics of the closed-loop transfer function. Then, the characteristic polynomial of the closed-loop system can be expressed as

$$\begin{aligned} P^{CL}(s) &= s^{n+1} \\ &\quad + \left(a_1 + \left\langle K^{pid}, \bar{b}_0 \right\rangle \right) s^n \\ &\quad + \left(a_2 + \left\langle K^{pid}, \bar{b}_1 \right\rangle \right) s^{n-1} \\ &\quad + \left(a_3 + \left\langle K^{pid}, \bar{b}_2 \right\rangle \right) s^{n-2} \\ &\quad \vdots \\ &\quad + \left(a_{n-2} + \left\langle K^{pid}, \bar{b}_{m-3} \right\rangle \right) s^3 \\ &\quad + \left(a_{n-1} + \left\langle K^{pid}, \bar{b}_{m-2} \right\rangle \right) s^2 \\ &\quad + \left(a_n + \left\langle K^{pid}, \bar{b}_{m-1} \right\rangle \right) s^1 \\ &\quad + \left(a_{n+1} + \left\langle K^{pid}, \bar{b}_m \right\rangle \right) s^0 \end{aligned} \quad (18)$$

where the vectors $\bar{b}_i$ of the polynomial of zeros of the closed-loop system are given by

$$\bar{b}_i = \begin{bmatrix} b_i \\ b_{i-1} \\ b_{i-2} \end{bmatrix},$$

and the vector K^{pid} is given by

$$K^{pid} = [K_D \ K_P \ K_I]^T.$$

The tuning problem is established from the system of equations representing actions of the PID controller in plant dynamics, from the point of view whereby the internal product of the gains and coefficients of the characteristic polynomial is the mechanism for adjusting the gains. The gains of the high-order PID controller are represented by

$$[K_D \ K_P \ K_I] \begin{bmatrix} b_i \\ b_{i-1} \\ b_{i-2} \end{bmatrix} = \left\langle K^{pid}, \bar{b}_i \right\rangle. \quad (19)$$

From Eq. (18), the system of equations that has an unknown vector K^{pid} and design specifications $\bar{a}_i$,

$i = 1, 2, \dots, n + 1$ is assembled. Such an equation system is represented by

$$a_i + \langle K^{\text{pid}}, \bar{b}_i \rangle = \bar{a}_i. \quad (20)$$

This system of equations given in a compact form can be written as

$$\bar{B} K^{\text{pid}} = \bar{e}, \quad (21)$$

where $\bar{e} = [\bar{a}_1 - a_1 \ \dots \ \bar{a}_i - a_i \ \dots \ \bar{a}_{n+1} - a_{n+1}]^T$.

The structured neural network is developed from Eq. (20) to determine the gain vector K^{pid} that satisfies the design specifications. Observing Eq. (20), it is clear that the procedure consisted of calculating the elements of the vector K^{pid} , which needed to satisfy the new parameters $\bar{a}_i$ of the closed-loop transfer function. Solving the equation system, where the number of equations is greater than the number of unknowns ($n > m$), by means of the least squares method, one has

$$\min_{0 < K^{\text{pid}} < \infty} \|e(K^{\text{pid}})\|_2^2, \quad (22)$$

where $e(K^{\text{pid}})$ is an error function that is given by

$$e(K^{\text{pid}}) = \bar{B}^T \bar{B} K^{\text{pid}} - \bar{B}^T \bar{e}. \quad (23)$$

To minimize error in the optimization structure given by (22), the error cost function is assembled from the Euclidean norm of Eq. (23) that is given by

$$\varepsilon(K^{\text{pid}}) = \frac{1}{2} \|\bar{B}^T \bar{B} K^{\text{pid}} - \bar{B}^T \bar{e}\|_2^2. \quad (24)$$

Inspired by the steepest descent method, the solution of this problem is given by the ANN training rule (Ham and Kostanic 2000), which is given by

$$\frac{dK^{\text{pid}}}{dt} = -\mu \nabla \varepsilon(K^{\text{pid}}). \quad (25)$$

The gradient $\nabla \varepsilon(K^{\text{pid}})$ of Eq. (25), which is obtained from the derivatives of Eq. (24), is given by

$$\nabla(K^{\text{pid}}) = \bar{B}^T \bar{B} (\bar{B}^T \bar{B} K^{\text{pid}} - \bar{B}^T \bar{e}). \quad (26)$$

Replacing the gradient of Eq. (26) in Eq. (25), one obtains the training rule equation that governs the computation of the gain vector K^{pid} for the new parameters $\bar{a}_i$ of the characteristic polynomial, which is given by

$$\frac{dK^{\text{pid}}}{dt} = -\mu (\mathbb{A} K^{\text{pid}} - \mathbb{B} \bar{e}), \quad (27)$$




Fig. 4 Topology of structured ANN with PID




Fig. 5 PID-neuro system of the bulk reclaimer process

where $\mathbb{A} = \bar{B}^T \bar{B} \bar{B}^T \bar{B}$ and $\mathbb{B} = \bar{B}^T \bar{B} \bar{B}^T$.

The training algorithm of Eq. (27) determines the parameters $\bar{a}_i$ of the closed-loop transfer function to ensure that the gains K^{pid} are optimal. The control system for the optimal online tuning of the controller's gain parameters using ANN is shown in Fig. 4.

The parallel PID controller takes the form of a connection of elementary neurons that represent the processing of the structure or topology for the computation of the gains, and adjustments to them are guided by the training algorithms. The proposed models are based on supervised learning as shown in Fig. 5.

3.2 PID-Neuro-Fuzzy Model

Figure 6 shows a schematic of the PID-neuro-fuzzy control system for the operation of the BR, where $R(s)$ is the reference value. This was compared with the value measured by the scale $H(s)$, and the difference was error




Fig. 6 PID–neuro-fuzzy system of the bulk reclaimer process

$E(s) = e_1, e_2, \dots, e_i$, which was the input to the controller $K^{pid}(s)$ ($K_D s^2 + K_P s + K_I/s$). Here, e_i and $\dot{e}_i$ are inputs to the fuzzy controller. The output $U(s)$ of the PID controller added to the disturbance $W(s)$ constituted the inputs to the plant, where the plant is represented by the transfer function, and coefficients a_i and b_i of the estimated transfer function $\hat{G}(s)$ are the inputs to the ANN ($\nabla_{K^{pid}} E(K^{pid})$). This is in turn adjusted according to error in the estimator ($\varepsilon = \bar{a}_i - a_i$) to determine the gains of the PID controller.

The PID controller with optimal gains determined by a structured ANN in conjunction with fuzzy gain scheduling control proposed in this work was developed based on the Euclidean norm to act as follows: The proportional action adjusts the output of the controller according to the variation of error; the integral action eliminates the steady-state offset, and future trends are anticipated by derivative action.

4 Experimental Results

The experiments were carried out on a third-order plant using the operation of a BR to validate the PID–neuro and PID–neuro-fuzzy methods presented in this paper, and they were compared with the method proposed by Zhao and Tomizuka in “Fuzzy gain scheduling of PID controllers.”

4.1 Setup

The design initiated with the identification of the estimated model of the plant in terms of the transfer function. In the

sequence, the PID controller was developed with its gains parameters tuned by the second Ziegler–Nichols method. The gains K_P , K_I , and K_D were then calculated using Eqs. (30) and (31). The fuzzy controller was subsequently designed to perform gain scheduling online, and a structured ANN was formulated to determine K_P , K_I , and K_D , and they were replaced by the previous gains. From then on, the fuzzy controller performed gain scheduling online for K'_P , K'_D , and K'_I while maintaining the adaptive system.

4.2 PID–Neuro-Fuzzy Experiments

The PID controller gains were obtained through a structured ANN. A fuzzy system scheduled the gains K'_P and K'_D . In the first instance, the gain K_I determined by the ANN was kept fixed, and the corresponding controller was called PID–neuro-fuzzy 1. In the second instance, K_I determined by the method proposed by Zhao and Tomizuka used in the PID–fuzzy controller was utilized, and it was called PID–neuro-fuzzy 2. The gains of the controllers used here are presented in Table 1.

4.2.1 PID–Neuro-Fuzzy Reference Signal Following

Figure 7 shows the behavior of the plant with the PID controller $\times$ PID–fuzzy controller $\times$ PID–neuro controller $\times$ PID–neuro-fuzzy 1 controller and PID–neuro-fuzzy 2 controller. The PID–neuro controller yielded the best performance, followed by the PID–neuro-fuzzy 2 controller, the PID–neuro-fuzzy 1 controller, the PID–fuzzy controller, and the conventional PID controller tuned by the second Ziegler–Nichols method. The disadvantage of the PID–neuro controller is that it is adjusted offline, whereas the PID–fuzzy, PID–neuro-fuzzy 1, and PID–neuro-fuzzy 2 controllers are self-adjusting.

4.2.2 Rejection of Disturbances

The same disturbance signal as in the plant was applied to the five controllers and analyzed for stability and disturbance rejection behavior. The applied disturbance signal was gradually increased from 0.3 to 0.5, 0.7, and 1. The PID and PID–fuzzy controllers were sensitive to the distur-

Table 1 Controller parameters K^{pid}

Controller	K_P	K_I	K_D	Settling time (s)
PID–ZN	0.08820	0.1175	0.1620	60
PID–Fuzzy	0.09789	0.7484	1.917	30
PID–Neuro	8.6581	4.8104	19.1234	15
PID–Neuro-Fuzzy 1	5.876	4.8104	12.98	15
PID–Neuro-Fuzzy 2	5.876	0.892	12.98	15




Fig. 7 Response to the unit step of the PID controller × controlador PID-fuzzy × PID-neuro-fuzzy 1 controller × PID-neuro-fuzzy 2 controller




Fig. 9 Response to the unit step of the PID controller × PID-fuzzy controller × PID-neuro-fuzzy 1 × PID-neuro-fuzzy 2 after a disturbance signal of 0.5 was applied to the plant




Fig. 8 Response to the unit step of the PID controller × PID-fuzzy controller × PID-neuro-fuzzy 1 × PID-neuro-fuzzy 2 after a disturbance signal of 0.3 was applied to the plant




Fig. 10 Response to the unit step of the PID controller × PID-fuzzy controller × PID-neuro-fuzzy 1 × PID-neuro-fuzzy 2 after a disturbance signal of 0.7 was applied to the plant

bance signal, while the PID-neuro, PID-neuro-fuzzy 1, and PID-neuro-fuzzy 2 controllers were more robust against the disturbance signal applied to the plant, as shown in Figs. 8, 9, 10, and 11.

5 Conclusion

Models for the online tuning of PID controllers based on computational intelligence approaches were presented in this paper. The proposed models are a fusion of an ANN and fuzzy logic. The effectiveness of the proposed method was evaluated on an industrial process. The PID tuning proposal was applied to the operational processes of BRs.

According to the experiment results and analysis, the conventional PID controller tuned by the second Ziegler–Nichols method did not achieve satisfactory results, but its use in industrial processes continues due to its ease of tuning. The PID controller tuned by fuzzy rules obtained a slight improve-




Fig. 11 Response to the unit step of the PID controller × PID-fuzzy controller × PID-neuro-fuzzy 1 × PID-neuro-fuzzy 2 after a disturbance signal of 1 was applied to the plant

ment in performance, whereas the PID controller with gains determined by ANN obtained the best performance, stabi-

lizing at around 15 s with small oscillations in the transient states.

Regarding the trade-offs and future prospects of the proposed method, the control system uses computational intelligence paradigms and a structured ANN to determine the vector of gains K^{pid} , and a fuzzy system to perform the gain scheduling online. In future work, to reduce human interference in the industrial process, the authors plan to integrate the ANN and the fuzzy system into an adaptive algorithm to implement the online and optimal adjustment of gains. The proposed method yielded good performance, in addition to being self-adjusting, where the main advantage of combining the ANN with fuzzy rules, compared with the other evaluated methods, is the ability to reject the disturbances and to adapt to the parametric variations occurring in the plant.

Acknowledgements We thank PGEE of the Federal University of Maranhão for the technical/scientific and practical lessons. We are especially grateful to FAPEMA for encouraging high-level research in the State of Maranhão. We also thank the Department of Physics of the State University of Maranhão for making this research feasible. We thank CAPES for promoting and supporting advanced research that contributed to this work. Finally, the Vale S.A. Company for providing its specialists for practical guidance for the execution of the experiments.

Appendix A: PID Controller Model

The PID controller model $C^{\text{pid}}(s)$ is given by

$$C^{\text{pid}}(s) = K^{\text{pid}}(s), \quad (28)$$

where $K^{\text{pid}}(s) = K_D s^2 + K_P s + K_I/s$.

The open-loop transfer function of the plant is given by

$$G_{\text{BR}}^{\text{OL}}(s) = \frac{K^{\text{pid}}(s) (0.1812s + 0.0871)}{s (s^3 + 0.3553s^2 + 0.1117s + 0.01567)}. \quad (29)$$

According to Table 2, second Ziegler–Nichols method can be used by tuning through the locus roots to find the critical gain K_{cr} and the frequency of oscillations w_{cr} (where $2\pi/w_{\text{cr}} = P_{\text{cr}}$). These values can be found from the points of intersection of the roots with axis jw , according to Fig. 12 (Katsuhiko 2009) (if the roots do not cross the jw -axis, this method does not apply).

The gain $K^{\text{pid}}(s)$ using the second Ziegler–Nichols method is given by

$$K_P = 0.6K_{\text{cr}} = 0.6 \times 1.47 = 0.8820$$

$$P_{\text{cr}} = \frac{2\pi}{w_{\text{cr}}} = \frac{2 \times 3.1416}{0.614} = 10.2332s$$

$$T_I = 0.5 \times 10.2332 = 5.1166s$$

$$K_I = \frac{0.6}{5.1166} = 0.1175$$

Table 2 Ziegler–Nichols tuning rule based on critical gain K_{cr} and critical period P_{cr} (second method)

Type	K_P	T_I	T_D
P	$0.5 K_{\text{cr}}$	∞	0
PI	$0.45 K_{\text{cr}}$	$\frac{1}{1.2} P_{\text{cr}}$	0
PID	$0.6 K_{\text{cr}}$	$0.5 P_{\text{cr}}$	$0.125 P_{\text{cr}}$




Fig. 12 Root locus

$$T_D = 0.125 \times 1.47 = 0.1837s$$

$$K_D = 0.8820 \times 0.1837 = 0.1620$$

$K_{\text{cr}} = 1.47$ and $w_{\text{cr}} = 0.614 \text{ rad/s}$ are identified in Fig. 12.

Appendix B: PID–Fuzzy Model

The control system uses a fuzzy rules-based system to tune the PID controller by scheduling gains. The fuzzy system assumes that K_P and K_D are at prescribed intervals in $[K_{P_{\text{min}}}, K_{P_{\text{max}}}]$ and $[K_{D_{\text{min}}}, K_{D_{\text{max}}}]$, respectively. Inputs to the PID–fuzzy controller are the error (e) and its derivative ($\dot{e}$), and the outputs are K'_P , K'_D , and α , where K'_P and K'_D are the normalized gains in a range of zero to one by means of a linear transformation, and α is a parameter used to calculate the gain K_I .

$$K'_P = \frac{K_P - K_{P_{\text{min}}}}{K_{P_{\text{max}}} - K_{P_{\text{min}}}} \quad (30)$$

$$K'_D = \frac{K_D - K_{D_{\text{min}}}}{K_{D_{\text{max}}} - K_{D_{\text{min}}}}. \quad (31)$$

In the design of the PID–fuzzy system, the parameters of the PID are determined based on current error $e(k)$ and

Table 3 Tuning rules for the outputs K'_P and K'_D from the inputs $e(k)$ and $\dot{e}(k)$

$e(t)$	$\dot{e}(t)$						
	NB	NM	NS	Z0	PS	PM	PB
NB	B/S	B/S	B/S	B/S	B/S	B/S	B/S
NM	S/B	B/B	B/S	B/S	B/S	B/B	S/B
NS	S/B	S/B	B/B	B/S	B/B	S/B	S/B
Z0	S/B	S/B	S/B	B/S	S/B	S/B	S/B
PS	S/B	S/B	B/B	B/S	B/B	S/B	S/B
PM	S/B	B/B	B/S	B/S	B/S	B/B	S/B
PB	B/S	B/S	B/S	B/S	B/S	B/S	B/S

Table 4 Tuning rules for α from the inputs $e(k)$ and $\dot{e}(k)$

$e(t)$	$\dot{e}(t)$						
	NB	NM	NS	Z0	PS	PM	PB
NB	2	2	2	2	2	2	2
NM	3	3	2	2	2	3	3
NS	4	3	3	2	3	3	4
Z0	5	4	3	3	3	4	5
PS	4	3	3	2	3	3	4
PM	3	3	2	2	2	3	3
PB	2	2	2	2	2	2	2

the difference in error $\Delta e(k)$. The integral time constant is determined with reference to the derivation time constant.

The parameters K'_P , K'_D , and K'_I are determined from this set of fuzzy rules:

IF $e(k)$ is A_i and $\Delta e(k)$ is B_i , THEN K'_P is C_i , K'_D is D_i , and $\alpha = \alpha_i$, $i = 1, 2, \dots, m$.

The set of rules used to adjust gains K'_P and K'_D is presented in Table 3, and that used to determine the gain K'_I is displayed in Table 4, where B (big) and S (small) are the membership functions of the big and small sets, respectively. NB is negative big, NM is negative medium, NS is negative small, ZO is zero, PS is positive small, PM is positive medium, and PB is positive big.

References

Alcántara, S., Vilanova, R., & Pedret, C. (2013). PID control in terms of robustness/performance and servo/regulator trade-offs: A unifying approach to balanced autotuning. *Journal of Process Control*, 23(4), 527–542.

Almutairi, N. B., & Zribi, M. (2009). Sliding mode control of a three-dimensional overhead crane. *Journal of Vibration and Control*, 15(11), 1679–1730.

Aström, K. J., & Hägglund, T. (1995). *PID controllers: Theory, design, and tuning* (Vol. 2). Research Triangle Park, NC: Instrument Society of America.

Aström, K. J., & Hägglund, T. (2001). The future of PID control. *Control Engineering Practice*, 9(11), 1163–1175.

Brisilla, R. M., & Sankaranarayanan, V. (2017). Extended state observer-based sliding mode control for multi-input multi-output system with multiple disturbances. *Journal of Control, Automation and Electrical Systems*, 28(1), 11–25.

Castillo-Garcia, F. J., Feliu-Batlle, V., & Rivas-Perez, R. (2013). Frequency specifications regions of fractional-order PI controllers for first order plus time delay processes. *Journal of Process Control*, 23(4), 598–612.

Chang, C.-Y. (2007). Adaptive fuzzy controller of the overhead cranes with nonlinear disturbance. *IEEE Transactions on Industrial Informatics*, 3(2), 164–172.

Chu, Q., Liu, T., & Wang, Y. (2013). Research on excitation controller based on the adaptive fuzzy PID technique. In *5th international conference on intelligent human-machine systems and cybernetics IHMSC, IEEE* (Vol. 1, pp. 297–300).

Cohen, G. H. (1953). Theoretical consideration of retarded control. *Transactions of ASME*, 75, 827–834.

de Moura, J. P., & da Fonseca Neto, J. V. N. (2003). Sistema Especialista para Identificação de Falhas e Tomada de Decisão (Expert System for Fault Identification and Decision Making), Master thesis, UFMA.

de Moura, J. P., & da Fonseca Neto, J. V. (2016a). Modelo de um Controle de Nível de Sólidos em Silos Usando Sistemas Fuzzy Aplicados Em PLC Industrial (Model of a Level Control of Solids in Silos Using Fuzzy Systems Applied in Industrial PLC). CBA (pp. 51–57).

de Moura, J. P., da Fonseca Neto, J. V. (2016b). Fuzzy controller in the cargo control wagons dump. In *IEEE conference on evolving and adaptive intelligent systems (EAIS)* (pp. 10–16).

de Moura, J. P., de Oliveira Serra, L. G., & da Fonseca, J. V. (2013). Logica Fuzzy no Controle de Embarque de Navios no Terminal Marítimo de Ponta da Madeira (Fuzzy Logic in the Control of Shipping of Ships in the Maritime Terminal of Ponta da Madeira). SBAI—Artigo (Article) 4836.

Desborough, L., & Miller, R. (2002). Increasing customer value of industrial control performance monitoring-Honeywell's experience. In *AIChE symposium series*. New York: American Institute of Chemical Engineers (Vol. 326, pp. 169–189).

Dias, C. G., & de Sousa, C. M. (2018). A neuro-fuzzy approach for locating broken rotor bars in induction motors at very low slip. *Journal of Control, Automation and Electrical Systems*, 29(4), 1–11.

Eris, O., & Kurtulan, S. (2011). A new PI tuning rule for first order plus dead-time systems (pp. 1–4). IEEE AFRICON.

Farias, O. S., Santos, J. H. M., & Neto, J. V. F., Labidi, S., Drummond, T., de Moura, J. P. & Neves, S. C. F. (2008). A real time expert system for faults identification in rotary railcar dumpers. In *ICINCO-ICSO* (pp. 347–350).

