

Universidade Federal do Maranhão  
Centro de Ciências Exatas e Tecnológicas  
Programa de Pós-Graduação em Ciência da Computação

**ALEX NEWMAN VELOSO DOS SANTOS**

COEFICIENTES DE CORRELAÇÃO COMO MÉTRICA DE  
AVALIAÇÃO DAS ESTRATÉGIAS DE CONTROLE  
INTELIGENTE FEL E MNFEL

São Luís  
2018

**ALEX NEWMAN VELOSO DOS SANTOS**

COEFICIENTES DE CORRELAÇÃO COMO MÉTRICA DE  
AVALIAÇÃO DAS ESTRATÉGIAS DE CONTROLE  
INTELIGENTE FEL E MNFEL

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal do Maranhão, **como parte dos requisitos necessários** para obtenção do grau de Mestre em Ciência da Computação.

Orientador: Prof<sup>o</sup> Dr. Alexandre César Muniz de Oliveira

Coorientador: Prof<sup>o</sup> Dr. Paulo Rogério de Almeida Ribeiro

São Luís

2018

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

Santos, Alex Newman Veloso dos.

Coeficientes de correlação como métrica de avaliação das estratégias de Controle Inteligente FEL e MNFEL / Alex Newman Veloso dos Santos. - 2018.

98 f.

Coorientador(a): Paulo Rogério de Almeida Ribeiro.

Orientador(a): Alexandre César Muniz de Oliveira.

Dissertação (Mestrado) - Programa de Pós-graduação em Ciência da Computação/ccet, Universidade Federal do Maranhão, São Luís, 2018.

1. Coeficiente de Spearman. 2. Feedback-Error-Learning. 3. Multi-Network-Feedback-Error-Learning. I. Oliveira, Alexandre César Muniz de. II. Ribeiro, Paulo Rogério de Almeida. III. Título.

*Para Alc a Veloso, Lindanir Abreu e Laryssa Costa,  
com todo amor e respeito.*

# Agradecimentos

Agradeço imensamente, infinitamente, às minhas mães Alcéa Veloso e Lindanir Abreu, por tudo que fazem por mim durante estes quase 25 anos. Também ao meu pai, Lourenço Santos, pela graça da vida e pelo exemplo. Me considero muito abençoado por ter vocês na minha vida, me apoiando e guiando em todas as decisões que tive que tomar. Amo vocês.

Agradeço à todos os professores os quais tive a oportunidade de aprender e me desenvolver. Em especial aos meus orientadores Prof. Dr. Paulo Rogério e Prof. Dr. Alexandre César. O modelo de profissional que vocês são é o mesmo que quero seguir na minha vida. Sou muito grato.

Agradeço aos meus familiares, em especial às minhas tias Fátima e Maria Veloso. *Família a gente não escolhe*, mas até nisso eu dei sorte.

Agradeço a todos os meus amigos, sejam do LACMOR, da UFMA, das empresas onde trabalhei, da minha cidade Bacabal ou da vida. Sintam-se todos abraçados. Nomeadamente aos amigos Juliano, Dayson, Lázaro e Eduardo que desde o começo do curso me suportam. Ao mestre Thiago que vai pro sul pra virar doutor. Ao mestre, guerreiro e justo, Daniel que neste momento está se recuperando de um acidente e que em breve estará de volta às pesquisas. Aos meus amigos de Bacabal, Glauber, André, Lindemberg, Alisson, Cássio e Antonio Carlos, gente que eu conheço desde que eu nasci. Aos companheiros de LACMOR e da UFMA, Matheus, Ramon, Gilvan, Moisés, Chrystian, André, Luann, Ítalo, Gleidson, Antonio, Rodrigo e o quase doutor Marcelo. Ao Caio, Paulo e Andreia do Módulo Estatística do Grupo Mateus.

Agradecimento especial para a minha amiga, namorada, companheira e mestrandia Laryssa Costa. Só você sabe o quanto eu aprendo com você todos os dias. A vida é muito mais fácil, feliz e colorida ao seu lado. Te amo.