Garpinger, O. (2015). *Analysis and design of software-based optimal PID controllers*. Department of Automatic Control, Lund Institute of Technology, Lund University.

Golub, G. H., & Van Loan, C. F. (2012). *Matrix computations* (Vol. 3). Baltimore: JHU Press.

Gopi Krishna Rao, P. V., Subramanyam, M. V., & Satyaprasad, K., (2013). Model based tuning of PID controller. In *JoCI* (Vol. 16).

Gopi Krishna Rao, P. V., Venkata, S. M., & Kodati, S. (2015). Robust design of PID controller using IMC technique for integrating process based on maximum sensitivity. *Journal of Control, Automation and Electrical Systems*, 26, 466–475.

- Ham, F. M., & Kostanic, I. (2000). *Principles of neurocomputing for science and engineering*. New York: McGraw-Hill Higher Education.
- Hampel, F. R., Ronchetti, E. M., Rousseeuw, P. J., & Stahel, W. A. (2011). *Robust statistics: The approach based on influence functions* (Vol. 114). New York: Wiley.
- Haykin, S. (1994). *Neural networks: A comprehensive foundation*. Upper Saddle River: Prentice Hall PTR.
- Huber, P. J. (1996). *Robust statistical procedures*. Philadelphia: SIAM.
- Jeng, J.-C. (2015). A model-free direct synthesis method for PI/PID controller design based on disturbance rejection. *Chemometrics and Intelligent Laboratory Systems*, 147, 14–29.
- Kar, B., & Roy, P. (2018). A comparative study between cascaded FOPI–FOPD and IOPI–IOPD controllers applied to a level control problem in a coupled tank system. *Journal of Control, Automation and Electrical Systems*, 29(3), 340–349.
- Katsuhiko, O. (2009). *Modern control engineering* (5th ed.). Prentice-Hall Electrical Engineering Series. Instrumentation and Controls Series.
- Khayamy, M., Chaoui, H., Oukaour, A., & Gualous, H. (2016). Adaptive fuzzy logic control mixing strategy of DC/DC converters in both discontinuous and continuous conduction modes. *Journal of Control, Automation and Electrical Systems*, 27(3), 274–288.
- Lasi, H., Fettke, P., Kemper, H.-G., Feld, T., & Hoffmann, M. (2014). Industry 4.0. *Business & Information Systems Engineering*, 6(4), 239–242.
- Lee, H.-H., Liang, Y., & Segura, D. (2006). A sliding-mode antiswing trajectory control for overhead cranes with high-speed load hoisting. *Journal of Dynamic Systems, Measurement, and Control*, 128(4), 842–845.
- Lee, M., Shamsuzzoha, M., & Vu, T. N. L. (2008). IMC–PID approach: An effective way to get an analytical design of robust PID controller. In *ICCAS international conference on control, automation and systems* (pp. 2861–2866).
- Le, T. A., Kim, G.-H., Kim, M. Y., & Lee, S.-G. (2012). Partial feedback linearization control of overhead cranes with varying cable lengths. *International Journal of Precision Engineering and Manufacturing*, 13(4), 501–507.
- Lopes, B. E., de Moura, J. P., Ribeiro, D. A., e Borges, F. H. C., & de Souza, M. A. (2012). Flow optimization for iron ore reclaiming process. In *ICINCO* (pp. 425–432).
- Mizuyama, D., da Silva, C. E., Goedtel, A., Graciola, C. L., & Palácios, R. H. C. (2018). Neural predictor for surface roughness of turned parts. *Journal of Control, Automation and Electrical Systems*, 29(3), 360–370.
- Murrill, P. W. (1967). *Automatic control of processes*. Scranton: International Textbook Company.
- Ngo, Q. H., & Hong, K.-S. (2012). Sliding-mode antisway control of an offshore container crane. *IEEE/ASME Transactions on Mechatronics*, 17(2), 201–209.
- O'Dwyer, A. (2009). *Handbook of PI and PID controller tuning rules*. Singapore: World Scientific.
- Pai, N.-S., Chang, S.-C., & Huang, C.-T. (2010). Tuning PI/PID controllers for integrating processes with deadtime and inverse response by simple calculations. *Journal of Process Control*, 20(6), 726–733.
- Park, H., Chwa, D., & Hong, K. (2007). A feedback linearization control of container cranes: Varying rope length. *International Journal of Control Automation and Systems*, 5(4), 379–387.
- Parr, E. A. (1998). *Industrial control handbook*. New York City: Industrial Press Inc.
- Pratap, B., & Purwar, S. (2014). Real-time implementation of neuro adaptive observer-based robust backstepping controller for twin rotor control system. *Journal of Control, Automation and Electrical Systems*, 25(2), 137–150.
- Precup, R.-E., & Hellendoorn, H. (2011). A survey on industrial applications of fuzzy control. *Computers in Industry*, 62(3), 213–226.
- Rossomando, F. G., & Soria, C. M. (2015). Design and implementation of adaptive neural-PID for non linear dynamics in mobile robots. In *Institute of electrical and electronics engineers* (pp. 913–918).
- Sanchez, E. N., Becerra, H. M., & Velez, C. M. (2007). Combining fuzzy, PID and regulation control for an autonomous mini-helicopter information sciences. *Information Sciences*, 177(10), 1999–2022.
- Shamsuzzoha, M. (2014). A unified approach of PID controller tuning for time delay processes. In *American Control Conference—ACC. IEEE* (pp. 4865–4870).
- Sun, N., & Fang, Y. (2012). New energy analytical results for the regulation of underactuated overhead cranes: An end-effector motion-based approach. *IEEE Transactions on Industrial Electronics*, 59(12), 4723–4734.
- Verma, S. K., Yadav, S., & Nagar, S. K. (2017). Optimization of fractional order PID controller using grey wolf optimizer. *Journal of Control, Automation and Electrical Systems*, 28(3), 314–322.
- Wang, L.-X. (1993). Stable adaptive fuzzy control of nonlinear systems. *IEEE Transactions on Fuzzy Systems*, 1(2), 146–165.
- Yang, J. H., & Yang, K. S. (2007). Adaptive coupling control for overhead crane systems. *Mechatronics*, 17(2), 143–152.
- Zhao, Z.-Y., Tomizuka, M., & Isaka, S. (1993). Fuzzy gain scheduling of PID controllers. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(5), 1392–1398.
- Ziegler, J. G., & Nichols, N. B. (1942). Optimum settings for automatic controllers. *Transactions of the ASME*, 64(11), 759–768.



Practice article

Online discrete-time LQR controller design with integral action for bulk Bucket Wheel Reclaimer operational processes via Action-Dependent Heuristic Dynamic Programming

José Pinheiro de Moura^{a,*}, Patrícia Helena Moraes Rego^a, João Viana da Fonseca Neto^b

^a UEMA, Brazil

^b UFMA, Brazil

HIGHLIGHTS

- Methodology for optimal online tuning of controllers.
- ADHDP-DLQR controllers with integral action.
- Industrial plant of the ore Bucket Wheel Reclaimer process.
- Measurements of input signals and states during the operational process.
- The parameters of system gains are self-adjustable in real-time.

ARTICLE INFO

Article history:

Received 1 August 2017

Received in revised form 1 April 2018

Accepted 5 January 2019

Available online 30 January 2019

Keywords:

Online design

Optimal control systems

Action dependent heuristic dynamic programming

Bucket Wheel Reclaimer

Discrete Linear Quadratic Regulator

Integral action

ABSTRACT

In this paper, a novel approach for online design of optimal control systems applied to the bulk resumption process by bucket wheel reclaimer (BWR) is presented. This approach is based on reinforcement learning paradigms, more specifically Action Dependent Heuristic Dynamic Programming (ADHDP), that learn online in real-time the Discrete Linear Quadratic Regulator (DLQR) optimal control solution with integral action. Due to the geometric irregularities of the storage yard stacks and variation in physical and chemical characteristics of the stacked material, the flow control of solid bulks by bucket wheel reclaimer requires methods that are suitable with the high degree of imprecision of process variables and environment uncertainties. The resumption of bulk solids is carried out by dividing the stack into layers, each layer is approximately 4 m high, and the layers are divided into workbenches up to 12 m in length. To take up a workbench several translation steps are required (penetration in the stack), with the translation step varying from 0 to 1 m. In order to maintain the desired ore flow throughout the process, the BWR lance speed must be periodically adjusted. The main advantage of the proposed control method is that besides the decision rule is fully independent of plant model, the gains of the resulting controller are self-adjustable. The control system was designed in such a way that the ADHDP-based DLQR controller with integral action would act in real-time in the plant control, using only the input and output signals and states measured along the system trajectory.

© 2019 ISA. Published by Elsevier Ltd. All rights reserved.

1. Introduction

With the increasing complexity of modern industrial processes, control design approaches using the methods of Classic Control, Modern Control, and Robust Control have become insufficient to meet the stringent performance requirements [1–3]. In general, the designs of controllers resulting from these methods have been structured to have lower sensitivity (robustness) to selected

changes in plant or ambient parameter values. While such controllers accommodate certain context changes (plant, environment, goals, and associated performance criteria), this occurs because of margins in controller design, rather than online changes in the design itself.

In a number of industrial applications, the plant dynamics changes so much during the operation that the design of controllers with fixed gains becomes inadequate. An efficient approach to compensate for parameter variations in the process is given in Adaptive Control Theory, where the control designs are performed online and, in fact, based not only on a single point of operation but at different points of operation. The ability to preserve the system performance in the presence of variations in

* Corresponding author.

E-mail address: josepinheiro@professor.uema.br (J.P. de Moura).

plant dynamics, modeling uncertainties, and process disturbances has motivated more researches in the adaptive control field for several practical applications [4–6].

Specifically, the bulk resumption by Bucket Wheel Reclaimer (BWR) is a complex industrial process for dealing with large equipments, which suffer many external interferences, such as wear of mechanical components, imprecision of process variables and variation in physical and chemical characteristics of the material to be handled. Such a process consists of taking up the stored material in stack form of the yard and putting it on conveyor belts to be transported to the ship loader for shipment.

The current flow control via BWR is done by a Proportional and Integral (PI) controller to act directly on the lance speed variation. This controller was designed based on the operator's expertise, which observed by means of instruments installed to measure the electric current intensity of the BWR Bucket Wheel (BW) motor, a very great similarity to the load measured by a dynamic scale installed on the BWR lance, which motivated the conception of a control design based on the signals of the plant sensors. However, a major disadvantage of this controller is that the gain parameters K_p and K_i are determined by a trial and error method. In addition, these parameters are constants, after being determined, if there is variation in the plant dynamics, the control system no longer suits, there being necessary to determine new parameters K_p and K_i to meet the new dynamics.

Adaptive control techniques were developed with the purpose of designing controllers for systems with unknown or uncertain dynamics, using real-time data measured along the system trajectory [7–9]. However, adaptive controllers are not generally designed with the quality of being optimal in the sense of minimizing cost functions as defined in the Optimal Control context [10]. In the case of indirect adaptive control [11], estimation techniques are employed to determine the parameters of the plant model from the input and states measurements of the system and, after the model is obtained, the optimal design equation (Hamilton–Jacobi–Bellman) is solved. As is known, a modeling and identification process for the dynamics of a nonlinear system is often a time-consuming iterative procedure, which requires model design, parameter identification and model validation at each iteration. This approach becomes even less feasible when the system presents non-linear dynamics manifested in certain operational regions.

Optimal control has emerged as one of the fundamental design philosophies of modern control systems design [12]. Optimal control policies satisfy the specified system performance while minimizing a structured cost index which describes the balance between desired performance and available control resources [13]. From a different perspective of control design, several researchers have proposed in the literature approaches that aggregate concepts and methods of optimal control and adaptive control based on Reinforcement Learning (RL) paradigms and Approximate/Adaptive Dynamic Programming (ADP) [14,15]. According to Werbos [16], ADP both can be seen as an extension of adaptive control that, due to the implicit lookahead, achieves stability under much weaker conditions than the well-known forms of direct and indirect adaptive control, but it can also be formulated as an optimal control part that seeks general methods computationally viable for the non-linear stochastic case [17].

The work presented by [18–20] discusses reinforcement learning (Q-learning) as a direct adaptive optimal control approach. Barto, Bradtke and Singh [21] discussed learning schemes based on dynamic programming in order to bring such techniques closer to real-time learning/planning and control theory (mainly optimal control and adaptive control) [21]. A more detailed discussion of optimal adaptive control theory via ADP can be found in the Bertsekas book [22]. Adaptive actor–critic structures are the most popular and probably most efficient RL methods for designing optimal adaptive controllers [15,23–32]. However, the fundamental

structure of adaptive actor–critic can be found in the work of Barto and Sutton [33].

RL is inspired by natural learning mechanisms based on reward and punishment incentives received from the environment [34, 35]. RL implies a relationship of cause and effect between actions and rewards or punishments. This leads to goal-directed behavior, at least insofar as the agent understands the reward versus lack of reward or punishment [36]. RL algorithms are constructed with the premise that effective control decisions should be remembered by means of a reinforcement signal so that they become more likely to be used a second time. The RL method is based on real-time evaluative information from the environment and can be called action-based learning. Thus, the focus of the learning process is focused on a performance index that quantifies how close to the optimality is the closed-loop control system in operation, no longer having as object of interest the system dynamics model.

Variations of critic adaptive designs most common in the literature are the methods of Temporal Differences and Q-learning [37–39]. These, in turn, are classified by Werbos in Heuristic Dynamic Programming (HDP) and Dual heuristic Programming (DHP) [10]. Through the Action Dependent (AD) approach, the HDP and DHP schemes are modified in order to carry out the control strategies without the knowledge of the model that represents the dynamics of the system [40,41].

In this paper we propose a new methodology of optimal control design with integral action which is based on RL and ADHDP principles for the online adaptive tuning of controller parameters according to the plant dynamics. The main advantage of the ADHDP-based optimal control system with integral action is that in addition to achieving better performance, the parameters of system gains are self-adjustable in real-time following the plant dynamics. Another interesting advantage, is that it does not depend on models, only the inputs and states measured directly or indirectly. Many ADP applications can be found in various practical systems, such as missile control [42,43], automotive control [44], aircraft landing control [39,45], autopilot [46] reconfiguration of helicopter after rotor failure [47], power system control [48,49], vehicle steering and speed control [50]. However, for the first time an application in a bulk resumption process by BWR is proposed.

This paper is organized as follows: in Section 2, the ore resumption process and the problem characterization are presented. In Section 3, the fundamentals to assemble the framework of online optimal control design which is supported in Q-Learning and function approximation theory are presented. Section 4 focuses on the methodology of online optimal control system design, which is based on the adaptive critic approach. In this section, the proposed control scheme for the ore resumption process is described, where besides the controller gain being self-adjustable, the decision policy computation is fully independent of plant model. In addition, simulation results that verify the performance of the proposed method are presented in Section 5, and finally in Section 6, the conclusion of the work is presented.

2. Ore resumption process

The ore resumption process consists of taking up the stored material in stacks and transporting it through conveyor belts for shipment. The BWRs have a nominal capacity of 8000 t/h, the operational routes, which are composed of BWRs, Conveyor Belts (CTs) and Ship Loaders (SL) have a nominal capacity of transporting up to 16000 t/h, so two BWRs can do the simultaneous resumption for a 16000 t/hr route or a BWR to do the resumption for a route of 8000 t/hr [51]. The ore resumption is made with large equipment, its structure is constituted of two parts, one fixed and another mobile [52]. On the fixed part the trucks and the translation drives are installed, and on the moving part the lance and the counterweight

are installed, on the tip of the lance is the BW, device that makes the ore resumption [53]. As shown in Fig. 1, to the left a BWR, and to the right the wheel of buckets is highlighted, device that attacks the stack to do the ore resumption.

The three main events that occur during the plant's operational process are presented in the block diagram of Fig. 2. The translation step is the first event to occur and simultaneously the events of BWR lance rotation and BW rotation occur. The events of the BW rotation speed and translation step size are not controlled, the only controlled event is the speed of the BWR lance rotation in the desired flow search. The event of translational step varies from 0 to 1 m and occurs isolated from other events, that is, occurs at the beginning of each stage. A layer to be retaken requires several translation steps, which are the stages, these occur first, and after each stage, the events of the BW rotation and the lance rotation take place simultaneously. The electric current intensity of the BW motor generates a flow estimate, the estimated flow is compared to the flow measured by the scale, and the difference between the estimated flow and the flow measured by the scale is the error. This in turn is handled to ensure the best performance of the system.

2.1. Problem characterization

The ore resumption process by BWR is very complex, because the events occur in a discrete way, that is, an event only has its behavior changed if there is a change in the action of the event. The main events of the ore retaking process are the size of the translation step, the motor electric current of the BW, and the lance rotation speed.

The flow of the ore resumption process is cyclical, starting with the positioning of the machine in the stack where the ore is stored, the definition of the height of the layers, the translation step size, the lance rotation direction and the workbench length to be resumed. This full flow is shown in Fig. 3. The control system is designed to act on the speed of BWR lance rotation, so as to maintain the desired load throughout the resumption process. Such a process is influenced by the translation step size and electric current of the BW motor, i.e., according to the three events shown in Fig. 2.

In the development of the proposed methodology in this paper, the plant model was not used. Such methodology was conceived based on ADHDP approach to design an optimal control law that is estimated online in real-time directly from the data observed along the system trajectories. The data set basically consists of electric current intensity of the BW motor, the lance rotation speed of the BWR measured by an encoder, and the load measured on the scale or resumed volume.

The resumption of ore is done as follows: the stack is divided into n layers and m stands, where L_{ij} represents the layer i th and stand j th, with $i = 1, \dots, n$ and $j = 1, \dots, m$. In Fig. 4 presents a stack with $i = 1, \dots, 20$ and $j = 1, \dots, 5$. The green lines represent the conventional flow of the process, which starts with $q(t)$ load initial, then to the layer L_{11} following a consecutive sequence until reaching the total load stored in the stack $q(T)$. The red lines represent the other possibilities of the flow sequence, i.e. the unconventional flow. In case it is impossible to follow the conventional flow, it is ensured that any decision made is optimal, independent of previous decisions. The controller proposed in this work only acts based on the signals measured by the sensors, without requiring the model of the plant. If the stack has a variation in its physical and chemical characteristics, this will directly affect the measured signals, and based on this information the controller will make the decision.

The data presented in Table 1 refer to the information of the process of resumption of the layer L_{11} (highlighted in Fig. 4), composed of 12 translation steps indicated in column 1 ($S_1, \dots,$

Table 1

Flow behavior in tonnes per hour (t/h) of layer L_{11} in steps (S) of 1 to 12 (S_1 to S_{12}).

L_{11}	I (A)	S_L (m)	G (m/s)	F (t/h)	T(s)
S_1	50	1.00	4.00	5600	40
S_2	65	0.80	4.30	6030	42
S_3	69	0.70	4.50	4840	38
S_4	80	0.60	4.50	6700	41
S_5	78	0.60	4.40	6500	43
S_6	67	1.00	3.90	6500	45
S_7	65	0.80	4.20	7210	43
S_8	75	0.70	4.40	6530	48
S_9	82	0.60	4.50	5340	50
S_{10}	55	0.90	4.50	6510	56
S_{11}	60	1.00	4.40	5200	51
S_{12}	65	1.00	4.30	6150	54

S_2). The average variation of the electric current intensity (A) of the bucket wheel drive is displayed in column 2. In column 3 the length of each translation step (S) is illustrated. Column 4 shows the average variation of the speed of rotation of the BWR lance (G). The remaining information is the flow of the resumed load (F) and the step-up time (T) shown in columns 6 and 7 respectively. Such data was used for getting a process simulator for the ADHDP-based optimal control design purpose. Here it is presented only for one layer, the same procedure was followed for the other layers. The presented data was collected during twelve stages of the process of picking up a layer, with sampling interval of 0.005 s. The plant was instrumented with an ammeter to measure the electric current variation of the BW motor, two encoders, one to measure the translation step size and the other to measure the BWR rotation speed, and a dynamic scale to measure the hourly flow of ore in tons per hour. In the control logic a timer to count the time of each stage was inserted. All mentioned sensors were registered in a Plant Information Management System (PIMS) to collect online data.

The data references obtained in columns two and five of Table 1 were used to generate Fig. 5. Note that the behavior of the data of the BW engine electric current with that of the ore flow data exhibited the same behavior. The curve in blue represents the ore flow in tons per hour, and the curve in red represents the electric current intensity of the bucket wheel motor during the ore resumption process. It was also observed that the flow variation is proportional to the variation of BWR lance rotation speed. With that in mind, the control system was conceived to act directly on the speed control of the BWR lance rotation.

In the event of a failure to raise the BWR lance or other disturbance in the system, one must choose the best way to take up the ore, so that the operational performance is not affected, maintaining the desired flow.

Note that the stacks do not have uniform geometric shapes and have non-linear functions, thus the mathematical model is very complex. The volume is considered to be a state and the function that describes the effective rate obtained with the BWR operation defines the relationship between the current and future states which is the state transition function.

For a better understanding of the problem presented in this work, the following states and process variables are considered: A is the electric current of the BW drive motor; S is the size of the translation step; G is the lance rotation speed; F is the load flow in tons per hour; and T is the resumed load (volume).

3. Q-learning

The conception of Action Dependent Heuristic Dynamic Programming (ADHDP) for the design of linear quadratic regulators [54,55] is based on input and state signals gathered online



Fig. 1. Bucket wheel reclaimer.




Fig. 2. Block diagram of the ore resumption process.

from the plant. The action-dependent heuristic dynamic programming is grounded on the Q -learning, which will be denoted by Q_L , and consists of a method for estimating the Q_L function for any optimal or non-optimal policy [56] and [57]. The ADHDP formulation only requires samples from the instantaneous reward function r [58]. The ADHDP approach is presented in two instances. Firstly, the Q_L is formulated in terms of the Bellman equation and forms of optimal decision policy [59]. Secondly, the Q_L function approximation to get the optimal control policy is approached.

The control policy is given by the mapping $g : X \rightarrow U$ that produces the action u to be taken at every time step k , where X is the state space and U is the control action space. For a given control policy $g(x) = u$, the action-value function $Q_L^g : X \times U \rightarrow \mathbb{R}$ is given as the discounted sum of long term rewards obtained when starting from a given state x , taking a given action u , and using g to generate future actions

$$Q_L^g(x, u) = \sum_{k=0}^{\infty} \gamma^k r(x_k, u_k), \quad (1)$$

where γ is the discount factor that is defined in $0 \leq \gamma \leq 1$. In the form of the Bellman equation, it follows that the action-value function, Eq. (1), is given by

$$Q_L^g(x, u) = r(x, u) + \gamma Q_L^g(f(x, u), g(f(x, u))), \quad (2)$$

where f is the state transition function (dynamic system model).

According to Bellman optimality equation, the optimal action-value function, denoted by Q_L^* , must satisfy

$$Q_L^*(x, u) = r(x, u) + \gamma Q_L^*(f(x, u), g^*(f(x, u))) \quad (3)$$

The right-hand side of Eq. (2) is used as the target value to approximate Q_L by a parameterized model

$$d(r, f, g(f), \theta) = r(x, u) + \gamma Q_L(f(x, u), g(f(x, u)), \theta) \quad (4)$$

The squared errors between the estimated value $Q_L(x, u, \theta)$ and measured value $d(\cdot)$ are minimized, in view of improving through the greedy policy the optimal estimate of parameters. The new parameters yield new targets, so the process is computationally realizable.

$$\theta_{j+1} = \arg \min_{\theta} E \left\{ |Q_L(x, u, \theta) - d(r, f, g(f), \theta_j)|^2 \right\}, \quad (5)$$

where $E(\cdot)$ denotes the expected value.

The greedy iteration is the policy used for determining the optimal Q_L -function. The policy is parameterized as $g(x) = g(x, u)$. The control law is obtained by the Bellman optimality equation for the Q_L -function, Eq. (3), which is given by

$$u^* = g^*(x) = \arg \max_u Q_L^*(x, u). \quad (6)$$

Such policy allows for the determination of optimal policies making no reference to a environment model f .




Fig. 3. Flowchart of the resumption process.




Fig. 4. Flow of one resumption of a stack.




Fig. 5. Behavior of bucket wheel motor electric current x ore flow during the resumption in the five initial layers of a stack.

4. DLQR based on sensors

This section presents the basis for the construction of a methodology based on the DLQR for a model independent control system.

4.1. DLQR parameterization

For the DLQR, one has that the parameterized functions are classified in parameters Q_L and R of the instantaneous cost (utility function) and in the parameters A and B of the dynamic system (environment). The parameterizations of the environment are given by the dynamic system that is represented by

$$f(x, g(x)) = A_d x + B_d u, \quad (7)$$

where $A_d \in \mathbb{R}^{n \times n}$, n is the order of the system, $B_d \in \mathbb{R}^{n \times n_e}$ and n_e is the number of system inputs. The control policy, formed from the linear combination of states, is given by

$$g(x) = -K(\cdot)x, \quad (8)$$

where $K(\cdot) \in \mathbb{R}^{n_e \times n}$ is the matrix of state feedback gains.

The parameterization of the instantaneous cost is the utility function in k , representing the state deviations and the control

policy energy in $k - 1$ for the state in k , which is given by

$$r(x, u) = x^T Q x + u^T R u, \quad (9)$$

where $Q_L \in \mathbb{R}^{ne \times ne} \geq 0$ is the state weighting matrix and $R \in \mathbb{R}^{n \times n} > 0$ is the control weighting matrix.

The parameterization of the utility function of Eq. (9) is replaced in Eq. (1) to obtain the parameterized DLQR cost function, where the control policy is given by a constant feedback gain matrix K , Eq. (8), [60]. The optimal solution of the cost Q_L of Eq. (2) is a quadratic form which is given by

$$Q_L(x, u) = \begin{bmatrix} x \\ u \end{bmatrix}^T \begin{bmatrix} H_{xx} & H_{xu} \\ H_{ux} & H_{uu} \end{bmatrix} \begin{bmatrix} x \\ u \end{bmatrix} \triangleq z^T H z \quad (10)$$

where $H_{xx} = Q + \gamma A_d^T P A_d$, $H_{xu} = \gamma A_d^T P B_d$, $H_{ux} = \gamma B_d^T P A_d$, $H_{uu} = R + \gamma B_d^T P B_d$, for some matrix $P \in \mathbb{R}^{n \times n} > 0$, and $z^T = [x^T \ u^T]$.

The minimization of the parameterized Q_L function provide the means for determining the optimal policy u . The gradient $\partial Q_L / \partial u$ is given by

$$\frac{\partial Q_L}{\partial u} = \frac{\partial}{\partial u} \begin{bmatrix} x \\ u \end{bmatrix}^T \begin{bmatrix} H_{xx} & H_{xu} \\ H_{ux} & H_{uu} \end{bmatrix} \begin{bmatrix} x \\ u \end{bmatrix} \quad (11)$$

The gradient equation $\partial Q_L / \partial u = 0$, when solved for u , provides the optimal policy. Consequently, the optimal control is given by

$$u = -H_{uu}^{-1} H_{ux} x = K(H)x \quad (12)$$

The quadratic form of the optimal cost, Eq. (10), is approximated by a transformation that uses the *Kronecker* product for obtaining a linear equation system in Q_L . By applying the *Kronecker* product and vectorizations definitions [61–63], one has that the optimal cost value is represented by

$$Q_L^K(x_k, u_k) = z_k^T H^K z_k = \bar{z}_k^T \text{vec}(H^K), \quad (13)$$

where $\text{vec}(H^K)$ is the vectorization of the learning matrix H^K , and $\bar{z}_k \in \mathbb{R}^{(n+n_e)(n+n_e+1)/2}$ is defined according to the *Kronecker* product that is given by

$$\bar{z}_k^T = z_k^T \otimes z_k^T = [x_{1k} z_k^T \ \dots \ x_{nk} z_k^T \ u_{1k} z_k^T \ \dots \ u_{n_e k} z_k^T] \quad (14)$$

The function $\text{vec}(H^K) \in \mathbb{R}^{(n+n_e)(n+n_e+1)/2}$ is a vector containing the $n + n_e$ diagonal elements of the matrix H^K and the $\frac{(n+n_e)(n+n_e+1)}{2} - n$ non-repeated sums $H_{ij}^K + H_{ji}^K$.

Replacing the vectorization of Eq. (13) in Bellman equation (2), in terms of instantaneous reward for the DLQR design, one obtains the relation for reward estimation that is given by

$$r(x_k, u_k) + \gamma \bar{z}_{k+1}^T \text{vec}(H^K) = \bar{z}_k^T \text{vec}(H^K) = \phi_k^T \theta^K \quad (15)$$

4.2. Online optimal control design

This section presents the development of the methodology of ADHDP-based DLQR control with integral action (IA) for the optimization and adaptation of the ore flow control design. That methodology is referred to as ADHDP-DLQR-IA method, which is the junction of the ADHDP, DLQR, and IA approaches. The control design was conceived taking into account possible plant dynamics variations which may change the system operation point, since conventional PI controllers do not meet satisfactorily all the aspects of the plant dynamic variation. Since such controllers have been tuned by a trial and error method, making it difficult to determine new gain parameters K_p and K_i every time the plant dynamic goes through variations.

The ADHDP-DLQR-IA method was implemented to guarantee the optimal control of the plant. While the proposed controller acts on the plant dynamics assuring optimality of the system performance, integral action acts to reduce the steady-state error.

The ADHDP-DLQR-IA method assures the convergence of all controlled variables. In this control design, the RLS method is used to estimate the parameters of the DLQR cost function [64]. Next, the mathematical description of the ADHDP-DLQR-IA method applied to the ore resumption process via BWR is presented.

4.2.1. Formulation of ADHDP-DLQR-IA method

Let the plant be represented by

$$x_{k+1} = A_d x_k + B_d u_k \quad (16)$$

$$y_k = C_d x_k, \quad (17)$$

where $x_k \in \mathbb{R}^n$ is the state, $u_k \in \mathbb{R}^{n_e}$ is the control input, and $y_k \in \mathbb{R}^{n_s}$ is the output.

In order to formulate the performance of the ADHDP-based DLQR system with integral action, a new state variable based on measurements is defined by

$$\varepsilon_k = \varepsilon_{k-1} + u_{ref} - y_k, \quad (18)$$

where u_{ref} is the reference input. The Eq. (18) is added to reduce steady-state errors corresponding to the accumulated regulation error for the output y_k .

By simple algebraic manipulations, one obtains the representation in the state space for entire system

$$\begin{bmatrix} x_{k+1} \\ \varepsilon_{k+1} \end{bmatrix} = \begin{bmatrix} A_d & 0 \\ -C_d A_d & 1 \end{bmatrix} \begin{bmatrix} x_k \\ \varepsilon_k \end{bmatrix} + \begin{bmatrix} B_d \\ -C_d B_d \end{bmatrix} u_k + \begin{bmatrix} 0 \\ 1 \end{bmatrix} u_{ref}. \quad (19)$$

A diagram of the proposed control system is shown in Fig. 6, comprising the actor and critic blocks that perform the evaluations and improvements of the decision policies. An integrator is inserted into the control loop so that the control law is given by [65]

$$u_k = -K x_k + K_i \varepsilon_k = - \begin{bmatrix} K & -K_i \end{bmatrix} \begin{bmatrix} x_k \\ \varepsilon_k \end{bmatrix}, \quad (20)$$

where $\tilde{K} = \begin{bmatrix} K & -K_i \end{bmatrix}$ is a block matrix of gains, made up of the matrices of feedback gain K and integral gain K_i .

Now the optimal control policy is parameterized by the linear relation of the states x_k and ε_k

$$u_k = \tilde{K}(\tilde{H}) \tilde{x}_k, \quad (21)$$

where $\tilde{K}(\tilde{H}) = -\tilde{H}_{uu}^{-1} \tilde{H}_{ux}$, and $\tilde{H}_{uu}$ and $\tilde{H}_{ux}$ are matrix blocks of the expanded learning matrix $\tilde{H}$ which is associated with the value function defined by

$$\tilde{Q}_L(\tilde{x}_k, u_k) = \tilde{z}_k^T \tilde{H} \tilde{z}_k, \quad (22)$$

where $\tilde{x}_k^T = [x_k^T \ \varepsilon_k^T]$ and $\tilde{z}_k^T = [\tilde{x}_k^T \ u_k^T]$.

Thus, the control problem is reduced to find the matrix $\tilde{K}$ so that the value function $\tilde{Q}_L$ is minimized. The estimation of parameters of the function $\tilde{Q}_L$ is based on the same iterative scheme presented in Eq. (15) for estimating the function Q_L , so in the policy evaluation step one has the following parametric structure

$$\bar{z}^T \tilde{z}_{k+1} = \bar{z}^T d(\tilde{z}, \tilde{r}, g(f, \varepsilon), \tilde{K}^\theta), \quad (23)$$

where $d(\cdot)$ is the value function model for the whole system which is given by

$$d(\tilde{z}, \tilde{r}, g(f, \varepsilon), \tilde{K}^\theta) = \tilde{x}_k^T \tilde{Q} \tilde{x}_k + u_k^T \tilde{R} u_k + \tilde{z}_{k+1}^T \tilde{H} \tilde{z}_{k+1} \quad (24)$$

The updates of the parameter $\tilde{H}$ of the value function as well as the parameter $\tilde{K}$ of the control policy are simply based on information that comes from interaction between the actor (controller) and the process (plant) and includes observations of the states x_k and ε_k , control actions u_k , and instantaneous costs $\tilde{r}_k$.




Fig. 6. Control system with critic actor learning applied to the bulk reclaimer process.

For the BWR plant in particular, the control system has state variables x_k corresponding to x_1, x_2 , and x_3 , where x_1 is the electric current of the BW motor measured by an ammeter, x_2 is the lance rotation speed of the BWR measured by an encoder, x_3 , that is equal to y_k , is the load measured by a dynamic scale installed in the BWR lance, u_k is the electric frequency f_k (Hz) of the lance rotation engine measured by the frequency inverter, and Δ is the delay operator.

4.2.2. ADHDP-DLQR-IA Algorithm

The main steps for determining the optimal control policy are presented in following Algorithm, called ADHDP-DLQR-IA Algorithm. In this algorithm, a recursive least-square implementation is used to find $vec(\tilde{H})$. In this case, the algorithm has a persistence resetting (state revitalization condition) due to problems of null state that lead to the regression matrix with null rank. In such case, the revitalization is applied at the end of each revitalization interval n_{revit} as can be seen in first block the algorithm.

For a better understanding, the algorithm is divided into two blocks, as shown in Fig. 7.

The blocks of the algorithm with the respective steps shown in Fig. 7 are described below

(1) First block — Iterative process parameters and initial conditions: In the first block, the initial conditions and the iterative process parameters for the configuration of the algorithm are defined.

- 1 ▷ Setup (Iterative process parameters and initial conditions)
- 2 ▷ Weighting and Dynamic System Matrices: $\tilde{Q}, \tilde{R}, A_d, B_d$
- 3 ▷ Discount Factor: $0 < \gamma \leq 1$
- 4 ▷ RLS Parameters: μ, Φ_0, θ_0
- 5 ▷ State Resetting: $x_{revit}, \varepsilon_{revit}$
- 6 ▷ Initial States: x_0, ε_0
- 7 ▷ Initial Values of $\tilde{H}, \tilde{K}$: $\tilde{H}_0$ and $\tilde{K}_0 = [K_0 \ K_{I0}]$
- 8 ▷ Number of Iterations: N
- 9 ▷ $m \leftarrow n + n_e$
- 10 ▷ $n_\theta \leftarrow \frac{(n+n_e)(n+n_e+1)}{2}$
- 11 ▷ $n_{revit} \leftarrow n_\theta$

(2) Second block — Iterative process: The second block of the ADHDP-DLQR-IA algorithm implements the updates of the value function in step (b) (target assembling) as well as the regression vector (Kronecker product) in step (c) for each reading of the samples of state transition. It also implements the updates of the parameter θ vector in step (d), the matrix $\tilde{H}$ recovery from vector θ in step (e) and the gain computing $\tilde{K}$ in step (f).




Fig. 7. Algorithm blocks.

- 1 ▷ Iterative Process
- 2 for $\leftarrow 0:N$
- 3 do

(a) Simulator: in this step the simulations of state and input signals measured by sensors are carried out.

- 1 ▷ Environment Simulation
- 2 Implementation of Control Noise
- 3 $\xi_i \leftarrow []$
- 4 Control Action
- 5 $u_{(i, i)} = -K_i x_{(i, i)} + K_{I_i} \varepsilon_i + \xi_i$
- 6 ▷ States
- 7 $x_{i+1} \leftarrow A_d x_{(i, i)} + B_d u_i$
- 8 $\varepsilon_{i+1} \leftarrow \varepsilon_i + u_{ref} - C_d x_{(i, i+1)}$
- 9 $\tilde{x}_{(i, i)} \leftarrow [x_{(i, i)}; \varepsilon_{(i, i)}]$

(b) Target Assembling: in this step the target that will be used as objective function in the RLS estimation is assembled.

- 1 ▷ Target Assembling
- 2 $d_i \leftarrow \tilde{x}_{(i)}^T \tilde{Q} \tilde{x}_{(i)} + u_i^T \tilde{R} u_i + [\tilde{x}_{(i)}, i+1; \tilde{K} \tilde{x}_{(i)}, i+1]^T \tilde{H} [\tilde{x}_{(i)}, i+1; \tilde{K} \tilde{x}_{(i)}, i+1]$

(c) Kronecker Product: in this step the state variables Kronecker product is realized.

- 1 ▷ Basis Set — Kronecker Product
- 2 $\tilde{z}_{(i)} \leftarrow \begin{bmatrix} \tilde{x}_{(1,i)}^2; \tilde{x}_{(1,i)} \tilde{x}_{(2,i)}; \tilde{x}_{(1,i)} \tilde{x}_{(3,i)}; \tilde{x}_{(1,i)} \tilde{x}_{(4,i)} \tilde{x}_{(1,i)} u_i; \\ \tilde{x}_{(2,i)}^2; \tilde{x}_{(2,i)} \tilde{x}_{(3,i)}; \tilde{x}_{(2,i)} \tilde{x}_{(4,i)}; \tilde{x}_{(2,i)} u_i; \\ \tilde{x}_{(3,i)}^2; \tilde{x}_{(3,i)} \tilde{x}_{(4,i)}; \tilde{x}_{(3,i)} u_i; \\ \tilde{x}_{(4,i)}^2; \tilde{x}_{(4,i)} u_i; u_i^2 \end{bmatrix}$

(d) RLS Search: in this step the updates of RLS parameters are carried out.

- 1 ▷ Vector Updating θ_i through the Recursive Least Squares (RLS)
- 2 $\varphi \leftarrow \tilde{z}_{(i), i}$
- 3 $e \leftarrow d_i - \varphi^T \theta$
- 4 $\theta_{i+1} \leftarrow \theta_i + ((\Phi_i \phi_i)/\mu + \phi_i^T \Phi_i \phi_i) e$
- 5 $\Phi_{i+1} \leftarrow (1/\mu)[\Phi_i - (\Phi_i \phi_i \phi_i^T)/(\mu + \phi_i^T \Phi_i \phi_i)]$

(e) Matrix $\tilde{H}$ Recovery from Vector θ : in this step the association of the vector θ with the matrix $\tilde{H}$ is realized.

$$1 \quad \tilde{H} \leftarrow \begin{bmatrix} \theta_1 & \theta_2/2 & \theta_3/2 & \dots & \theta_m/2 \\ \theta_2/2 & \theta_{m+1} & \theta_{m+2}/2 & \dots & \theta_{2m-1}/2 \\ \theta_3/2 & \theta_{m+2}/2 & \theta_{2m} & \dots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \theta_{n_\theta-1}/2 \\ \theta_m/2 & \theta_{2m-1}/2 & \dots & \theta_{n_\theta-1}/2 & \theta_{n_\theta} \end{bmatrix}$$

(f) Optimal Feedback Gain Computing: finally, in this step the feedback optimal gain is updated.

- 1 ▷ Optimal Feedback Gain $\tilde{K}$
- 2 $\tilde{K}_{i+1} \leftarrow H_{uu}^{-1} \tilde{H}_{ux}$

(g) State Resetting: in this step the revitalization of the states is carried out to bypass problems of null state that lead to regression matrix with null rank. The revitalization is applied to each interval n_{revit} .

- 1 if $\text{mod}(i, n_{revit}) = 0$
- 2 $x_{(i,i+1)} \leftarrow x_{revit}$
- 3 $\varepsilon_{(i,i+1)} \leftarrow \varepsilon_{revit}$
- 4 End (Iterative Process)

5. Experimental results

The experiments are performed to evaluate the optimal policy of Eq. (21) that is obtained without direct computation of the HJB equation solution. The realization of the ADHDP strategy is guided by online ADHDP-DLQR-IA algorithm presented in Section 4.2.2. For such an algorithm, the gain computation $\tilde{K}$ is performed in two steps: (a) the HJB solution for the $\tilde{Q}_L$ function, and (b) the optimal policy $\tilde{K}_{ADHDP}^{final}$.

The performance of the proposed controller is evaluated for the operational process of an iron ore reclaimer, which is a large equipment (Fig. 1), according to the mechanical arrangement of a BWR shown in Fig. 8, highlighting its main components and its dimensions (20000t mass, 102 m length, 36 m high and 22 m wide). The controller using the ADHDP-DLQR-IA method acts on the speed variation of the lance rotation, with a maximum value of 4.5 m/s,




Fig. 8. Mechanical arrangement of BWR.

since the speed is relatively high for the mass to be moved, this speed variation cannot be too abrupt.