Agradeço à UFMA e à CAPES, bem como aos seus colaboradores. A estrutura, os incentivos e as condições que tive para desenvolver este trabalho foram de vital importância para o sucesso da pesquisa.

*“If you removed all the arteries, veins,  
and capillaries from a person’s body,  
and tied them end-to-end . . .  
the person will die”  
(Neil deGrasse Tyson)*

# Resumo

Sistemas de controle têm sido largamente utilizados nas mais diversas áreas: plantas industriais, robótica, medicina etc. Assim sendo, novas técnicas são frequentemente sugeridas para melhorar esses sistemas. *Feedback-Error-Learning* (FEL) é uma estratégia de controle inteligente que emprega uma rede neural ao lado de um controle convencional, por exemplo um Proporcional-Integral-Derivativo (PID) que é um dos mais usados na indústria. Um melhor controle é obtido com FEL a partir da aquisição do modelo inverso ou da compensação pela não-linearidade. Adicionalmente, tem-se a estratégia *Multi-Network-Feedback-Error-Learning* (MNFEL), que é baseada na FEL e utiliza múltiplas redes neurais, que pode melhorar mais o controle. Os trabalhos que utilizam FEL e MNFEL presumem que a adição das redes neurais irá melhorar o controle, no entanto, não existem muitos trabalhos que contabilizem o grau de contribuição da rede no sistema de controle. Uma pesquisa anterior propôs uma métrica baseada no Coeficiente de Correlação de Pearson (CP). Entretanto, essa métrica assume algumas condições de funcionamento que podem não ser garantidas nos sistemas de controle. Este trabalho visa propor duas abordagens baseadas no Coeficiente de Spearman (CS) e CP. A metodologia de avaliação é dividida em duas fases. A primeira fase determina o comportamento esperado do CS a partir da análise da correlação inicial entre o erro quadrático da planta e o controlador convencional, sendo essa antes do uso das estratégias FEL e MNFEL. A segunda fase avalia o comportamento do coeficiente durante o treinamento das redes. Duas plantas industriais foram utilizadas neste trabalho: Forno de Pelotização e Serpentina de Refrigeração. Os resultados mostraram que: i) a abordagem do trabalho anterior, isto é usando o CP, pode induzir a conclusões precipitadas sobre o sistema em análise; ii) a abordagem proposta, usando CS, demonstrou – em ambas as plantas – o grau de contribuição das rede durante a melhoria do sistema de controle; iii) o CS – durante o treinamento das redes neurais – pode antecipar que o uso dessas redes não irá melhorar substancialmente o controle do sistema. Assim sendo, constata-se que a métrica proposta é capaz de avaliar a contribuição das redes neurais para melhoria do controle, assim como indica que essas redes podem não contribuir no sistema de controle.

**Palavras-chaves:** Métricas de Controle Inteligente. Coeficiente de Spearman. *Feedback-Error-Learning*. *Multi-Network-Feedback-Error-Learning*.

# Abstract

Control systems have been largely used in many fields such as industrial plants, robotics, medicine and so on. Therefore, new techniques are frequently proposed to enhance these systems. Feedback-Error-Learning (FEL) is an intelligent control strategy which applies a neural network alongside a conventional controller, as an example the Proportional-Integral-Derivative (PID) that is the most used on the industry. The enhanced control is achieved in FEL by the acquisition of the inverse model or the non-linearity compensation. Moreover, Multi-Network-Feedback-Error-Learning (MNFEL), which is based on FEL, uses multiple neural networks that can lead to a better control. FEL and MNFEL works assume that enhanced controls are achieved by adding neural networks, however, there are few works account for the network's degree of contribution to the control system. A previous research proposed a metric based on Pearson product-moment correlation coefficient (PC). However, this metric assumes working conditions that may not be met in control systems. This work aims to propose two approaches based on Spearman Coefficient (SC) and PC. The evaluation methodology is comprised of two phases. The first phase, placed before the intelligent control strategy insertion, determines the expected SC behavior based on the initial analysis of the correlation between the squared error and the conventional controller. The second phase evaluates the coefficient behavior during the neural network training. Two industrial plants were used in this work: Burner group of a Pelletizing plant and Cooling Coil plant. The results shown: i) the previous work approach using PC may lead to precipitated conclusions about the system in analysis; ii) the proposed approach using SC demonstrated – in both plants – the neural networks' degree of contribution while enhancing the control; iii) the SC – during the networks' training – can preview that those networks will or not significantly enhance the control, i.e. indicating that those networks may not contribute in the control system. Thus, the proposed approach, which uses PC and SC, may calculate the contribution of the neural networks during the improvement of the control system with FEL and MNFEL.