The results obtained by the ADHDP-DLQR-IA algorithm applied to the operational process of an ore reclaimer were analyzed according to the convergence of their parameters with the solution of the Schur method (true), where it was possible to observe the convergence of all elements of the matrix $\tilde{H}_{ADHDP}$ and the gains vector $\tilde{K}_{ADHDP}$ for the elements of matrix $\tilde{H}_{Schur}$ and the gains vector $\tilde{K}_{Schur}$, respectively.

5.1. Simulations setup

The setup of the ADHDP-DLQR-IA Algorithm consists of the information that is related to the dynamic system parameters, instantaneous reward weightings, initial conditions and iterative process parameters as presented in the first block of the ADHDP-DLQR-IA algorithm. That information is established having as reference the designer's empiricism or the relationships among system variables related to the methods, and it consist of the following elements: discrete model matrices (A_d , B_d), state and control weighting matrices ($\tilde{Q}$, $\tilde{R}$), sampling time t_{samp} , discount factor λ , initial conditions of the controller gain $\tilde{K}$ and matrix $\tilde{H}$ parameter estimates (K_0 , K_{l_0} , $\tilde{H}_0$), system initial conditions (x_0 , ε_0), and number of iterations N . As to the RLS estimator, one has: state revitalization interval n_{revit} with respect to the persistent excitation condition, initial conditions (Φ_0 , θ_0), forgetting factor μ , and state revitalization (x_{revit} , ε_{revit}). The values for all the cited elements are shown in Appendix A.

5.2. Optimal control law estimation

The optimal values of the parameters $\tilde{H}$ and $\tilde{K}$ by Schur method [66] are compared with those obtained from the ADHDP approach. These values are used to evaluate the accuracy of the approximate solutions by ADHDP, taking into account that the Schur values are the true values. The Schur solution is given by

$$\tilde{H}_{Schur} = \begin{bmatrix} 4.7041 & 1.4787 & 0.4637 & 3.0962 & -0.1460 \\ 1.4787 & 2.3612 & 0.2310 & 1.3292 & -0.0813 \\ 0.4637 & 0.2310 & 1.7220 & 0.2873 & -0.0657 \\ 3.0962 & 1.3292 & 0.2873 & 2.6337 & -0.1034 \\ -0.1460 & -0.0813 & -0.0657 & -0.1034 & 0.1068 \end{bmatrix} \quad (25)$$




Fig. 9. Convergence behavior of the parameters θ_1 , θ_2 and θ_3 for the BWR operational process.




Fig. 10. Convergence behavior of the parameters θ_4 , θ_5 and θ_6 for the BWR operational process.

$$\tilde{K}_{Schur} = \begin{bmatrix} -1.3663 & 0.7608 & -0.6151 & -0.9674 \end{bmatrix} \quad (26)$$

The evolution of the iterative process for parameter θ estimation is presented in Figs. 9–13 for a cycle of 200 iterations in the sense of sensor samples, with sampling interval of 1 s. The curves of Figs. 9–13 represent the convergence behavior of the components θ_i , $i = 1, 2, \dots, 15$, of the parameter vector θ corresponding to the elements of matrix $\tilde{H}^\theta$. It is observed that all the components of the parameter vector θ reached the steady state around 200 iterations at most. The convergence of all the parameters θ in a smaller variation of the hourly flow of ore and consequently a larger productivity of the plant, that is the volume resumption by time of operation machine.

The steady-state solution associated with the parameter θ evolution of Figs. 9–13 is given by

$$\tilde{H}_{\infty}^{ADHDP} = \begin{bmatrix} 4.7041 & 1.4787 & 0.4637 & 3.0962 & -0.1460 \\ 1.4787 & 2.3612 & 0.2310 & 1.3292 & -0.0813 \\ 0.4637 & 0.2310 & 1.7220 & 0.2873 & -0.0657 \\ 3.0962 & 1.3292 & 0.2873 & 2.6337 & -0.1034 \\ -0.1460 & -0.0813 & -0.0657 & -0.1034 & 0.1068 \end{bmatrix} \quad (27)$$

$$\tilde{K}_{\infty}^{ADHDP} = \begin{bmatrix} -1.3663 & 0.7608 & -0.6151 & -0.9674 \end{bmatrix} \quad (28)$$

The behavior of the parametric estimation process of the optimal gains are presented in Figs. 9–13, where it was possible to observe the settling time, process severity and overshoot. The convergence of the parameters θ_i of the matrix $\tilde{H}_{\infty}^{ADHDP}$ to the parameters of the Schur solution $\tilde{H}_{Schur}$ took place around 180 s. At 120 s, however, a convergency tendency of all analyzed parameters is observed. One can also observe a smooth behavior of the transitory states, not showing problems of possible losses of the system stabilization trajectories.

The comparison of steady-state value given by Eq. (27) with the Schur solution of Eq. (25) shows a good accuracy in the ADHDP approximation, showing that the RLS-based ADHDP estimator is consistent. Taking into account that the ADHDP and RLS fusion reaches the unbiased estimator, the convergence can be improved




Fig. 11. Convergence behavior of the parameters θ_7 , θ_8 and θ_9 for the BWR operational process.

in terms of adjustments in the RLS parameters of ADHDP-DLQR-IA algorithm.

From the viewpoint of control systems, we show the trajectory of the states x_k and the control signal u_k that was applied to the system in tuning the ADHDP parameters for the third order model (Ore Replacer) for effect of the analysis of the ADHDP-DLQR-IA algorithm performance. The behaviors of the system states x_k and ε_k for third order model are presented in Fig. 14. In order to maintain the excitation condition of the recursive least squares problem, the state resetting is performed with $\tilde{x}_{revit} = [4 \ 2 \ 5 \ 10]^T$, after each recurrence interval, to avoid singularity problems with the regressor matrix $\Gamma = \Phi^{-1}$. It is observed that the revitalization of the states and the system error during the duration of the experiment for the ADHDP-based DLQR design are excited around zero.

The behavior of the control signal u_k associated with the noise signal n_k is shown in Fig. 15. It is observed that the control efforts




Fig. 12. Convergence behavior of the parameters θ_{10} , θ_{11} and θ_{12} for the BWR operational process.




Fig. 13. Convergence behavior of the parameters θ_{13} , θ_{14} and θ_{15} for the BWR operational process.

oscillate after being revitalized, reacting abruptly to meet the design specifications in face of variations in the process dynamics.

The designer must bear in mind the state resetting problems. This can be seen as a problem of biased observations that comes from the plant along the data acquisition, that is, the relation between the estimator computation and sensor observations leads to linear dependence situation in the autocorrelation matrix.

5.3. Control process results

The results of the ore reclaimer process are presented and analyzed from the control viewpoint in two instances. Firstly, the controller performance is evaluated without taking into account random disturbances in the plant states. Secondly, rejection to random disturbances on the system is tested.

5.3.1. Control target evaluation

The associated eigenvalues are presented in Fig. 16, representing the influence of each eigenvalue in matrix trace of closed loop




Fig. 14. System states and error trajectories with revitalization for the duration of the experience for the BWR operational process.




Fig. 15. Control signal with noise for the BWR operational process.

matrices for the iterative process. In terms of control target, the closed loop traces and the associated eigenvalues show oscillations that represent the stability behavior of the dynamic system globally (during the search process of optimal control policy). The traces can be seen as a good metric to evaluate the convergence of the algorithm and to guide computational intelligence heuristics in order to evaluate the convergence without computing the eigenvalues of the closed loop system, avoiding eigenvalues computation in real-time applications, due to its high cost.

The behavior of the gain matrix is presented in Fig. 17, where the steady state of the estimated value of K is reached around 200 iterations, illustrating the evolution of the ADHDP-DLQR-IA algorithm with respect to the gain vector $\tilde{K}_{\infty}^{ADHDP}$ converging to the optimal gain vector $\tilde{K}_{Schur}$, having its components represented by dashed lines. It is important to emphasize, observing Fig. 17, that the first policy update is performed after 30th iteration, due to the necessary condition of initialization of ADHDP-DLQR-IA algorithm




Fig. 16. The trace behavior and the associated eigenvalues of the closed loop model.




Fig. 18. Convergence behavior of the parameters θ_1 , θ_2 and θ_3 with disturbance signal on the plant for the BWR operational process.




Fig. 17. ADHDP-DLQR-IA controller gains for the BWR operational process.




Fig. 19. Convergence behavior of the parameters θ_4 , θ_5 and θ_6 with disturbance signal on the plant for the BWR operational process.

based on the Kronecker product, Eq. (14). The revitalization of the states is performed after each 30 recurrence interval.

5.3.2. Disturbance rejection evaluation

In order to evaluate the robustness of the control system with respect to rejection to disturbances on the plant, a random disturbance vector was inserted by varying the conditions of the plant states, simulating the physical variations of the ore stack, which influences the time flow behavior of the recovered load. From Figs. 18–22 it can be seen that the system behaved satisfactorily even with disturbance in the plant, both for the parametric evaluations and for the control results. That is, after the disturbance, the system tends to follow the optimal solution (Schur method). All the components of the matrix $\tilde{H}_{ADHDP}$ and the vector $\tilde{K}_{ADHDP}$ have tended toward the convergence of the matrix $\tilde{H}_{Schur}$ and to the vector $\tilde{K}_{Schur}$.

The vector of gains $\tilde{K}_{ADHDP}$ after the inserted disturbance in the plant, oscillated around the optimal (true) solution. Therefore, the ADHDP-DLQR-IA algorithm, in addition to guaranteeing an optimal solution, guarantees robustness to disturbance signals and parametric variations of the plant, as Fig. 23.

5.3.3. Evaluation of the ADHDP-DLQR-IA method

To evaluate the efficiency of controller tuning by the ADHDP-DLQR-IA method, the comparison was made with controllers tuned by the following methods: PID tuned by the second Ziegler–Nichols method, PID tuned by fuzzy rules and sliding mode control (SMC).

The performance of the behavior of step response of the controllers were compared, where it was possible to observe the evolution of the performances of the analyzed methods. The controller tuned by the ADHDP-DLQR-IA method, obtained a faster convergence with the reference value meeting the design specifications. Note that the reference load of 8000 t/h was achieved faster and with small Fig. 24.

The performance of the impulse response behavior of the controllers was also compared, where it was observed that the controller tuned by the ADHDP-DLQR-IA method obtained lower overshoot, shorter settling time and greater robustness to the disturbances (see Fig. 25).




Fig. 20. Convergence behavior of the parameters θ_7 , θ_8 and θ_9 with disturbance signal on the plant for the BWR operational process.




Fig. 21. Convergence behavior of the parameters θ_{10} , θ_{11} and θ_{12} with disturbance signal on the plant for the BWR operational process.

The parameters used in the plant model without controller and the ADHDP-DLQR-IA method are displayed in the [Appendix A](#). The parameters of the PID-ZN, PID-Fuzzy models are presented in the [Appendix B](#). Finally, the SMC parameters are presented in the [Appendix C](#).

6. Conclusion

According to the results in simulated experiments of the ADHDP-based DLQR control system with integral action, compared to the practical results of the control system with the PI controller implemented in the BWR, and noting that both the matrices $\tilde{H}_{\infty}^{ADHDP}$ and $\tilde{H}_{Schur}$, how much the gains $\tilde{K}_{\infty}^{ADHDP}$ and $\tilde{K}_{Schur}$ are equal, guarantees the convergence of all parameters of the plant under study. Thus, it was ensured that the performance achieved by the simulated results of the proposed control system ensures that the system is feasible to be implemented in industrial process control.




Fig. 22. Convergence behavior of the parameters θ_{13} , θ_{14} and θ_{15} with disturbance signal on the plant for the BWR operational process.




Fig. 23. ADHDP-based DLQR controller gains with disturbance signal on the plant for the BWR operational process.

In view of the complexity of identifying real plant models, the ADHDP-DLQR with integral action can be an alternative for many problems, since it does not depend on models, but rather on input and state signals that can be measured with the installation of sensors to capture these signals. Therefore, it is concluded that a control system with PI controller with the gains K_P and K_I constants works well only for the dynamics of the plant in which these parameters were adjusted, changing the dynamics of the plant, the control system no longer responds. On the other hand, the ADHDP-based DLQR control system with integral action proved to be more efficient, since the gain parameters are adjusted automatically according to the updated dynamics of the plant in real-time and the results are optimal.

The comparison of the ADHDP-DLQR-IA controller with the fuzzy controller tuned by fuzzy rules is fairer, since the two do not depend on plant model, but the comparison was extended to the conventional PID controller, tuned by the second Ziegler–Nichols




Fig. 24. Step response - ADHDP-DLQR-IA algorithm x PID-Fuzzy x PID-ZN x SMC x Plant model.




Fig. 25. Impulse response - ADHDP-DLQR-IA algorithm x PID-Fuzzy x SMC x Plant model.

method, and the sliding mode controller, tuned by a RBF. After comparing the results of the evaluated controllers, one concludes that the ADHDP-DLQR-IA controller is more efficient, both for the parametric evaluations and for the control evaluations.

Acknowledgments

We thank PPGE of the Federal University of Maranhão (UFMA) for the technical/scientific and practical lessons. We are especially grateful to FAPEMA for encouraging high-level research in the State of Maranhão. We also thank the Department of Physics of the State University of Maranhão (UEMA) for making this research feasible. We thank CAPES for promoting and supporting advanced research that contributed to this work. Finally, the Vale S.A. Company for providing its specialists for practical guidance for the execution of the experiments.

Appendix A. Iterative process parameters and initial conditions

System identification techniques were performed to determine the approximate linear BWR model in state space representation, which was needed for getting a process simulator for the ADHDP-DLQR design purpose. The approach involves the application of input signals that represent the electric frequency f_k (Hz) of the lance rotation engine measured by the frequency inverter and recording the corresponding output signal, which is the load measured by a dynamic scale installed in the BWR lance. These input/output data was then used to estimate the BWR model based on the subspace method (Least Squares) and the search algorithm Numerical algorithms for Subspace State Space System Identification (N4SID) [67]. The identification process resulted in the following third order linear continuous-time state-space model.

$$A = \begin{bmatrix} -0.08728 & -0.2905 & 0.3078 \\ 0.206 & -0.009143 & 1.035 \\ -0.0963 & -0.9774 & -0.09775 \end{bmatrix}, \quad (A.1)$$

$$B = \begin{bmatrix} -0.02255 \\ -0.03438 \\ -0.01721 \end{bmatrix}, \quad (A.2)$$

$$C = \begin{bmatrix} 0 & 0 & 1 \end{bmatrix},$$

$$D = [0].$$

For the sampling interval of 1 s, the sampled system matrices were obtained by zero-order-hold method. These matrices are given by

$$A_d = \begin{bmatrix} 0.8736 & -0.3570 & 0.1022 \\ 0.1196 & 0.5159 & 0.8369 \\ -0.1581 & -0.7528 & 0.4595 \end{bmatrix},$$

$$B_d = \begin{bmatrix} -0.168 \\ -0.0382 \\ 0.0026 \end{bmatrix},$$

$$C_d = \begin{bmatrix} 0 & 0 & 1 \end{bmatrix},$$

$$D_d = [0].$$

The weighting matrices $\tilde{Q}$ and $\tilde{R}$ are used to penalize the deviations of the state variables and the cost of the control policy. The search methods of the matrices $\tilde{Q}$ and $\tilde{R}$ are oriented to impose a specified control goal. The classification of these methods is based on their search characteristics, such as heuristic search [68], empirical search [69], and search based on computational intelligence [70]. In this paper, these matrices were defined by the empirical search method (by trial and error) according to the user's expertise.

$$\tilde{Q} = \begin{bmatrix} 0.1 & 0 & 0 & 0 \\ 0 & 0.1 & 0 & 0 \\ 0 & 0 & 0.1 & 0 \\ 0 & 0 & 0 & 0.1 \end{bmatrix},$$

$$\tilde{R} = [0.1].$$

The initial parameter vector θ_0 of the Riccati/Lyapunov equation estimated by the RLS method is given by $\theta = [\theta_1 \dots \theta_i \dots \theta_{15}]^T$, where $\theta_i = 0$ for $i = 1, \dots, 15$ (the startup corresponds to the third-order dynamic system model).

The iterative process startup of the approximate policy iteration requires the selection of an admissible initial policy $\tilde{K}_0$. For such a case, the initial matrix of the Riccati/Lyapunov equation for RLS is

given by

$$\tilde{H}_0 = \begin{bmatrix} 11.4026 & 0.9428 & 1.4549 & 0.2426 & 0.9328 \\ 0.9428 & 11.9521 & 0.6357 & 0.4577 & 1.1304 \\ 1.4549 & 0.6357 & 11.1728 & 1.0220 & 0.6182 \\ 0.2426 & 0.4577 & 1.0220 & 10.4352 & 1.5246 \\ 0.9328 & 1.1304 & 0.6182 & 1.5246 & 11.7183 \end{bmatrix}$$

and, consequently, the initial control policy is given by

$$\tilde{K}_0 = [0.0796 \quad 0.0965 \quad 0.0528 \quad -0.1301].$$

The initial state vector, the forgetting factor and the discount factor are given by $\tilde{x}_0 = [4 \quad 2 \quad 5 \quad 10]^T$, $\mu = 0.95$ and $\lambda = 1$, respectively. The RLS initial covariance matrix is given by $\Phi_0 = 1000 \times I$, where I is the identity matrix, 15×15 .

Appendix B. PID-ZN and PID-Fuzzy controller designs

The PID-ZN and PID-Fuzzy models were proposed by Zhao and Tomizuka [71]. Such models have been adapted to the BWR operational process.

B.1. PID control

The critical gain of the PID-ZN controller is K_{cr} (1.47) and the frequency of oscillations w_{cr} (0.614) were determined. These values can be found from the crossing points of the root-locus with the axis jw [72].

The gain vector computing $K^{pid}(s)$ using the second Ziegler–Nichols method is given by

$$K_p = 0.6K_{cr} = 0.6 \times 1.47 = \boxed{0.8820}$$

$$P_{cr} = \frac{2\pi}{w_{cr}} = \frac{2 \times 3.1416}{0.614} = 10.2332s$$

$$T_i = 0.5 \times 10.2332 = 5.1166s$$

$$K_i = \frac{0.6}{5.1166} = \boxed{0.1175}$$

$$T_d = 0.125 \times 1.47 = 0.1837s$$

$$K_d = 0.8820 \times 0.1837 = \boxed{0.1620}$$

The PID controller model $C(s)$ is given by

$$C(s) = K^{pid}(s), \quad (B.1)$$

where $K^{pid}(s) = K_d s^2 + K_p s + K_i/s$.

The transfer function of the closed-loop system is given by

$$C_{Rppid}^{MF} = \frac{K^{pid}(s) (0.1812s + 0.0871)}{s(s^3 + 0.3553s^2 + 0.1117s + 0.01567)} \quad (B.2)$$

B.2. PID-Fuzzy controller model

The control system uses a fuzzy rules-based system for tuning the PID controller by scheduling gains. The Fuzzy system assumes that K_p and K_d are at prescribed intervals in $[K_{pmin}, K_{pmax}]$ and $[K_{dmin}, K_{dmax}]$, respectively. The PID-Fuzzy controller inputs are the error(e) and its derivative ($\dot{e}$), and the outputs are K'_p , K'_d and α , where K'_p and K'_d are the normalized gains in a range of 0 to 1 by means of a linear transformation and α is a parameter used to calculate the gain K_i .

$$K'_p = \frac{K_p - K_{pmin}}{K_{pmax} - K_{pmin}} \quad (B.3)$$

Table B.2

Tuning rules for the outputs K'_p and K'_d from the inputs $e(k)$ and $\dot{e}(k)$.

$\dot{e}(t) \backslash e(t)$	NB	NM	NS	ZO	PS	PM	PB
NB	B/S	B/S	B/S	B/S	B/S	B/S	B/S
NM	S/B	B/B	B/S	B/S	B/S	B/B	S/B
NS	S/B	S/B	B/B	B/S	B/B	S/B	S/B
ZO	S/B	S/B	S/B	B/B	S/B	S/B	S/B
PS	S/B	S/B	B/B	B/S	B/B	S/B	S/B
PM	S/B	B/B	B/S	B/S	B/S	B/B	S/B
PB	B/S	B/S	B/S	B/S	B/S	B/S	B/S

Table B.3

Tuning rules for the alpha from the inputs $e(k)$ and $\dot{e}(k)$.

$\dot{e}(t) \backslash e(t)$	NB	NM	NS	ZO	PS	PM	PB
NB	2	2	2	2	2	2	2
NM	3	3	2	2	2	3	3
NS	4	3	3	2	3	3	4
ZO	5	4	3	3	3	4	5
PS	4	3	3	2	3	3	4
PM	3	3	2	2	2	3	3
PB	2	2	2	2	2	2	2

$$K'_d = \frac{K_d - K_{dmin}}{K_{dmax} - K_{dmin}} \quad (B.4)$$

In the PID-Fuzzy design, the PID parameters are determined based on the current error $e(k)$ and the error difference $\Delta e(k)$. The integral time constant is determined with reference to the derivation time constant.