**Keywords:** Intelligent Control Metrics. Spearman Correlation Coefficient. Feedback-Error-Learning. Multi-Network-Feedback-Error-Learning.



# Lista de ilustrações

|   |    |
|---|----|
| Figura 1 – Esquema de um controle à malha fechada . . . . .   | 23 |
| Figura 2 – Exemplo de resposta de um controlador de malha fechada com métricas  | 25 |
| Figura 3 – Esquema de controlador PID . . . . .   | 26 |
| Figura 4 – Comparativo entre as saídas de um controlador P e PI . . . . .   | 27 |
| Figura 5 – Exemplo de neurônio artificial. As entradas $x_i$ são ponderadas através dos pesos sinápticos $\omega_i$ e posteriormente agregadas no módulo de soma. O resultado, chamado de entrada líquida, é passado pela a função de ativação e dado como <i>output</i> do neurônio. . . . .                                       | 31 |
| Figura 6 – Exemplo estrutural de uma MLP <i>feedforward</i> de três camadas, sendo três neurônios na camada de entrada (marcados com I); quatro na camada escondida (H) e um único neurônio na camada de saída (O). . . . .   | 31 |
| Figura 7 – Esquema básico FEL. Note que o sinal de erro utilizado pela RNA é a saída do CV $u_{cfc}$ . O sinal enviado à planta é a soma das saídas da rede e do CV. $u = u_n + u_{cfc}$ . . . . .  | 34 |
| Figura 8 – Estrutura FEL modificada com <i>tapped delay line</i> e atraso de referência em $M$ períodos para o CV. . . . .  | 34 |
| Figura 9 – Estratégia MNFEL em treinamento. Note que não há elemento realizando a coordenação das múltiplas redes. Tal efeito só pôde ser alcançado devido à política de treinamento adotada na MNFEL – que congela o treinamento da rede anterior antes de acrescentar uma nova – e à maneira que as redes são integradas. . . . . | 36 |
| Figura 10 – Coeficiente de Pearson calculado para diferentes padrões de dados. . . . .  | 39 |
| Figura 11 – Coeficiente de Spearman calculado para diferentes padrões de dados em comparação com o coeficiente de Pearson. . . . .  | 40 |
| Figura 12 – Exemplo de referência do tipo degrau . . . . .  | 44 |
| Figura 13 – Fluxograma das etapas necessárias à avaliação. . . . .  | 47 |
| Figura 14 – Generalização da MLP utilizada para aquisição do modelo da planta da pelotização. . . . .   | 49 |
| Figura 15 – Diagrama de blocos de um modelo de Hammerstein. . . . .   | 50 |
| Figura 16 – Gráfico contendo os dados do erro e da ação de controle PID na planta de pelotização. . . . .   | 52 |
| Figura 17 – Histograma dos dados do erro e da ação de controle PID na planta de pelotização. . . . .  | 52 |

|   |    |
|---|----|
| Figura 18 – Comparação entre a relação do erro da planta e da ação de controle do PID com e sem a remoção das observações anteriores ao degrau do <i>setpoint</i> , nos gráficos 1) e 2), respectivamente. Os dados destacados por A) são correspondentes às observações no período anterior ao degrau. . . . . | 53 |
| Figura 19 – Comparação entre as ações de controle e o erro antes e depois do treinamento das redes na estratégia MNFEL. . . . .   | 54 |
| Figura 20 – Detalhes entre o erro da planta e a ação de controle do controlador convencional. . . . .   | 55 |
| Figura 21 – Detalhes entre a relação do erro da planta e a ação de controle do controlador convencional. O gráfico da direita traz a ampliação dos dados destacados por A) no gráfico da esquerda. . . . .  | 56 |
| Figura 22 – Relação inicial do erro e ação de controle do PID na planta da pelotização.   | 57 |
| Figura 23 – Controle FEL DESVPAD na planta da Pelotização utilizando diferentes RNAs. . . . .   | 59 |
| Figura 24 – Sinais de controle FEL DESVPAD na planta de Pelotização. $u_{cfc}$ é a ação de controle do PID, $u_n$ a ação de controle da rede neural e $u$ o combinado das ações. . . . .  | 59 |
| Figura 25 – Evolução dos coeficientes de correlação de Pearson e Spearman ao longo do treinamento da estratégia FEL DESVPAD na planta Pelotização. . . . .  | 60 |
| Figura 26 – Controle MNFEL DESVPAD na planta da Pelotização utilizando diferentes configurações. . . . .  | 62 |
| Figura 27 – Sinais de controle MNFEL DESVPAD na planta de Pelotização. $u_{cfc}$ é a ação de controle do PID, $u_n$ a ação de controle das redes neurais e $u$ o combinado das ações. . . . .   | 63 |
| Figura 28 – Evolução dos coeficientes de correlação de Pearson e Spearman ao longo do treinamento da estratégia MNFEL DESVPAD na planta Pelotização.  | 64 |
| Figura 29 – Controle FEL na planta Pelotização utilizando critério de parada pelo erro quadrático médio. . . . .  | 65 |
| Figura 30 – Sinais de controle FEL EQM na planta de Pelotização. $u_{cfc}$ é a ação de controle do PID, $u_n$ a ação de controle da rede neural e $u$ o combinado das ações. . . . .  | 66 |
| Figura 31 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia FEL EQM na planta Pelotização. . . . .  | 67 |
| Figura 32 – Controle MNFEL na planta Pelotização utilizando critério de parada pelo erro quadrático médio. . . . .  | 68 |
| Figura 33 – Sinais de controle MNFEL EQM na planta de Pelotização. $u_{cfc}$ é a ação de controle do PID, $u_n$ a ação de controle das redes neurais e $u$ o combinado das ações. . . . .   | 69 |

|  |    |
|--|----|
| Figura 34 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia MNFEL EQM na planta Pelotização. . . . .   | 70 |
| Figura 35 – Dispersão dos EQMs finais pelos coeficientes de correlação finais para os experimentos FEL na planta Forno de Pelotização. . . . .   | 71 |
| Figura 36 – Dispersão dos EQMs finais pelos coeficientes de correlação finais para os experimentos MNFEL na planta Forno de Pelotização. . . . .   | 72 |
| Figura 37 – Relação inicial do erro e ação de controle do PID na planta da Serpentina de Refrigeração. . . . .   | 73 |
| Figura 38 – Controle FEL na planta da Serpentina de Refrigeração utilizando critério de parada pelo desvio padrão do erro. . . . .   | 75 |
| Figura 39 – Sinais de controle FEL DESVPAD na planta da Serpentina de Refrigeração. $u_{cfc}$ é a ação de controle do PID, $u_n$ a ação de controle da rede neural e $u$ o combinado das ações. . . . .      | 75 |
| Figura 40 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia FEL DESVPAD na planta <i>Cooling Coil</i> . . . . .  | 76 |
| Figura 41 – Controle MNFEL na planta da Serpentina de Refrigeração utilizando critério de inserção e parada pelo desvio padrão do erro. . . . .  | 78 |
| Figura 42 – Sinais de controle MNFEL DESVPAD na planta da Serpentina de Refrigeração. $u_{cfc}$ é a ação de controle do PID, $u_n$ a ação de controle das redes neurais e $u$ o combinado das ações. . . . . | 79 |
| Figura 43 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia MNFEL DESVPAD na planta <i>Cooling Coil</i> . . . . .  | 80 |
| Figura 44 – Controle FEL na planta da Serpentina de Refrigeração utilizando critério de parada pelo erro quadrático médio. . . . .   | 82 |
| Figura 45 – Sinais de controle FEL EQM na planta da Serpentina de Refrigeração. $u_{cfc}$ é a ação de controle do PID, $u_n$ a ação de controle da rede neural e $u$ o combinado das ações. . . . .          | 82 |
| Figura 46 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia FEL EQM na planta <i>Cooling Coil</i> . . . . .  | 83 |
| Figura 47 – Controle MNFEL na planta da Serpentina de Refrigeração utilizando critério de parada pelo erro quadrático médio. . . . .   | 85 |
| Figura 48 – Sinais de controle MNFEL EQM na planta da Serpentina de Refrigeração. $u_{cfc}$ é a ação de controle do PID, $u_n$ a ação de controle das redes neurais e $u$ o combinado das ações. . . . .     | 85 |
| Figura 49 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia MNFEL EQM na planta <i>Cooling Coil</i> . . . . .  | 86 |
| Figura 50 – Dispersão dos EQMs finais pelos coeficientes de Spearman finais para os experimentos FEL na planta <i>Cooling Coil</i> . . . . .   | 88 |