The parameters K'_p , K'_d and K'_i are determined from a set of fuzzy rules, such as:

IF $e(k)$ is A_i and $\Delta e(k)$ is B_i , THEN K'_p is C_i is D_i , and $\alpha = \alpha_i$, $i = 1, 2, \dots, m$.

The set of rules used to adjust the gains K'_p and K'_d is presented in Table B.2, and the set of rules to determine the gain K'_i is displayed in Table B.3, where B (big) and S (small) are the membership functions of the Big and Small sets, respectively, where NB is negative big, NM is negative medium, NS is negative small, ZO is zero, PS is positive small, PM is positive medium, and PB is positive big.

Appendix C. Sliding mode control

In sliding mode the movement is independent of the control. However, the control must be designed so that it drives the trajectories to the switching surface and holds it on this surface once the trajectory has been reached [73,74]. For a better understanding, the layer L_1 of the stack shown in Fig. 4 is considered, it is stratified and illustrated in Fig. C.26. The stack of ore storage is considered a state-dependent switching system containing a single switching surface, denoted by S_i (translation step), $i = 1, \dots, 12$, and two subsystems $\dot{x} = f_i(x)$ ($i = 1, 2$), one on each side of S_i with $i = 2n + 1$ for the trajectory S_{Left} and $i = 2n$ for the trajectory S_{Right} . Assuming there are no impulse effects, thus the state does not jump with the switching events. It is understood that when the continuous trajectory reaches S_{Left} , it returns to the other side




Fig. C.26. Sliding mode control applied to the recovery of a stack – graphical representation.



Fig. C.27. Sliding mode control applied to resumption of a real stack.

until S_{Right} , characterized by a sliding surface. This will be true if at the corresponding point $x \in S$, both vectors $f_1(x)$ and $f_2(x)$ have the same direction relative to S_i .

In Fig. C.27, the real resumption process of an ore stack with the sliding mode surface is highlighted.

The SMC was applied with the adjustment made by a RBF-type neural network in the model of the operational process of the plant of a BWR.

Let the system be given by

$$\ddot{y} = f(y, \dot{y}) + g(y, \dot{y})u, \quad (C.1)$$

in which f and g are unknown functions, and u and y are the input and output of the system, respectively.

Eq. (C.1) can be written as

$$\begin{aligned} \dot{x}_1 &= x_2 \\ \dot{x}_2 &= f(x_1, x_2) + g(x_1, x_2)u. \\ y &= x_1 \end{aligned} \quad (C.2)$$

The desired position signal is y_d and the error is defined by

$$e = y_d - y = y_d - x_1. \quad (C.3)$$

The control law by sliding modes [73] is given by

$$u^* = \frac{1}{g(x)} [-f(x) + \ddot{y}_d + \beta^T E], \quad (C.4)$$

$x = [x_1 \ x_2]^T$, $\beta = [\beta_0 \ \beta_1]^T$ and $E = [e \ \dot{e}]^T$. Substituting the control law given by Eq. (C.4) and the error given by Eq. (C.2) in Eq. (C.1), the closed-loop control system is obtained as a function of the error given by

$$\ddot{e} + \beta_1 \dot{e} + \beta_0 e, \quad (C.5)$$

with β_1 and β_0 positive constants and the polynomial $s^2 + \beta_1 s + \beta_0$ being stable. With the suitable choices of β_1 and β_0 , $t \rightarrow \infty$, $e \rightarrow 0$ and $\dot{e} \rightarrow 0$ has been.

The RBF algorithm is described by [75], which is given by

$$\begin{aligned} h_j &= g(\|E - c_{ij}\|/b_j^2) \\ f &= W^T h(E) + \varepsilon, \end{aligned} \quad (C.6)$$

where $g(\cdot)$ is a Gaussian function; c and b are the center and the width of the Gaussian, respectively; E is the input vector, i is the i th network input, j is the j th hidden layer neuron, $h = [h_1, h_2, \dots, h_n]^T$, W is the vector of weights and ε is the approximation error.

The output of the RBF network that provides the approximation of f is given by

$$\hat{f}(x) = \hat{W}h(E), \quad (C.7)$$

in which $\hat{W}$ is the estimate of W .

Thus, the resulting control law is given by

$$u = \frac{1}{g(x)} [\hat{f}(x) + \ddot{y}_d + \beta^T E], \quad (C.8)$$

and the chosen adaptive control law is given by

$$\dot{\hat{W}} = -\gamma E^T P B h(x). \quad (C.9)$$

The parameters used for adjusting the control system by sliding mode are:

Sampling interval $t = 0.01$;

$$K = [\beta_0 \ \beta_1];$$

$$\beta_0 = 9;$$

$$\beta_1 = 7.5;$$

$$\gamma = 15000;$$

$$E = \begin{bmatrix} 0.2275 \\ 0.0008 \end{bmatrix};$$

$$\hat{f}(x) = 353.8289$$

$$g(x) = 19000;$$

$$W = 10^3 [0 \ 0 \ 0 \ 4.7116 \ 0 \ 0 \ 0]^T$$

$$h = [0 \ 0 \ 0 \ 0.0751 \ 0 \ 0 \ 0]^T;$$

$$u(k) = -0.0185.$$

References

- [1] Dorf RC, Bishop RH. *Modern Control Systems*. Pearson; 2011.
- [2] Goodwin GC, Graebe SF, Salgado ME. *Control system design*. Upper Saddle River; 2001.
- [3] Lewis FL. *Applied Optimal Control and Estimation*. Prentice Hall PTR; 1992.
- [4] Bellman RE. *Adaptive Control Processes: A Guided Tour*. Princeton university press; 2015.
- [5] Azar AT, Zhu Q. *Advances and Applications in Sliding Mode Control Systems*. Springer; 2015.
- [6] Steinbuch M, Norg ML. *Advanced motion control: An industrial perspective*. Eur J Control 1998;4(4):278–93.
- [7] Ioannou P, Fidan B. *Adaptive Control Tutorial*. SIAM Society for Industrial & Applied Mathematics, TJ217. I628. Tech. Rep., 2006.
- [8] Sutton R, Barto AG. *Reinforcement Learning Introduction*. Cambridge: MIT Press; 1998.
- [9] Li Z-H, Krstić M. Optimal design of adaptive tracking controllers for non-linear systems. *Automatica* 1997;33(8):1459–73.
- [10] Werbos PJ. Foreword-ADP: The key direction for future research in intelligent control and understanding brain intelligence. *IEEE Trans Syst Man Cybern B* 2008;38(4):898–900.
- [11] Wittenmark B. Adaptive dual control methods: An overview. *IFAC Proc Vol* 1995;28(13):67–72.
- [12] Lewis FL, Vrabie DL, Syrmos VL. *Optimal Control*. Wiley Online Library; 1995.
- [13] Vamvoudakis KG, Lewis FL. Online actor-critic algorithm to solve the continuous-time infinite horizon optimal control problem. *Automatica* 2010;46(5):878–88.
- [14] Werbos PJ. Approximate dynamic programming for real-time control and neural modeling. In: *Handbook of intelligent control: Neural, fuzzy, and adaptive approaches*, vol. 15. Nostrand, New York; 1992, p. 493–525.

- [15] Si J. Handbook of learning and approximate dynamic programming, vol. 2. John Wiley & Sons; 2004.
- [16] Werbos PJ. Reinforcement Learning and Approximate Dynamic Programming (RLADP)—Foundations, Common Misconceptions, and the Challenges Ahead. In: Reinforcement Learning and Approximate Dynamic Programming for Feedback Control. Wiley Online Library; 2012, p. 1–30.
- [17] Sokolov Y, Kozma R, Werbos LD, Werbos PJ. Complete stability analysis of a heuristic approximate dynamic programming control design. *Automatica* 2015;59:9–18.
- [18] Sutton RS, Barto AG, Williams RJ. Reinforcement learning is direct adaptive optimal control. *IEEE Control Syst* 1992;12(2):19–22.
- [19] Sutton RS. Temporal credit assignment in reinforcement learning, doctoral dissertations available from proquest. 1984.
- [20] Sutton RS, Barto AG. Reinforcement Learning: An Introduction, vol. 1. (1). MIT press Cambridge; 1998.
- [21] Barto AG, Bradtke SJ, Singh SP. Learning to act using real-time dynamic programming. *Artif Intell* 1995;72(1–2):81–138.
- [22] Bertsekas DP, Bertsekas DP, Bertsekas DP, Bertsekas DP. Dynamic Programming and Optimal Control, vol. 1. (2). Athena Scientific Belmont, MA; 1995.
- [23] Lewis FL, Vrabie D, Vamvoudakis KG. Reinforcement learning and feedback control: Using natural decision methods to design optimal adaptive controllers. *IEEE Control Syst* 2012;32(6):76–105.
- [24] Kumar P, Lin W. Optimal adaptive controllers for unknown Markov chains. *IEEE Trans Automat Control* 1982;27(4):765–74.
- [25] Kumar P, Becker A. A new family of optimal adaptive controllers for Markov chains. *IEEE Trans Automat Control* 1982;27(1):137–46.
- [26] Vrabie D, Vamvoudakis KG, Lewis FL. Optimal adaptive control and differential games by reinforcement learning principles, vol. 2. IET; 2013.
- [27] Sutton RS. Integrated architectures for learning, planning, and reacting based on approximating dynamic programming. In: Proceedings of the seventh international conference on machine learning; 1990. p. 216–224.
- [28] Jaakkola T, Jordan MI, Singh SP. On the convergence of stochastic iterative dynamic programming algorithms. *Neural comput* 1994;6(6):1185–201.
- [29] Al-Tamimi A, Lewis FL, Abu-Khalaf M. Discrete-time nonlinear HJB solution using approximate dynamic programming: Convergence proof. *IEEE Trans Syst Man Cybern B* 2008;38(4):943–9.
- [30] Bertsekas DP. Approximate Dynamic Programming. Citeseer; 2008.
- [31] Powell WB. Approximate Dynamic Programming: Solving the curses of dimensionality, vol. 703. John Wiley & Sons; 2007.
- [32] Castanon DA. Approximate dynamic programming for sensor management. In: Decision and Control, 1997., Proceedings of the 36th IEEE Conference on, vol. 2. IEEE; 1997, p. 1202–7.
- [33] Barto AG, Sutton RS, Anderson CW. Neuronlike adaptive elements that can solve difficult learning control problems. *IEEE Trans Syst Man Cybern* 1983;(5):834–46.
- [34] Mendel J, McLaren R. 8 Reinforcement-Learning Control and Pattern Recognition Systems. *Math Sci Eng* 1970;66:287–318.
- [35] Busoniu L, Babuska R, De Schutter B, Ernst D. Reinforcement Learning and Dynamic Programming Using Function Approximators, vol. 39. CRC press; 2010.
- [36] Rêgo PHM, Neto JVDf, Ferreira EM. Convergence of the standard RLS method and UDU T factorisation of covariance matrix for solving the algebraic Riccati equation of the DLQR via heuristic approximate dynamic programming. *Internat J Systems Sci* 2015;46(11):2006–28.
- [37] Lewis FL, Vrabie D. Reinforcement learning and adaptive dynamic programming for feedback control. *IEEE Circuits Syst Mag* 2009;9(3):32–50.
- [38] Cao X-R. Stochastic learning and optimization—a sensitivity-based approach. *IFAC Proc Vol* 2008;41(2):3480–92.
- [39] Murray JJ, Cox CJ, Lendaris GG, Saeks R. Adaptive dynamic programming. *IEEE Trans Syst Man Cybern C* 2002;32(2):140–53.
- [40] Zhao D, Xia Z, Wang D. Model-free optimal control for affine nonlinear systems with convergence analysis. *IEEE Trans Autom Sci Eng* 2015;12(4):1461–8.
- [41] Wang D, Liu D, Wei Q. Finite-horizon neuro-optimal tracking control for a class of discrete-time nonlinear systems using adaptive dynamic programming approach. *Neurocomputing* 2012;78(1):14–22.
- [42] Han D, Balakrishnan S. State-constrained agile missile control with adaptive-critic-based neural networks. *IEEE Trans Control Syst Technol* 2002;10(4):481–9.
- [43] Bertsekas DP, Homer ML, Logan DA, Patek SD, Sandell NR. Missile defense and interceptor allocation by neuro-dynamic programming. *IEEE Trans Syst Man Cybern A* 2000;30(1):42–51.
- [44] Prokhorov D. Neural networks in automotive applications. In: Computational Intelligence in Automotive Applications. Springer; 2008, p. 101–23.
- [45] McRuer DT, Graham D, Ashkenas I. Aircraft Dynamics and Automatic Control. Princeton University Press; 2014.
- [46] Ferrari S, Stengel RF. Online adaptive critic flight control. *J Guid Control Dyn* 2004;27(5):777–86.
- [47] Enns R, Si J. Helicopter flight-control reconfiguration for main rotor actuator failures. *J Guid Control Dyn* 2003;26(4):572–84.
- [48] da Fonseca Neto JV, Ferreira EF, Rego PHM. Online optimal dlqr-dfgr control system design via recursive least-square approach and state heuristic dynamic programming for approximate solution of the hjb equation. In: Systems, Man, and Cybernetics (SMC), 2013 IEEE International Conference on. IEEE; 2013, p. 3174–9.
- [49] Yu M, Lu C, Liu Y. Direct heuristic dynamic programming method for power system stability enhancement. In: American Control Conference. IEEE; 2014, p. 747–52.
- [50] Lendaris GG, Schultz L, Shannon T. Adaptive critic design for intelligent steering and speed control of a 2-axle vehicle. In: Neural Networks, 2000. IJCNN 2000, Proceedings of the IEEE-INNS-ENNS International Joint Conference on, vol. 3. IEEE; 2000, p. 73–8.
- [51] Moura JP, de Oliveira Serra GL, Fonseca JV. Fuzzy Logic in The Control of Shipping of Ships in The Maritime Terminal of Tip of the Wood. In: Brazilian Symposium on Intelligent Automation; 2013.
- [52] Williams R, Luke S, Ostrowski K, Bennett M. Measurement of bulk particulates on belt conveyor using dielectric tomography. *Chem Eng J* 2000;77(1):57–63.
- [53] Lopes BE, de Moura JP, Ribeiro DA, e Borges FHC, de Souza MA. Flow Optimization for Iron Ore Reclaiming Process., in: ICINCO (1). 2012, p. 425–32.
- [54] Landelius T. Reinforcement learning and distributed local model synthesis, University Electronic Press, 1997. Linköping University Electronic Press; 1997.
- [55] Al-Tamimi AA. Discrete-time control algorithms and adaptive intelligent systems designs. The University of Texas at Arlington; 2007.
- [56] Fonseca Neto JV, Rêgo PHM. QR-Tuning and approximate-LS solutions of the HJB equation for online DLQR design VIA state and action-dependent heuristic dynamic programming. *International Journal of Innovative Computing, Information and Control* 2014;10(3).
- [57] Zhang H, Liu D, Luo Y, Wang D. Adaptive Dynamic Programming for Control: Algorithms and Stability. Springer Science & Business Media; 2012.
- [58] Ni Z, He H, Zhao D, Xu X, Prokhorov DV. GrDHP: A general utility function representation for dual heuristic dynamic programming. *IEEE Trans Neural Netw Learn syst* 2015;26(3):614–27.
- [59] Lewis FL, Liu D. Reinforcement Learning and Approximate Dynamic Programming for Feedback Control. 17, John Wiley & Sons; 2013.
- [60] He S, Song J, Ding Z, Liu F. Online adaptive optimal control for continuous-time Markov jump linear systems using a novel policy iteration algorithm. *IET Control Theory Appl* 2015;9(10):1536–43.
- [61] Brewer J. Kronecker products and matrix calculus in system theory. *IEEE Trans circuits Syst* 1978;25(9):772–81.
- [62] Van Loan CF, Pitsianis N. Approximation with Kronecker products. In: Linear algebra for large scale and real-time applications. Springer; 1993, p. 293–314.
- [63] Björck Å. Numerical Methods in Matrix Computations. Springer; 2015.
- [64] Ferreira EF, Rêgo PH, Neto JV. Numerical stability improvements of state-value function approximations based on RLS learning for online HDP-DLQR control system design. *Eng Appl Artif Intell* 2017;63:1–19.
- [65] Ogata K. Modern Control Engineering, fifth ed.. Lugar: Upper Saddle River, New Jersey 07458: Prentice Hall; 2009, p. 55.
- [66] Laub AJ. A schur method for solving algebraic Riccati equations. In: 1978 IEEE Conference on Decision and Control Including the 17th Symposium on Adaptive Processes; 1978. p. 60–65, <http://dx.doi.org/10.1109/CDC.1978.267893>.
- [67] Van Overschee P, De Moor B. Subspace Identification for Linear Systems: Theory—Implementation—Applications. Springer Science & Business Media; 2012.
- [68] Bryson AE. Applied Optimal Control: Optimization, Estimation and Control. CRC Press; 1975.
- [69] Fonseca Neto JV, Abreu IS, Da Silva FN. Neural-genetic synthesis for state-space controllers based on linear quadratic regulator design for eigenstructure assignment. *IEEE Trans Syst Man Cybern B* 2010;40(2):266–85.
- [70] Neto JVDf, Abreu IS, Rêgo PHM, de Melo MP. Modelos e Convergência de um Algoritmo Genético para Alocação de Auto-estrutura via RLQ. *IEEE Latin America Trans* 2008.
- [71] Zhao Z-Y, Tomizuka M, Isaka S. Fuzzy gain scheduling of PID controllers. *IEEE Trans Syst Man Cybern* 1993;23(5):1392–8.
- [72] Ogata K. Modern Control Engineering. Prentice-Hall electrical engineering series. Instrumentation and controls series, fifth ed.. Prentice Hall; 2009.
- [73] Jean-Jacques Slotine WL. Applied Nonlinear Control. Pearson; 1991.
- [74] Perruquetti W. Sliding Mode Control in Engineering, first ed.. Control engineering 11, M. Dekker; 2002.
- [75] Ge SS, Hang CC, Lee TH, Zhang T. Stable adaptive neural network control, vol. 13. Springer Science & Business Media; 2013.

José Pinheiro de Moura He holds a Technician in Mechanics course from the Federal Technical School of Piauí, Brazil (1984), Degree in Industrial Chemistry from the Federal University of Maranhão (1998), Bachelor's Degree in Sciences-Chemistry by the State University of Maranhão, Brazil (2001), Master in Electrical Engineering in the Automation and Control Area, Federal University of Maranhão, Brazil (2003) and Ph.D. in Electrical Engineering in the Automation and Control of Industrial

Processes, Federal University of Maranhão, Brazil (Studying). He is currently an Assistant Professor at the State University of Maranhão, Brazil and the company Vale. S.A. Researcher, working mainly on the following topics: Optimal tuning of PID controllers, adaptive control, reinforcement learning, adaptive dynamic programming, action dependent heuristic dynamic programming, computational intelligence, programmable logical controller, remote and automatic operation of industrial equipment, port management and education.

Patrícia Helena Moraes Rego He holds a degree in mathematics from the Federal University of Maranhão, Brazil (1999), a specialization in mathematics education from the State University of Maranhão, Brazil (2001), a Master's degree in electrical Engineering from the Federal University of Maranhão (2007) and a Ph.D. in Electrical Engineering from the Federal University of Maranhão, Brazil. She is currently Adjunct Professor at the State University of Maranhão. She has experience in the area of Electrical Engineering, with emphasis on Automation and Control, Modeling and Control Systems.

João Viana da Fonseca Neto He is Adjunct Professor at the Federal University of Maranhão, Brazil. He holds a degree in Electrical Engineering from the Federal University of Paraíba, Brazil (1982), a Master's degree in Electrical Engineering from the Federal University of Paraíba (1986) and a Ph.D. in Electrical Engineering from the State University of Campinas, Brazil (2000). He has developed R & D projects in Modeling and Control for Aluminum Industry of Maranhão (ALUMAR) and Intelligent Systems for Decision Making for Discharge and Storage of Ores (CVRD). He is currently developing research in Computational Intelligence focusing on neuro-genético-fuzzy fusion for determination and selection of optimal LQG/LTR controllers for MIMO systems. Also develops Bayesian methods for the Riccati Recurrence training in Standard Kalman type Stochastic Filters. He has experience in the area of Electrical Engineering, with emphasis on Electronic Process Control, Feedback, working mainly on the following topics: artificial intelligence models for industrial systems, genetic algorithms, PID controller tuning, indirect measurement via Kalman Filtering, neural solution Of the Riccati algebraic equation and the intelligent recovery of the LQR control mesh.

A Neuro-Fuzzy Model for Online Optimal Tuning of PID Controllers in Industrial Systems Applications to the Mining Sector

José Pinheiro de Moura, João Viana da Fonseca neto, Patrícia Helena Moraes Rêgo.