|  |    |
|--|----|
| Figura 51 – Dispersão dos EQMs finais pelos coeficientes de Spearman finais para os experimentos MNFEL na planta <i>Cooling Coil</i> . . . . . | 89 |
|--|----|

# Lista de tabelas

|           |   |    |
|-----------|---|----|
| Tabela 1  | – Métricas clássicas de controle a partir do controle convencional com PID na planta do Forno de Pelotização. . . . .   | 58 |
| Tabela 2  | – Detalhes das redes neurais utilizadas nos experimentos da planta Pelotização. Cada RNA tem números de neurônios na camada de entrada ( $n_i$ ) e camada escondida ( $n_h$ ), além de coeficientes de aprendizado entre as camadas de entrada e escondida ( $\mu_{ih}$ ) e entre as camadas escondida e de saída ( $\mu_{ho}$ ). . . . . | 58 |
| Tabela 3  | – Dados de métricas de controle para os experimentos FEL DESVPAD na planta da Pelotização. . . . .  | 60 |
| Tabela 4  | – Dados sumarizados das observações do coeficiente de Spearman no controle FEL DESVPAD do Forno de Pelotização. . . . .   | 61 |
| Tabela 5  | – Dados sumarizados das observações do coeficiente de Pearson no controle FEL DESVPAD do Forno de Pelotização. . . . .  | 61 |
| Tabela 6  | – Configurações MNFEL utilizadas no experimento da Pelotização. . . . .   | 62 |
| Tabela 7  | – Dados de métricas de controle para os experimentos MNFEL DESVPAD na planta da Pelotização. . . . .  | 63 |
| Tabela 8  | – Dados sumarizados das observações do coeficiente de Spearman no controle MNFEL DESVPAD do Forno de Pelotização. . . . .   | 64 |
| Tabela 9  | – Dados sumarizados das observações do coeficiente de Pearson no controle MNFEL DESVPAD do Forno de Pelotização. . . . .  | 65 |
| Tabela 10 | – Dados de métricas de controle para os experimentos FEL EQM na planta da Pelotização. . . . .  | 66 |
| Tabela 11 | – Dados sumarizados das observações do coeficiente de Spearman no controle FEL EQM do Forno de Pelotização. . . . .   | 67 |
| Tabela 12 | – Dados sumarizados das observações do coeficiente de Pearson no controle FEL EQM do Forno de Pelotização. . . . .  | 68 |
| Tabela 13 | – Dados de métricas de controle para os experimentos MNFEL EQM com critério de parada pelo erro quadrático médio na planta da Pelotização. . . . .  | 69 |
| Tabela 14 | – Dados sumarizados das observações do coeficiente de Spearman no controle MNFEL EQM do Forno de Pelotização. . . . .   | 70 |
| Tabela 15 | – Dados sumarizados das observações do coeficiente de Pearson no controle MNFEL EQM do Forno de Pelotização. . . . .  | 71 |
| Tabela 16 | – Métricas clássicas de controle a partir do controle convencional com PID na planta da Serpentina de Refrigeração. . . . .   | 74 |