Abstract—This study develops a model for optimal and online tuning of PID controllers and evaluates its performance. The proposed model is based on computational intelligence approaches and can be used in industrial plant operating processes. The proposed tuning model is called PID-neuro-fuzzy model, a formulation based on a structured artificial neural network and fuzzy rules. The neural network is used to perform an optimal adjustment of PID controller gains to ensure the operating point of the system, required to reduce the time of accommodation and the steady-state error. A fuzzy system is incorporated into a real-time gain-scheduling scheme to compensate for the possible variations in plant parameters. The performance of the proposed model is evaluated based on its ability to deal with uncertainties and disturbances in the process. The efficiency of the model is investigated through computational simulations in five plants of two industrial processes in the mining sector: i) solid bulk unloading processes by car dumper and ii) solid bulk resumption process by bucket wheel reclaimers. We conclude, the main advantage of the proposed model is adaptability related to variations in plant parameters during the operational process.

Index Terms—Online Tuning, PID Controllers, Computational Intelligence, Artificial Neural Network, Steady-State Error, Fuzzy System.

I. INTRODUCTION

Proportional, derivative and integral (PID) controllers are commonly used to control industrial systems owing to their simple structure, robust nature, and easy implementation [1] [2]. Furthermore, they have several important functions such as the ability to reduce steady-state error through integral action and the possibility of being anticipatory through derivative action [3]. This latter action is also helps improve transient performance and stability.

A good controller should also have parameters that will adapt themselves automatically to the actual process dynamics [25] [26]. According to [27], PID controllers can be divided into two main categories: fixed-gain controllers and adaptive controllers. Fixed-gain controllers are simple, but might not always control systems with variant parameters efficiently, which may require frequent online retuning. The Ziegler-Nichols tuning method is the most popular example of this category [24]. In contrast, adaptive

controllers have their parameters continuously adjusted to accommodate changes in the plant parameters.

Recently, fuzzy adaptive control and neural network (NN) control have received considerable attention. A few important results have been achieved in [10] [11], and adaptive backstepping control designs have been extensively investigated for the nonlinearity property. In [12] - [15], the authors proposed adaptive methods of backstepping control design for nonlinear multiple input multiple output (MIMO) systems [17]. In [23], the authors present a method for gain tuning of fuzzy PID controllers for real-time implementation, where the plant's dynamics are locally approximated by a linear model and the parameters are recursively updated. PID-neuro-fuzzy model, compared to the models presented in the articles above, besides the advantages presented by their respective authors, such as speed in achieving the objectives of controls and maintaining the trajectories reached within the specifications of the projects and robustness, also has the advantage of being optimal in achieving the control goal by following the specified parameters imposed by the designer, of being adaptive in the sense of online self-tuning through fuzzy rules in addition to being robust with respect to resistance to brute perturbations suffered in its parameters recovering the parameters.

Methods related to that proposed herein can be verified in articles of conference proceedings and journals. It is observed that journal articles primarily focus on the development of methods and the conference proceeding articles present their applications in various sectors of contemporary society, highlighting their relevance in the context of research and development (R&D). The applications of these methods were emphasized as it is understood that each plant is characterized by its *modus operandi*. In this way, expert knowledge can be represented or modeled by fuzzy algorithms.

For the purpose of providing context to our research, we present and describe the content of articles cited in the previous paragraph. The present study aims to develop a model for the optimal tuning of the PID controller using a structured artificial neural network (S-ANN) and fuzzy rules in the online adjustment of the gains in terms of variations in plant parameters. This model is called PID-neuro-fuzzy, and is applied to five plants of the following two industrial processes of the mining sector: i) discharge processes of bulk solids by car dumper (CD)

and ii) resumption process of bulk solids by bucket wheel reclaimer (BWR). Plants in the mining industry are very complex, and the use of high-performance controllers is not common. The PID-neuro-fuzzy model is an innovative proposal for these applications and provides solutions to problems that consider different realistic aspects, such as ability to follow the reference input, disturbance rejection, parametric uncertainties, and adaptability.

The application of the PID-neuro-fuzzy model in industrial processes in the mining sector is motivated by the fact that these processes are automated and implemented in programmable logic controllers (PLCs), which already incorporate a PID controller programming module and fuzzy programming in their structure [41]. In addition, S-ANN exhibits high performance and relatively low computational cost. Thus, the implementation of the proposed model in real plants is feasible. Such an adjustment model is based on the actual plant data collected during the operational process by a plant information management system (PIMS) [40]. PIMS is a software in which the sensors are registered to the records of events that occur in real time [45].

The performance evaluation and validity of the PID-neuro-fuzzy model are demonstrated in this study through extensive computational simulations. The simulated results show that the computational intelligence (CI) methods provide better performance in terms of optimality, steady-state error stability, disturbance rejection, and adaptability in the evaluated plants when compared to conventional tuning methods, such as PID controllers tuned by the second Ziegler-Nichols method and the PID-Fuzzy controller proposed by Zhao and Tomizuka on "Fuzzy Gain Scheduling of PID Controllers" [27].

The contribution of the present paper involves the development of algorithms for the optimal and online tuning of PID controllers by combining CI (S-ANN and fuzzy logic) techniques and the assemblage of the propagation matrix. This matrix is obtained from the internal product operation between the controller gain vector and the numerator coefficients of the transfer function of the plants under study, enabling the efficient control of industrial dynamic systems while requiring low computational cost. Furthermore, in this context, it contributes to the control strategy and to the solution of the problem via the S-ANN algorithm.

In addition, this paper is relevant in the context of application, because the proposed model will innovate industrial processes of high operational complexity, such as mining processes.

The rest of this paper is organized as follows. In Section 2, the plants of the operational processes are described. In Section 3, a mathematical formulation of the PID-neuro-fuzzy model is presented. Section 4 describes the design of the evaluated controller models. In Section 5, the experimental results that evaluate the performance of the proposed model are shown, and finally, Section 6 presents the conclusion.

II. DESCRIPTION OF THE PLANTS

It was necessary to estimate the plant models by using the reference data of the electrical current intensity (I) of the drive motors of the CD feeders and bucket wheels (BW) of the BWR, and relate them with the load flows measured by the scales. Thus, the estimated models were generated [45]. The state space models were designed based on real data of the plants, using the subspace method (least-squares) and the search algorithm *Numerical algorithms for Subspace State Space System Identification* (N4SID) [43] [44]. From these models, the transfer functions of the plants were obtained. CD and BWR are briefly described below.

A. Operational Process of Car Dumpers

This process is carried out by CD, which are equipment used for wagon downloading of solid bulk. They are rotators turning around their own axis up to 180°, discharging one or two wagons with 110 tons each at every rotation movement [41]. The wagons have mobile couplings at the end points, allowing their rotating movement during discharge, their decoupling not being necessary, as shown in Fig. 1.



Fig. 1. Car dumper.

The process of wagon discharge occurs in two simultaneous events. Event 1 corresponds to the variation in the electric current intensity of the drive motors of the feeders. Event 2 corresponds to the feeders' rotation speed, that is, varying the electric current intensity of the drive motors of the feeders interferes with their rotation speed variation and vice-versa. A block diagram of the two process events is illustrated in Fig. 2.




Fig. 2. Block diagram of the CD operational process.

B. Operational Process of Reclaimers

The ore resumption process consists of taking up the stored material in stacks and transporting it through conveyor belts for shipment. The BWRs have a nominal capacity of 8000t/h, and the operational routes, which are composed of BWRs, conveyor belts (CTs), and ship loaders (SL), have a nominal capacity of transporting up to 16000 t/h. Thus, two BWRs can perform simultaneous resumption for a 16000t/h route or a BWR can perform the resumption for a route of 8000t/h [45]. As shown in Fig. 3, a BWR to the left and the wheel of buckets to the right are highlighted, which are devices that attack the stack to perform the ore resumption.




Fig. 3. Bucket wheel reclaimer.

The three main events that occur during a plant's operational process are presented in the block diagram of Fig. 4. The translation step is the first event to occur, followed by the events of BWR lance rotation and BW rotation. The events of the BW rotation speed and translation step size are not controlled, and the only controlled event is the speed of BWR lance rotation in the desired flow search. The event of the translational step varies from 0 to 1 m and occurs isolated from other events, that is, at the beginning of each stage. A layer to be retaken requires several translation steps, which are the stages. These occur first, and after each stage, the events of BW rotation and lance rotation occur simultaneously.




Fig. 4. Block diagram of the ore resumption process.

C. Models of the Plants

The plant models are conceived through real data collected during their operational process by the PIMS, where the input signal of the plants is the electric current intensity of the motors of the feeder drives for the plants of the operational process of VV and the electric current intensity of the drive motor of the bucket wheel for the plants of the RP operational process [41] [45]. The plants are represented in mathematical models through their transfer functions, and are divided into two groups:

- **Group 1** - Made up of primary plants, which include
 - wagon discharge operational process by one dumper with one feeder;
 - ore resumption process by one BWR; and
 - wagon discharge operational process by one dumper with two feeders.
- **Group 2** - Made up of the secondary plants, which are formed by combinations of the primary plants, which include
 - wagon discharge simultaneous operational process by one dumper with one feeder with the solid bulk resumption operational process per BWR;
 - solid bulk resumption simultaneous operational process by two BWRs.

D. Plants

Plant I refers to the wagon discharge process of dumpers with a 4000 t/h capacity having only one feeder, as illustrated by the block diagram of Fig. 5. Here, $G^{PI}(s)$ is the transfer function of one CD with one feeder, which is given by

$$G^{PI}(s) = G_1^{CD}(s) \quad (1)$$




Fig. 5. Block diagram of Plant - I.

Plant II refers to the operational process of a bulk BWR with a 8000 t/h capacity, as illustrated by the block diagram of Fig. 6. Here, $G^{PII}(s)$ is the transfer function of one BWR, which is given by

$$G^{PII}(s) = G^{BWR}(s) \quad (2)$$




Fig. 6. Block diagram of Plant - II.

Plant III refers to the wagon discharge process by one car dump with 8000 t/h capacity, having two feeders, as illustrated by the block diagram of Fig. 7. Plant III is of fourth order and its transfer function is obtained from the transfer functions of each feeder, associated in parallel:

$$G^{PIII}(s) = G_1^{CD}(s) + G_2^{CD}(s), \quad (3)$$

where G_1^{CD} is the transfer function of feeder 1 and G_2^{CD} is the transfer function of the feeder 2.




Fig. 7. Block diagram of Plant - III.

Plant IV refers to the wagon discharge process by one dumper with a 4000 t/h capacity simultaneously with the operational process of an ore BWR with a capacity of 8000 t/h, as illustrated by the block diagram of Fig. 8. This is a fifth-order plant and its transfer function is obtained from those of Plants I and II, associated in parallel:

$$G^{PIV}(s) = G^{PI}(s) + G^{PII}(s). \quad (4)$$




Fig. 8. Block diagram of Plant - IV.

Plant V refers to the ore BWR process by two simultaneous BWRs with a capacity of 8000 t/h each, as illustrated by the block diagram of Fig. 9. The transfer function of Plant V is given by

$$G^{PV}(s) = G^{PII}(s) + G^{PII}(s). \quad (5)$$




Fig. 9. Block diagram of Plant - V.

III. FORMULATION OF THE FUZZY-NEURO PID MODEL

The control tuning problem of PID controller formulation and neural, fuzzy, and neuro-fuzzy model developments are presented in this section.

A. PID Control Tuning Problem Formulation

The formulation of the tuning problem is established from the system of equations that represents the actions of the PID controller in the plant dynamics, from the viewpoint that the internal product of the gains and coefficients of the characteristic polynomial is the mechanism for adjusting the gains.

Let an n -order model with m zeros be given by

$$G_p(s) = \frac{N_p(s)}{D_p(s)} = \frac{b_0 s^m + b_1 s^{m-1} + \dots + b_{m-1} s + b_m}{s^n + a_1 s^{n-1} + \dots + a_{n-1} s + a_n}. \quad (6)$$

The three-term PID controller associated with the transfer function of Eq.6) is given by

$$G_c(s) = \frac{N_c(s)}{D_c(s)} = \frac{K_D s^2 + K_P s + K_I}{s}. \quad (7)$$

The polynomial of zeros of the closed-loop control system has order $m+m^{pid}$, where m is the polynomial order of the plant zeros and m^{pid} is the order of the PID controller, m^{pid} , with $m^{pid} = 0, 1, 2$. If $m^{pid} = 0$, one has only the gain K_P , if $m^{pid} = 1$, one has the gains K_I and K_P , and if $m^{pid} = 2$, one has three gains [45]. From Eq. (6) and Eq. (7), the polynomial of zeros of the closed-loop control system for the PID controller is given by

$$N^{CL}(s) = \sum_{j=0}^{m+m^{pid}} (b_j K_D + b_{j-1} K_P + b_{j-2} K_I) s^{m+m^{pid}-j}. \quad (8)$$

Similarly from Eq.(8), one obtains the closed-loop denominator polynomial, which is given by

$$D^{CL}(s) = s^{n+n_D-pid} + \sum_{i=0}^{n+n_D-pid-1} (b_i K_D + b_{i-1} K_P + b_{i-2} K_I + a_{i+1}), \quad (9)$$

where $n_{D-pid} = 0$ or 1. When $n_{D-pid} = 0$, the PID controller structure has the terms derivative and proportional. When $n_{D-pid} = 1$, the structure of the PID controller has an integrator term that increases the order of the system by 1, starting with the following three terms: proportional, derivative, and integrative.

The equationing of the problem is given in the form of an internal product that weights the coefficients of the polynomial of zeros in the closed-loop and additive to the dynamics of the closed-loop transfer function.

From Eq. (9), an equation system that has the vector K^{pid} as unknown and a_i^s as the design specification, $i = 1, 2, \dots, n+1$ is assembled. In the matrix form, such equation system is represented by

$$a_i + \langle K^{pid}, \bar{b}_i \rangle = a_i^s, \quad (10)$$

where

$$K^{pid} = [K_D \quad K_P \quad K_I]^T, \quad (11)$$

and

$$\bar{b}_i = \begin{bmatrix} b_i \\ b_{i-1} \\ b_{i-2} \end{bmatrix}. \quad (12)$$

In a compact form, this equation system can be written as

$$\bar{B}K^{pid} = \bar{a}, \quad (13)$$

$$\text{where } \bar{B} = \begin{bmatrix} b_0 & 0 & 0 \\ b_1 & b_0 & 0 \\ b_2 & b_1 & b_0 \\ b_3 & b_2 & b_1 \\ \dots & \dots & \dots \\ b_m & b_{m-1} & b_{m-2} \\ 0 & b_m & b_{m-1} \\ 0 & 0 & b_m \end{bmatrix},$$

and $\bar{a} = [a_1^e \quad a_2^e \quad \dots \quad a_i^e \quad \dots \quad a_n^e \quad a_{n+1}^e]^T$, with $a_i^e = a_i^s - a_i$.

B. PID-Neuro Model

S-ANN is formulated to act directly on the adjustments of the coefficient a_i and indirectly on the coefficient b_i of the transfer function $G_p(s)$ of the plant, determining the gain parameters K_P , K_I , and K_D (proportional, integral, and derivative, respectively).

The structured neural network is developed from Eq. (10) in order to determine the gain vector K^{pid} that meets the design specifications. Eq. (10) indicates that the procedure includes calculating the elements of the vector K^{pid} that must meet the new parameters a_i^s of the observer transfer function.

Solving the equation system, where the number of equations is greater than the number of unknowns ($n > m$), through the least-squares method, one has

$$\min_{0 < K^{pid} < \infty} \|e(K^{pid})\|_2^2, \quad (14)$$

where $e(K^{pid})$ is an error function given by

$$e(K^{pid}) = \bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{a}. \quad (15)$$

To minimize the error of the optimization structure given by (14), the error cost function is assembled from the Euclidean norm of Eq. (15), given by

$$\mathcal{E}(K^{pid}) = \frac{1}{2} \|\bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{a}\|_2^2. \quad (16)$$

Inspired by the steepest descent method, the solution of this problem, which is given by the S-ANN training rule [46], is given by

$$\frac{dK^{pid}}{dt} = -\mu \nabla \mathcal{E}(K^{pid}). \quad (17)$$

The gradient $\nabla \mathcal{E}(K^{pid})$ of Eq. (17), which is obtained from the derivatives of Eq. (16), is given by

$$\nabla \mathcal{E}(K^{pid}) = \bar{B}^T \bar{B} (\bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{a}). \quad (18)$$

Replacing the gradient of Eq. (17) with that of Eq. (18), one obtains a training rule equation that governs the computation of the gain vector K^{pid} for the new parameters $\bar{a}$ of the characteristic polynomial:

$$\frac{dK^{pid}}{dt} = -\mu (\mathbb{A} K^{pid} - \mathbb{B} \bar{a}), \quad (19)$$

where $\mathbb{A} = \bar{B}^T \bar{B} \bar{B}^T \bar{B}$ and $\mathbb{B} = \bar{B}^T \bar{B} \bar{B}^T$.

The training algorithm of Eq. (19) determines the parameters $\bar{a}$ of the closed-loop transfer function, ensuring that the gains K^{pid} are optimal. The topology of S-ANN is illustrated in Fig. 10, where the S-ANN inputs are the components of the error vector $\bar{a}$ and S-ANN outputs are those of the gain vector K^{pid} associated with Eq. (13).




Fig. 10. Structured artificial neural network topology.

The strategies for tuning the gains of the PID controller by an S-ANN are implemented such that the training algorithm of the S-ANN determines the gains of the PID controller for changes in the dynamic behavior of the plant. The gradient error of Eq. (18) is calculated as follows:

$$\varepsilon(K^{pid}) = \bar{B}^T \bar{B} K^{pid} - \bar{B}^T \bar{b}_i \quad (20)$$

The control system algorithm related to Fig. 10 is divided into six modules for better understanding, as presented in the PID_{S-ANN} algorithm:

PID_{S-ANN} ALGORITHM

```

1  ▷ - Module 0 - Setup (Initial Conditions)
2  ▷ Learning Rate -  $\eta \leftarrow [ \quad ]$ 
3  ▷ Parameters of the Transfer Function -  $[b_i, a_i] \leftarrow [ \quad ]$ 
4  ▷ Iterative Process
5  for  $i \leftarrow 0 : N$ 
6      do
7          ▷ - Module 1 - Sensors
8          ▷ a) readings - u and y
9           $[y, x] \leftarrow read_{xy}(x, y, p_x, p_y)$ 
10         ▷ - Module 2 - RLS Estimator of Plant Parameters
11          $b(i) \leftarrow num_{3p}(1, i)$ 
12          $a(i) \leftarrow den_{3p}(1, i)$ 
13         ▷ - Module 3 - Design Specifications
14          $[V_c, V_{\omega_n}] \leftarrow [par_1, \dots, par_3]$ 
15         ▷ - Module 4 - Coefficient Comparator
16          $[\Delta(ab)] \leftarrow [(a_i, b_i), (a_i^s, \bar{b}_i), par_{ab}]$ 
17         ▷ - Module 5 - Adaptive and Optimal Tuning
18          $[K^{pid}] \leftarrow f_{ANN}(K_P, K_I, K_D, \Delta(ab))$ 
19         ▷ - Module 6 - Gain Transfer Scheme  $K_{PID}$ 
20          $[PID_{cont}] \leftarrow K^{pid}$ 
21 End - Iterative Process

```

C. PID-Fuzzy Model

Classical fuzzy inference methods may not work to their full potential because the given knowledge base may not cover the entire domain of the problem. Due to the requirements of fuzzy systems may change over time [47] [28]. In this study, the parameters of the gain vector K^{pid} are scheduled by fuzzy rules during the operational process according to the plant parametric variations so as to guarantee that the stability of the control system is maintained independent of the changes in its requirements [48] [49].

The PID-fuzzy controller model presented here was proposed by Zhao and Tomizuka [27]. This model was customized to the operational processes of the evaluated plants. The PID-fuzzy control design uses a fuzzy rule-based system for tuning the PID controller by scheduling the gains online. The fuzzy system assumes the values K_P , K_D , and K_I determined by S-ANN, and the PID-fuzzy controller inputs are the error $e(t)$ and its derivative $\dot{e}(t)$ and the outputs are K'_P , K'_D , and K'_I , where K'_P and K'_D are the normalized gains in the range of 0 to 1 determined through a linear transformation and α is a parameter used to calculate the gain K'_I . For convenience, K_P and K_D are normalized into the range between zero and one by the following linear transformation.

The fuzzy sets C_i and D_i may be either big or small, and are characterized by the membership functions, where the grade of the membership functions, μ , and the variable x is K'_P or K'_D have the relation $\mu_{SMALL}(x) = -\frac{1}{4} \ln x$ or $x_{SMALL}(\mu) = e^{-4\mu}$ for small and $\mu_{BIG}(x) = -\frac{1}{4} \ln(1-x)$ or $x_{BIG}(\mu) = 1 - e^{-4\mu}$ for big.

That is, the PID controller should have a small proportional gain, a large derivative gain, and a small integral gain. Thus, the following fuzzy rule is taken

if $e(k)$ is ZO and $\Delta e(k)$ is NB; then, K'_P is small, K'_D is big, and $\alpha = 5$.

The truth value of the i -th rule μ_i is obtained by the product of the MF values in the antecedent part of the rule

$$\mu_i = \mu_{A_i}[e(k)] \cdot \mu_{B_i}[\Delta e(k)], \quad (21)$$

where μ_{A_i} is the MF value of the fuzzy set A_i given a value of $e(k)$ and μ_{B_i} is the MF value of the fuzzy set B_i given a value of $\Delta e(k)$.

By using the membership functions, one has the following condition [50]:

$$\sum_{i=1}^m \mu_i = 1. \quad (22)$$

Then, the defuzzification yields the following:

$$K'_P = \sum_{i=1}^m \mu_i K'_{P,i}, \quad (23)$$

$$K'_D = \sum_{i=1}^m \mu_i K'_{D,i}, \quad (24)$$

$$\alpha = \sum_{i=1}^m \mu_i \alpha_i. \quad (25)$$

Here, $K'_{P,i}$ is the value of K'_P corresponding to grade μ_i for the i -th rule and $K'_{D,i}$ is obtained similarly [27].

The parameters K'_P , K'_D , and K'_I are determined from a set of rules *fuzzy*. The fuzzy logic model comprises a fuzzy inference system of the Mamdani type with two inputs, which are the error $e(t)$ and its derivative $\dot{e}(t)$, and three outputs: K'_P , K'_I , and K'_D . These are the online parameters of the PID controller.

The fuzzy PID controller has seven linguistic terms, where 49 rules are used, as can be observed in Table I, where system errors and PID controller gains are related. The membership function adopted is that of Mamdani, implemented with the minimum operator, and the defuzzification method adopted is the center of the gravity method, which assures a smooth and continuous control surface.

TABLE I
TUNING RULES FOR THE OUTPUTS K'_P AND K'_D FROM THE INPUTS $e(t)$ AND $\dot{e}(t)$.

$e(t) \backslash \dot{e}(t)$	NB	NM	NS	ZO	PS	PM	PB
NB	B/S	B/S	B/S	B/S	B/S	B/S	B/S
NM	S/B	B/B	B/S	B/S	B/S	B/S	B/S
NS	S/B	S/B	B/B	B/S	B/B	S/B	S/B
ZO	S/B	S/B	S/B	B/S	S/B	S/B	S/B
PS	S/B	S/G	B/B	B/S	B/B	S/B	S/B
PM	S/B	B/B	B/S	B/S	B/S	B/B	S/B
PB	B/S	B/S	B/S	B/S	B/S	B/B	B/b

TABLE II
TUNING RULES FOR α FROM THE INPUTS $e(t)$ AND $\dot{e}(t)$.

$\dot{e}(t) \backslash e(t)$	NB	NM	NS	ZO	PS	PM	PB
NB	2	2	2	2	2	2	2
NM	3	3	2	2	2	3	3
NS	4	3	3	2	3	3	4
ZO	5	4	3	3	3	4	5
PS	4	3	3	2	3	3	4
PM	3	3	2	2	2	3	3
PB	2	2	2	2	2	2	2

D. PID-Neuro-Fuzzy Model

In this section, the proposed PID-neuro-fuzzy model is presented. In recent years, intelligent industrial systems and consumer electronics have been widely and intensely developed, incorporating fuzzy logic, neural network, and neuro-fuzzy technology. The fuzzy control is very useful for designing and controlling complex systems whose mathematical model cannot be easily obtained. In this case, the IF-THEN-type fuzzy rules are used to express the skillful operator experience and to control the expert knowledge. This linguistic approach of the fuzzy theory allows the fusion of symbol processing and numerical computation. On the other hand, the artificial neural network provides versatile functions such as pattern recognition, identification, and prediction of nonlinear systems, as well as diagnosis and control [51] [52].

In general, the methodology of the control system proposed in this study is presented in the form of a block diagram. The control system topology for optimal online tuning of the controller gain parameters via S-ANN is illustrated in Fig. 11, where a_i is the reference value, a_i^e is the i -th component of the error vector $\bar{a}$, K^{pid} is the PID controller gain vector, $U(s)$ is the plant input, $G(s)$ is the plant transfer function, $\bar{G}(s)$ is the specified plant transfer function, S-ANN is the structured artificial neural network, and a_i^s are the specified transfer function parameters. In addition, $W(s)$ is the disturbance in the plant parameters; the Fuzzy block is the controller based on fuzzy rules having the error e_i and its derivative $\dot{e}_i$ as inputs and the gain vector K^{pid} as the output; $Y_m(s)$ is the output measured by the sensors; and $Y(s)$ is the plant output.




Fig. 11. Topology of the PID-Neuro-Fuzzy model.

The design of the PID controller with optimal gains determined by an S-ANN in conjunction with the fuzzy gain scheduling control, proposed in this study, was developed to act as follows: the proportional action adjusts the controller output according to the variation in the error, the integral action eliminates the steady-state offset, and the future behavior is anticipated by the derivative action.

IV. COMPUTATIONAL EXPERIMENTS

In this section, we present the computational experiments that were executed in the MATLAB software with real data of the operational processes that are associated with the plants presented in Section III.

A. Setup

The experiments are initiated by identifying the mathematical models of the plants. Then, the gains K^{pid} are determined by the second Ziegler-Nichols method. An analysis of the influence of the coefficients a_i of the transfer function in the three terms of the PID controller is performed, and the new parameters a_i^s are specified. After that, an S-ANN is designed for each plant to determine the coefficients a_i^e , resulting in the gain vector K^{pid} . Then, the fuzzy controller performs online scheduling of the gains K^{pid} , which were determined by the second method of Ziegler-Nichols and by S-ANN. Following that, the parameters a_i of the transfer functions were altered and regenerated by S-ANN through the pole placement. Finally, the comparative analyses of the performances of the controllers presented in this study are carried out.

B. Simulation Results

This subsection shows the individual results of the five plants evaluated in this study, with the parameters of the gain vector K^{pid} initially determined by the second Ziegler-Nichols method and by the S-ANN algorithm, indicating the root locus and zeros of the open- and closed-loop transfer functions. Furthermore, the results are presented under three aspects. First, the plant behavior is evaluated with respect to the following reference value and error behavior. Second, the rejection to sudden disturbances inserted in the plant is analyzed, and finally, the adaptability

to the variations occurring in the parameters a_i^s of the transfer functions of the plants is assessed.

1) *Plant I*: Plant I is a second-order system represented by the transfer function associated with Eq. (1), which is given by

$$G^{PI}(s) = \frac{0.438s + 0.03861}{s^2 + 0.086096s + 0.04215}, \quad (26)$$

Table III shows the gains K_P , K_I , and K_D determined by the second Ziegler-Nichols method and by the structured neural network, which generated the closed-loop transfer functions.

TABLE III
METHOD USED TO DETERMINE THE GAINS OF THE PROPOSED CONTROLLERS.

Plant	2nd Method	K_P	K_I	K_D
I	ZN	0.4334	2.3723×10^{-2}	0.7232
	S-ANN	8.6581	4.8104	19.1234

With the gains K_P , K_I , and K_D determined by the second Ziegler-Nichols method, the closed-loop transfer function for Plant I, which is given by

$$G_{ZN}^{PI} = \frac{0.2891s^3 + 0.0444s^2 + 0.0127s + 0.0010}{1.2891s^3 + 0.13056s^2 + 0.0549s + 0.0010}, \quad (27)$$

and with the gains K_P , K_I , and K_D determined by S-ANN, the closed-loop transfer function for Plant I is given by

$$G_{S-ANN}^{PI} = \frac{0.1898s^3 + 0.0271s^2 + 0.3177s + 0.0279}{1.1898s^3 + 0.1132s^2 + 0.3598s + 0.0279} \quad (28)$$

2) *Plant II*: Plant II is a third-order system and its transfer function, associated with Eq. (2), is given by

$$G^{PII}(s) = \frac{0.1812s + 0.0871}{s^3 + 0.3553s^2 + 0.1117s + 0.01567}, \quad (29)$$

Table IV shows the gains K_P , K_I , and K_D determined by the second Ziegler-Nichols method and by the S-ANN that generated the new transfer functions.

TABLE IV
METHOD USED TO DETERMINE THE GAINS OF THE PROPOSED CONTROLLERS.

Plant	2nd Method	K_P	K_I	K_D
II	ZN	1.9867	0.123×10^{-2}	0.343
	S-ANN	0.09960	0.33	0.0252

With the gains K_P , K_I , and K_D determined by the second Ziegler-Nichols method, the closed-loop transfer function for Plant II is given by

$$G_{ZN}^{PII} = \frac{\left(\begin{array}{l} 0.1214s^3 + 0.6563s^2 \\ +0.2936s + 0.0030 \end{array} \right)}{\left(\begin{array}{l} s^4 + 0.4767s^3 + 0.7680s^2 \\ +0.3093s + 0.0030 \end{array} \right)}, \quad (30)$$

and with the gains K_P , K_I , and K_D determined by the S-ANN, the closed-loop transfer function for Plant II is given by

$$G_{S-ANN}^{PII} = \frac{\left(\begin{array}{l} 0.1329s^3 + 0.0698s^2 \\ +0.0074s + 0.0022 \end{array} \right)}{\left(\begin{array}{l} 1s^4 + 0.4882s^3 + 0.1815s^2 \\ +0.0231s + 0.0022 \end{array} \right)}. \quad (31)$$

3) *Plant III*: Plant III is of fourth order and is obtained from the transfer functions of Eqs. (32) and (33) of feeders 1 and 2 associated with Eq. (3):

$$G_1^{CD}(s) = \frac{0.438s + 0.03861}{s^2 + 0.086096s + 0.04215}. \quad (32)$$

$$G_2^{CD}(s) = \frac{0.521ss + 0.04715}{s^2 + 0.0906s6s + 0.2964}. \quad (33)$$

Replacing Eqs. (32) and (33) with Eq. (3), one obtains

$$G^{PIII}(s) = \frac{\left(\begin{array}{l} 0.959s^3 + 0.1698s^2 \\ +0.1593s + 0.01331 \end{array} \right)}{\left(\begin{array}{l} s^4 + 0.1767s^3 + 0.3463s^2 \\ +0.0293s + 0.0125 \end{array} \right)} \quad (34)$$

Table V shows the gains K_P , K_I , and K_D determined by the second Ziegler-Nichols method and by the S-ANN that generated the new transfer functions.

TABLE V
METHOD USED TO DETERMINE THE GAINS OF THE PROPOSED CONTROLLERS.

Plant	2nd Method	K_P	K_I	K_D
III	ZN	0.9867	0.123×10^{-2}	0.553
	S-ANN	0.67	0.3×10^{-2}	0.0343

With the gains K_P , K_I , and K_D determined by the second Ziegler-Nichols method, the closed-loop transfer function for Plant III is given by

$$G_{ZN}^{PIII} = \frac{\left(\begin{array}{l} 0.9462s^5 + 0.1793s^4 + 0.6896s^3 \\ +0.1090s^2 + 0.0883s + 0.0074 \end{array} \right)}{\left(\begin{array}{l} 1.9462s^5 + 0.3560s^4 + 1.0359s^3 \\ +0.1383s^2 + 0.1008s + 0.0074 \end{array} \right)}, \quad (35)$$

and with the gains K_P , K_I , and K_D determined by the S-ANN, the closed-loop transfer function for Plant III is given by

$$G_{S-ANN}^{P_{III}} = \frac{\begin{pmatrix} 0.6425s^5 + 0.1166s^4 + 0.1401s^3 \\ +0.0152s^2 + 0.0055s + 0.0005 \end{pmatrix}}{\begin{pmatrix} 1.6425s^5 + 0.2933s^4 + 0.4864s^3 \\ +0.0445s^2 + 0.0180s + 0.0005 \end{pmatrix}} \quad (36)$$

4) *Plant IV*: Replacing Eqs. (26) and (29) with Eq. (4), one obtains the transfer function of Plant IV, which is given by

$$G^{P_{IV}}(s) = \frac{\begin{pmatrix} 0.438s^4 + 0.4522s^3 + 0.1331s^2 \\ +0.02924s + 0.001481 \end{pmatrix}}{\begin{pmatrix} s^5 + 1.806s^4 + 1.048s^3 + 0.2296s^2 \\ +0.02914s + 0.001031 \end{pmatrix}}, \quad (37)$$

Table VI shows the gains K_P , K_I , and K_D determined by the second Ziegler-Nichols method and by the S-ANN that generated the new transfer functions.

TABLE VI
METHOD USED TO DETERMINE THE GAINS OF THE PROPOSED CONTROLLERS.

Plant	2nd Method	K_P	K_I	K_D
IV	ZN	1.5867	0.23×10^{-2}	0.0123
	S-ANN	0.67	0.3×10^{-2}	0.0343

With the gains K_P , K_I , and K_D determined by the second Ziegler-Nichols method, the closed-loop transfer function for Plant IV is given by

$$G_{ZN}^{P_{IV}} = \frac{\begin{pmatrix} 0.6950s^6 + 0.168s^5 + 0.4929s^4 \\ +0.1542s^3 + 0.0108s^2 \\ +0.0012s + 0.0001 \end{pmatrix}}{\begin{pmatrix} 1.6950s^6 + 1.8630s^5 + 0.9785s^4 \\ +0.2823s^3 + 0.0290s^2 \\ +0.0019s + 0.0005 \end{pmatrix}}, \quad (38)$$

and with the gains K_P , K_I , and K_D determined by S-ANN, the closed-loop transfer function for Plant IV is given by

$$G_{S-ANN}^{P_{IV}} = \frac{\begin{pmatrix} 0.2935s^6 + 0.2613s^5 + 0.2217s^4 \\ +0.0770s^3 + 0.0137s^2 \\ +0.0032s + 0.0001 \end{pmatrix}}{\begin{pmatrix} 1.2935s^6 + 1.5075s^5 + 0.7073s^4 \\ +0.2051s^3 + 0.0319s^2 \\ +0.0039s + 0.0001 \end{pmatrix}}, \quad (39)$$

5) *Plant V*: The transfer function of Plant V is obtained by substituting Eq. (29) into Eq. (5):

$$G^{P_V}(s) = \frac{\begin{pmatrix} 0.3624s^4 + 0.31383s^3 + 0.1076s^2 \\ +0.025137s + 0.0027297 \end{pmatrix}}{\begin{pmatrix} s^6 + 0.7706s^5 + 0.37186s^4 \\ +0.11742s^3 + 0.024552s^2 \\ +0.0035007s + 0.00024 \end{pmatrix}}, \quad (40)$$

Table VII shows the gains K_P , K_I , and K_D determined by the second Ziegler-Nichols method and by the S-ANN that generated the new transfer functions.

TABLE VII
METHOD USED TO DETERMINE THE GAINS OF THE PROPOSED CONTROLLERS.

Plant	2nd Method	K_P	K_I	K_D
V	ZN	0.47	0.298×10^{-2}	0.0526
	S-ANN	0.656	0.3324×10^{-3}	0.0343

With the gains K_P , K_I , and K_D determined by the second Ziegler-Nichols method, the closed-loop transfer function for Plant V is given by

$$G_{ZN}^{P_V} = \frac{\begin{pmatrix} 0.2126s^6 + 0.1848s^5 + 0.0788s^4 \\ +0.0279s^3 + 0.0061s^2 \\ +0.0010s + 0.0001 \end{pmatrix}}{\begin{pmatrix} 1s^7 + 0.9832s^6 + 0.5568s^5 + 0.1962s^4 \\ +0.0525s^3 + 0.0096s^2 \\ +0.0012s + 0.0001 \end{pmatrix}}, \quad (41)$$

and with the gains K_P , K_I , and K_D determined by the S-ANN, the closed-loop transfer function for Plant V is given by

$$G_{S-ANN}^{P_V} = \frac{\begin{pmatrix} 0.2066s^6 + 0.1796s^5 + 0.0780s^4 \\ +0.0284s^3 + 0.0064s^2 \\ +0.0011s + 0.0002 \end{pmatrix}}{\begin{pmatrix} s^7 + 0.9772s^6 + 0.5515s^5 \\ +0.1954s^4 + 0.0530s^3 + 0.0099s^2 \\ +0.0013s + 0.0002 \end{pmatrix}}. \quad (42)$$

6) *Reference Value Following*: The behavior of the plants for the three controller models is evaluated in relation with the control target range and following the reference value, from the formation of the coefficients a_i of the plants by means of the desired poles, these poles directly impact on the dynamics of the system, ie, inferring in the values of the figures of merits, such as: overshoot, rise time and stationary error. As shown in Figs. 12-16, where the system with the PID-neuro-fuzzy controller presents the smallest rise time, smallest overshoot, time to hit the control target, and steady-state error, presented in the same figure, where in the upper part one has the

behavior of the control variables in continuous lines and in the lower part, we have the error in dashed lines. Figs 12-16 are obtained from Eqs. (26), (29), (34), (37) and (40).




Fig. 12. Reference signal following behavior for Plant I with PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers and behavior of their respective errors.




Fig. 14. Reference signal following behavior for Plant III with PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers and behavior of their respective errors.




Fig. 15. Reference signal following behavior for Plant IV with PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers and behavior of their respective errors.




Fig. 13. Reference signal following behavior for Plant II with PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers and behavior of their respective errors.




Fig. 16. Reference signal following behavior for Plant V with PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers and behavior of their respective errors.

7) *Disturbance Rejection:* To evaluate the rejection to disturbance signals in the plants during the operational process, a disturbance signal of 80% of the reference value was inserted at 10 s intervals, as shown in Figs. 17-21. The controller resulting from the PID-neuro-fuzzy model achieved the best performance, that is, after the disturbance signal is applied, the controller keeps the plant stabilized with small oscillations around the reference value, demonstrating its rejection to sudden disturbances in plant parameters.




Fig. 17. Plant I behavior with respect to the rejection of disturbance signal of 80% for the PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers and behaviors of their respective errors.




Fig. 18. Plant II behavior with respect to the rejection of disturbance signal of 80% for the PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers and behaviors of their respective errors.




Fig. 19. Plant III behavior with respect to the rejection of disturbance signal of 80% for the PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers and behaviors of their respective errors.




Fig. 20. Plant IV behavior with respect to the rejection of disturbance signal of 80% for the PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers and behaviors of their respective errors.




Fig. 21. Plant V behavior with respect to the rejection of disturbance signal of 80% for the PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers and behaviors of their respective errors.

8) *Evaluation Adaptability*: The proposed model is evaluated with respect to the adaptability to the parametric variations in the parameters a_i of the transfer functions and compared with the results of the PID-ZN and PID-Fuzzy controllers in the three primary plants (Group I) of orders 2, 3, and 4, respectively, of the operating processes of the mining industry. The same procedure can be used for the secondary plants (Group II). For the evaluation of adaptability, the transfer functions have their parameters a_i changed and then simulations are conducted with the new transfer functions.

First case - Plant I represented by the transfer function given by Eq. (26) is evaluated. A sudden disturbance was added in the parameters a_i of the plant generating the new transfer function, given by

$$G_{New}^{P_I} = \frac{0.438s + 0.03861}{s^2 + 1.08609s + 1.04215} \quad (43)$$

The original transfer function of plant I is regenerated by S-ANN, according to the general expression

$$G^{P_I}(s) = KG_{New}^{P_I}(s) = G_{Reg}^{P_I}(s), \quad (44)$$

where $G^{P_I}(s)$ is the original transfer function of the plant, $G_{New}^{P_I}(s)$ is the new transfer function of plant I, and $G_{Reg}^{P_I}(s)$ is the regenerated transfer function of plant I.

Second case -Plant II represented by the transfer function given by Eq. (29) is evaluated. Similar to the first case, a sudden disturbance was added in the parameters a_i of the plant generating the new transfer function, given by

$$G_{New}^{P_{II}}(s) = \frac{0.1812s + 0.0871}{s^3 + 1.3553s^2 + 1.1117s + 1.01567}, \quad (45)$$

The original transfer function of plant II is regenerated by S-ANN, according to the general expression

$$G^{P_{II}}(s) = KG_{New}^{P_{II}}(s) = G_{Reg}^{P_{II}}(s), \quad (46)$$

where $G^{P_{II}}(s)$ is the original transfer function of the plant, $G_{New}^{P_{II}}(s)$ is the new plant transfer function of plant II, and $G_{Reg}^{P_{II}}(s)$ is the regenerated transfer function of plant II.

Third case - Plant III represented by the transfer function given by Eq. (34) is evaluated taking into account sudden disturbance in its parameters a_i , except in the parameter a_4 , generating the new transfer function, given by

$$G_{New}^{P_{III}} = \frac{\begin{pmatrix} 0.956s^3 + 0.169s^2 \\ +0.1593s + 0.01331 \end{pmatrix}}{\begin{pmatrix} s^4 + 1.1767s^3 + 0.3463s^2 \\ +0.0293s + 0.0125 \end{pmatrix}} \quad (47)$$

Note: The parameter a_4 da Eq. (47) was kept constant, due to the instability caused by the addition of 1 in its value, not allowing a good graphical representation of

the behavior of the new plant III $G_{New}^{P_{III}}(s)$ PID-Fuzzy controllers in the same figure.

The original transfer function of plant III is regenerated by S-ANN, according to the general expression

$$G^{P_{III}}(s) = KG_{New}^{P_{III}}(s) = G_{Reg}^{P_{III}}(s), \quad (48)$$

where $G^{P_{III}}(s)$ is the original transfer function of the plant, $G_{New}^{P_{III}}(s)$ is the new plant transfer function of III plant, and $G_{Reg}^{P_{III}}(s)$ is the regenerated transfer function of plant III.

The specified parameters a_i^s of the transfer functions of the primary plants (CD with 1 feeder, BWR and CD with 2 feeders) are presented in Table VIII.

TABLE VIII
SPECIFIED PARAMETERS a_i^s .

a_i^s	G^{P_I}	$G^{P_{II}}$	$G^{P_{III}}$
a_1^s	0.8609	0.3553	0.1767
a_2^s	0.04215	0.1117	0.3463
a_3^s	-	0.01567	0.0293
a_4^s	-	-	0.0125

In Table IX, the coefficients a_i^N that have suffered a sudden disturbance in the specified parameters a_i^s of the transfer functions of the presented plants are highlighted in red.

TABLE IX
NEW PARAMETERS a_i^N .

a_i^N	$G_{New}^{P_I}$	$G_{New}^{P_{II}}$	$G_{New}^{P_{III}}$
a_1^N	1.8609	1.3553	1.1767
a_2^N	1.04215	1.1117	1.3463
a_3^N	-	1.01567	1.0293
a_4^N	-	-	0.0125

We observe the adaptability to the parametric variations in the evaluated plants of the proposed tuning model, in comparison with Table VIII, where all parameters a_i^s , highlighted in red, suffered sudden disturbances and had their parameters regenerate a_i^R by the algorithm S-ANN returning the original configuration, as highlighted in blue as shown in Table X.

TABLE X
REGENERATED PARAMETERS a_i^R .

a_i^R	$G_{Reg}^{P_I}$	$G_{Reg}^{P_{II}}$	$G_{Reg}^{P_{III}}$
a_1^R	0.8609	0.3553	0.1786
a_2^R	0.04215	0.1126	0.3462
a_3^R	-	0.01587	0.0291
a_4^R	-	-	0.0125

The behaviors of Plants I, II, and III for the three models of controllers presented here are illustrated in Figs. 22-24. The behaviors with the functions of original transfers of the plant are represented by solid lines, and those of the plants with the transfer functions with their changed parameters a_i are represented by dashed lines. For better understanding, the result with the new transfer functions is delayed by 5 s. As can be seen, the proposed model allocates poles to maintain the desired operating point, faithfully following the same behavior before changes in the parameters a_i of the transfer functions, whereas PID-ZN and PID-Fuzzy do not adapt to these changes suffered in parameters a_i of the transfer functions, taking a long time to enter in a state error.




Fig. 22. Plant-I adaptability in terms of following the reference for PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers after abrupt changes in the coefficients a_i of the transfer function as measured in the first case.




Fig. 23. Plant-II adaptability in terms of following the reference for PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers after abrupt changes in the coefficients a_i of the transfer function as measured in the second case.




Fig. 24. Plant-III adaptability in terms of following the reference for PID-Neuro-Fuzzy, PID-Fuzzy and PID-ZN controllers after abrupt changes in the coefficients a_i of the transfer function as measured in the third case.

V. CONCLUSION

Through the experiments conducted in this study, it was observed that our proposed PID-neuro-fuzzy controller model exhibited good performance, obtaining the smallest overshoots, shortest rise times, and lower settling time. This good performance of the proposed model is achieved through the S-ANN algorithm, which imposes the specified parameters. If there are parametric variations in the plants, these parameters were self-adjusted online by fuzzy rules. Also, the proposed controller presented good results for perturbations rejections in the plant.

Even with high perturbation signals inserted in the plants, the system did not lose stability, presenting small oscillations around the reference point, without reaching a significant loss of the trajectories. In addition, the proposed controller obtained the lowest errors for all evaluated plants and better adapted to the parametric variations simulated disturbance the operational process of the plants.

The optimal tuning of the PID controller with the vector gains K^{pid} determined by the S-ANN algorithm are combined with the fuzzy rules to perform online adjustments of these gains, achieving satisfactory performance that meets the design specifications of the five plants evaluated.

In this context, the specified parameters by the designer have been regenerated after the occurrence of sudden disturbance, guaranteeing the desired point of operation. Therefore, it is concluded that the proposed methodology is feasible and can be implemented because the gains are determined by an S-ANN and the adjustments are made online by fuzzy rules. The analyzed plants have their operational processes automated and implemented in industrial PLCs, which already come with PID and Fuzzy control modules built into their structures.

The continuity of this proposal is to develop the S-ANN algorithm combined with the fuzzy rules, in addition to determining and adjusting the PID controller gains based on the parametric variations of the plants, to include new

approaches for systems embedded in PLCs or dedicated platforms for the control of the process of bulk recovery by BWR, making it feasible to implement it in real plants.


ACKNOWLEDGMENT

We thank PPGE of the Federal University of Maranhão (UFMA) for the technical/scientific and practical lessons. We are especially grateful to FAPEMA for encouraging high-level research in the State of Maranhão. We also thank the Department of Physics of the State University of Maranhão (UEMA) for making this research feasible. We thank CAPES for promoting and supporting advanced research, which contributed to this study. Finally, we thank the Vale S.A. Company for providing its specialists for practical guidance for the execution of the experiments.

REFERENCES

- [1] Garpinger, Olof, (2015). Analysis and Design of Software-Based Optimal PID Controllers. Department of Automatic Control, Lund Institute of Technology, Lund University.
- [2] Yordanova, Snezana and Slavov, Milen and Gueorguiev, Branimir, (2018). Parallel Distributed Compensation for Improvement of Level Control in Carbonization Column for Soda Production. Control Engineering Practice. volume 71. Elsevier, pp. 53–60.
- [3] Khosravi, A and Koury, RNN and Machado, L and Pabon, JJG, (2018). Prediction of Wind Speed and Wind Direction Using Artificial Neural Network, Support Vector Regression and Adaptive Neuro-Fuzzy Inference System. Sustainable Energy Technologies and Assessments. volume 25. Elsevier, pp. 146–160.
- [4] Åström, Karl Johan and Hägglund, Tore, (2005). Advanced PID control. ISA-The Instrumentation, Systems and Automation Society
- [5] K.J. Åström and T. Hägglund, (2000). The Future of PID Control. IFAC Proceedings, volume 33, number 4, pp. 19–30. ISSN 1474-6670.
- [6] K.J. Åström and T. Hägglund, (1995). PID Controllers: Theory, Design, and Tuning. Instrument Society of America, Research Triangle Park, NC. Edition 3.
- [7] Li, Yun and Ang, KH and Chong, CCY, (2006). PID Control System Analysis and Design - Problems, Remedies, and Future Directions. IEEE control systems, volume 26.
- [8] O'Dwyer, A., (2009). Handbook of PI and PID Controller Tuning Rules. Imperial College Press
- [9] Webb, Andrew and Davies, Sergio and Lester, David, (2011). Spiking Neural PID Controllers. International Conference on Neural Information Processing. Springer, pp. 259–267.
- [10] Wu, Huai-Ning, and Zi-Peng Wang, (2018). Observer-Based H_∞ Sampled-Data Fuzzy Control for a Class of Nonlinear Parabolic PDE Systems. DOI: 10.1109/TFUZZ.2017.2686337.
- [11] P. Shi, F. B. Li, L. G. Wu, C. C. Lim, (2017). Neural Network-Based Passive Filtering for Delayed Neutral-Type Semimarkovian Jump Systems, IEEE Transactions on Neural Networks and Learning Systems, vol.28, no.9, pp.2101-2114.
- [12] M. Chen, S. S. Ge, B. V. E. How, (2010). Robust Adaptive Neural Network Control for a Class of Uncertain MIMO Nonlinear Systems with Input Nonlinearities, IEEE Transactions on Neural Networks, vol. 21, no. 5, pp. 796-812.
- [13] S. C. Tong, S. Sui, Y. M. Li, (2015). Fuzzy Adaptive Output Feedback Control of MIMO Nonlinear Systems with Partial Tracking Errors Constrained, IEEE Transactions on Fuzzy Systems, vol. 23, no. 4, pp. 729-742.
- [14] S. C. Tong, Y. M. Li, P. Shi, (2012). Observer-Based Adaptive Fuzzy Backstepping Output Feedback Control of Uncertain MIMO Pure-Feedback Nonlinear Systems, IEEE Transactions on Fuzzy Systems, vol. 20, no. 4, pp. 771-785.
- [15] Y. M. Li, S. C. Tong, T. S. Li, (2016). Hybrid fuzzy adaptive output feedback control design for uncertain MIMO nonlinear systems with time-varying delays and input saturation, IEEE Transactions on Fuzzy Systems, vol. 24, no. 4, pp. 841-853.
- [16] Y. M. Li, S. C. Tong, (2017). Command-Filtered-Based Fuzzy Adaptive Control Design for MIMO Switched Nonstrict-Feedback Nonlinear Systems, IEEE Transactions on Fuzzy Systems, vol.25, no.3, pp.668-681.
- [17] Li, Yongming, Kangkang Sun, and Shaocheng Tong, (2018). Adaptive Fuzzy Robust Fault-Tolerant Optimal Control for Nonlinear Large-Scale Systems. IEEE Transactions on Fuzzy Systems 26.5: 2899-2914.
- [18] P. Gil and C. Lucena and A. Cardoso and L. B. Palma, (2015). Gain Tuning of Fuzzy PID Controllers for MIMO Systems: A Performance-Driven Approach. IEEE Transactions on Fuzzy Systems, volume 23, number 4, pages 757-768.
- [19] S. Dettori and V. Iannino and V. Colla and A. Signorini, (2018). An Adaptive Fuzzy Logic-Based Approach to PID Control of Steam Turbines in Solar Applications. Journal Applied Energy, volume 227, pages 655 - 664.
- [20] Haocai Huang and Shuqing Zhang and Zhao Yang and Yongqiang Tian and Xiang Zhao and Zhuoli Yuan and Shuai Hao and Jianxing Leng and Yan Wei, (2018). Modified Smith Fuzzy PID Temperature Control in an Oil-replenishing Device for Deep-sea Hydraulic System. Journal Ocean Engineering, volume 149, pages =14 – 22.
- [21] K. Premkumar and B.V. Manikandan, (2015). Fuzzy PID supervised online ANFIS based speed controller for brushless dc motor. Journal Neurocomputing, volume 157, pages 76 – 90.
- [22] G.L. Demidova and D.V. Lukichev and A.Yu. Kuzin, (2019). A Genetic Approach for Auto-Tuning of Adaptive Fuzzy PID Control of a Telescope's Tracking System. Journal Procedia Computer Science, volume 150, pages 495 – 502 .
- [23] Gil, Paulo and Lucena, Catarina and Cardoso, Alberto and Palma, Luis Brito, (2015). Gain tuning of fuzzy PID controllers for MIMO systems: a performance-driven approach. IEEE Transactions on Fuzzy Systems, volume 23, number 4, pages=757–768.
- [24] Ziegler, John G and Nichols, Nathaniel B., (1942). Optimum settings for automatic controllers. Trans. ASME, volume 64, number 11, pp. 759–768.
- [25] Liu, Yan-Jun and Li, Dong-Juan and Tong, Shaocheng, (2014). Adaptive Output Feedback Control for a Class of Nonlinear Systems With Full-state Constraints. International Journal of Control, volume 87, number 2, pp. 281–290.
- [26] Liu, Yan-Jun and Gong, Mingzhe and Tong, Shaocheng and Chen, CL Philip and Li, Dong-Juan, (2018). Adaptive Fuzzy Output Feedback Control for a Class of Nonlinear Systems With Full-state Constraints. IEEE Transactions on Fuzzy Systems.
- [27] Zhao, Zhen-Yu and Tomizuka, Masayoshi and Isaka, Satoru, (1993). Fuzzy Gain Scheduling of PID Controllers. IEEE Transactions on Systems, Man, and Cybernetics, volume 23, number 5, pp. 1392–1398.
- [28] Singh, Samarth and Mitra, R., (2014). Comparative Analysis of Robustness of Optimally Offline Tuned PID Controller and Fuzzy Supervised PID Controller. IEEE-Engineering and Computational Sciences (RAECS), pp. 1–6.
- [29] Dehghani, Ali and Khodadadi, Hamed, (2017). Designing a Neuro-Fuzzy PID Controller Based on Smith Predictor for Heating System. IEEE-Control, Automation and Systems (ICCAS), pp. 15–20.
- [30] Haghiabi, Amir Hamzeh and Parsaie, Abbas and Ememgholizadeh, Samad, (2018). Prediction of Discharge Coefficient of Triangular Labyrinth Weirs Using Adaptive Neuro Fuzzy Inference System. Alexandria Engineering Journal, volume 55, number 3. Elsevier, pp. 1773–1782.
- [31] Chopra, Vikram and Singla, Sunil K and Dewan, Lillie, (2014). Comparative Analysis of Tuning a PID Controller Using Intelligent Methods. volume 11, number 8, pp. 235–249.
- [32] Li, Jinghao and Zhang, Qingling and Yan, Xing-Gang and Spurgeon, Sarah, (2018). Observer-Based Fuzzy Integral Sliding Mode Control For Nonlinear Descriptor Systems. IEEE Transactions on Fuzzy Systems
- [33] Bosque, Guillermo and del Campo, Inés and Echanobe, Javier, (2014). Fuzzy Systems, Neural Networks and Neuro-Fuzzy Systems: A Vision on Their Hardware Implementation and Platforms Over Two Decades. Engineering Applications of Artificial Intelligence, volume 32. Elsevier, pp. 283–331.
- [34] Hong, Haoyuan and Panahi, Mahdi and Shirzadi, Ataollah and Ma, Tianwu and Liu, Junzhi and Zhu, A-Xing and Chen, Wei and Kougiass, Ioannis and Kazakis, Nerantzis, (2018). Flood Susceptibility Assessment in Hengfeng Area Coupling Adaptive

- Neuro-Fuzzy Inference System With Genetic Algorithm and Differential Evolution. *Science of The Total Environment*, volume 621. Elsevier, pp. 1124–1141.
- [35] Li, Lian and Jia, Dong, (2017). Research on Air Conditioning System of Subway Station Based on Fuzzy PID Control. *IEEE-Information Science and Control Engineering (ICISCE)*, pp. 1131–1134.
- [36] Rossomando, F.G. and Soria, C.M., (2015). *Latin America Transactions, IEEE (Revista IEEE America Latina)*, volume 13, number 4, pp. 913–918.
- [37] Jyh-Cheng Jeng, (2015). A Model-Free Direct Synthesis Method for PI/PID Controller Design Based on Disturbance Rejection. *Chemometrics and Intelligent Laboratory Systems*, volume 14, pp. 14–29.
- [38] Qinghe Chu and Tuanjie Liu and Yalong Wang, (2013). Research on Excitation Controller Based on the Adaptive Fuzzy PID Technique. *Intelligent Human-Machine Systems and Cybernetics (IHMSC)*, 5th International Conference, volume 1, pp. 297–300.
- [39] Kar, Samarjit and Das, Sujit and Ghosh, Pijush Kanti, (2014). Applications of Neuro Fuzzy Systems: A Brief Review and Future Outline. *Applied Soft Computing*, volume 15. Elsevier, pp. 243–259.
- [40] Moura, J. P. and Rego, P. H. M. and Fonseca Neto, J. V. (2019). Online discrete-time LQR controller design with integral action for bulk Bucket Wheel Reclaimer operational processes via Action-Dependent Heuristic Dynamic Programming. *ISA Transactions*. Elsevier. ISSN = "0019-0578", doi = "https://doi.org/10.1016/j.isatra.2019.01.010".
- [41] Moura, José Pinheiro and da Fonseca Neto, João Viana, *Fuzzy Controller in the Cargo Control Wagons Dump. Evolving and Adaptive Intelligent Systems (EAIS)*. IEEE Conference on IEEE, (2016), pp. 10–16.
- [42] Mirzaee, Hossein and Naderi, B and Pasandideh, SHR., (2018). A Preemptive Fuzzy Goal Programming Model for Generalized Supplier Selection and Order Allocation With Incremental Discount Computers & Industrial Engineering. Elsevier.
- [43] Peter Van Overschee, Bart De Moor, (1996). *Subspace Identification for Linear Systems: Theory - Implementation - Applications*. Springer US.
- [44] Wibowo, Tri Chandra S and Saad, Nordin, (2010). MIMO Model of an Interacting Series Process for Robust MPC Via System Identification. *ISA Transactions*, volume 49, number , pp. 335–347.
- [45] José Pinheiro de Moura, João Viana da Fonseca Neto, Patrícia Helena Moraes Rêgo, (2019). Models for Optimal Online Tuning Based on Computational Intelligence of PID Controllers Applied to Operational Processes of Bulk BWR. *Journal of Control, Automation and Electrical Systems*, Springer.
- [46] Ham, Fredric M and Kostanic, Ivica, (2000). *Principles of Neurocomputing for Science and Engineering*. McGraw-Hill Higher Education.
- [47] Naik, Nitin and Diao, Ren and Shen, Qiang, (2018). Dynamic Fuzzy Rule Interpolation and its Application to Intrusion Detection. *IEEE Transactions on Fuzzy Systems*, volume 26, number 4, pp. 1878–1892.
- [48] Lei, Tao and Jia, Xiaohong and Zhang, Yanning and He, Lifeng and Meng, Hongying and Nandi, Asoke K., (2018). Significantly Fast and Robust Fuzzy C-means Clustering Algorithm Based on Morphological Reconstruction and Membership Filtering. *IEEE Transactions on Fuzzy Systems*, volume 26, number 5, pages 3027–3041.
- [49] Dettori, S and Iannino, V and Colla, V and Signorini, A., (2018). An Adaptive Fuzzy Logic-based Approach to PID Control of Steam Turbines in Solar Applications. *Journal Applied Energy*, volume 227, pages 655–664. Elsevier.
- [50] Zhao, Zhen-Yu and Tomizuka, Masayoshi and Sagara, Setsuo, (1992). A Fuzzy Tuner for Fuzzy Logic Controllers. *IEEE American Control Conference*, pp. 2268–2272.
- [51] Katayama, Ryu and Kajitani, Yuji and Kuwata, Kaihei and Nishida, Yukiteru, (1993). *Developing Tools and Methods for Applications Incorporating Neuro, Fuzzy and Chaos Technology*. Computers & Industrial Engineering, volume 24, number 4. Elsevier, pp. 579–592.
- [52] Deng, Yue and Ren, Zhiqian and Kong, Youyong and Bao, Feng and Dai, Qionghai, (2017). A Hierarchical Fused Fuzzy Deep Neural Network for Data Classification. *IEEE Transactions on Fuzzy Systems*, volume 25, number 4, pp. 1006–1012.
- [53] Tao, Yong and Zheng, Jiaqi and Lin, Yuanchang and Wang, Tianmiao and Xiong, Hegen and He, Guotian and Xu, Dong, (2015). Fuzzy PID Control Method of Deburring Industrial Robots. *IOS Press Journal of Intelligent & Fuzzy Systems*, volume 29, number 6, pp. 2447–2455.




José Pinheiro He is professor of Physics at the State University of Maranhão - UEMA, high school Chemistry teacher from the State Secretary of Maranhão - SEDUC and he is master engineer at Vale Company SA. He holds a technical course in mechanics at the Federal Technical School of Piauí - IFPI, degree in Industrial Chemistry at Federal University of Maranhão - UFMA, full degree in Sciences - Chemistry at the State University of Maranhão - UEMA, Master's degree in Electrical Engineering in the Automation and Control UFMA and PhD in Electrical Engineering in the Automation and Control UFMA. Researcher, working mainly on following topics: artificial intelligence, expert systems, fuzzy logic, neural networks, adaptive control, optimal control, PID controllers, adaptive dynamic programming.



João Viana He is associate Professor at the Federal University of Maranhão. He holds a degree in Electrical Engineering from the Federal University of Paraíba (1982), a Master's degree in Electrical Engineering from the Federal University of Paraíba (1986), and a PhD in Electrical Engineering from the State University of Campinas (2000). Currently, he develops research in Computational Intelligence focusing on the fusion of artificial neural network approaches, evolutionary computation

and fuzzy logic.



Patrícia Helena Patrícia Helena Moraes Rêgo received her B.Sc. degree in Mathematics and the M.S. and PhD degrees in Electrical Engineering from the Federal University of Maranhão, Maranhão-Brazil, in 1999, 2007 and 2014, respectively. She is a Lecturer with the Mathematics and Computing Department of the State University of Maranhão, Maranhão-Brazil. Currently, she takes part on the Electrical Engineering Post-Graduate Program of the Federal University of Maranhão and Post-Graduate Program in Computer Engineering and Systems of the State University of Maranhão, Maranhão-Brazil, where she develops research in the area of Industrial Automation and Control.