|  |    |
|--|----|
| Tabela 17 – Detalhes das redes utilizadas nos experimentos da planta <i>Cooling Coil</i> . Cada RNA tem números de neurônios na camada de entrada ( $n_i$ ) e camada escondida ( $n_h$ ), além de coeficientes de aprendizado entre as camadas de entrada e escondida ( $\mu_{ih}$ ) e entre as camadas escondida e de saída ( $\mu_{ho}$ ). . . . . | 74 |
| Tabela 18 – Dados de métricas de controle para os experimentos FEL com critério de parada pelo desvio padrão do erro na planta da Serpentina de Refrigeração.  | 76 |
| Tabela 19 – Dados sumarizados das observações do coeficiente de Spearman no controle FEL DESVPAD da planta <i>Cooling Coil</i> . . . . .   | 77 |
| Tabela 20 – Dados sumarizados das observações do coeficiente de Pearson no controle FEL DESVPAD da planta <i>Cooling Coil</i> . . . . .  | 77 |
| Tabela 21 – Configurações MNFEL utilizadas no experimento da Serpentina de Refrigeração. . . . .   | 78 |
| Tabela 22 – Dados de métricas de controle para os experimentos MNFEL com critério de inserção e parada pelo desvio padrão do erro da planta <i>Cooling Coil</i> . . . . .  | 79 |
| Tabela 23 – Dados sumarizados das observações do coeficiente de Spearman no controle MNFEL DESVPAD da planta <i>Cooling Coil</i> . . . . .   | 80 |
| Tabela 24 – Dados sumarizados das observações do coeficiente de Pearson no controle MNFEL DESVPAD da planta <i>Cooling Coil</i> . . . . .  | 81 |
| Tabela 25 – Dados de métricas de controle para os experimentos FEL com critério de parada pelo erro quadrático médio na planta da Serpentina de Refrigeração. . . . .  | 83 |
| Tabela 26 – Dados sumarizados das observações do coeficiente de Spearman no controle FEL EQM da planta <i>Cooling Coil</i> . . . . .   | 84 |
| Tabela 27 – Dados sumarizados das observações do coeficiente de Pearson no controle FEL EQM da planta <i>Cooling Coil</i> . . . . .  | 84 |
| Tabela 28 – Dados de métricas de controle para os experimentos MNFEL com critério de parada pelo erro quadrático médio na planta da Serpentina de Refrigeração. . . . .  | 86 |
| Tabela 29 – Dados sumarizados das observações do coeficiente de Spearman no controle MNFEL EQM na planta <i>Cooling Coil</i> . . . . .   | 87 |
| Tabela 30 – Dados sumarizados das observações do coeficiente de Pearson no controle MNFEL EQM na planta Serpentina de Refrigeração. . . . .  | 88 |



# Sumário

|            |  |           |
|------------|--|-----------|
| <b>1</b>   | <b>INTRODUÇÃO</b>  | <b>17</b> |
| <b>1.1</b> | <b>Trabalhos relacionados</b>  | <b>19</b> |
| <b>1.2</b> | <b>Objetivos</b>   | <b>20</b> |
| <b>1.3</b> | <b>Contribuições</b>   | <b>20</b> |
| <b>1.4</b> | <b>Organização do trabalho</b>   | <b>21</b> |
| <b>2</b>   | <b>TEORIA DE CONTROLE</b>  | <b>22</b> |
| <b>2.1</b> | <b>Principais conceitos</b>  | <b>22</b> |
| <b>2.2</b> | <b>Sistemas de controle</b>  | <b>23</b> |
| 2.2.1      | Controle a malha fechada   | 23        |
| 2.2.2      | Controle a malha aberta  | 24        |
| <b>2.3</b> | <b>Medidas de Desempenho</b>   | <b>24</b> |
| <b>2.4</b> | <b>Controlador PID</b>   | <b>25</b> |
| 2.4.1      | Ação Proporcional  | 26        |
| 2.4.2      | Ação Integral  | 26        |
| 2.4.3      | Ação Derivativa  | 27        |
| <b>2.5</b> | <b>Modelagem de Sistemas</b>   | <b>28</b> |
| <b>3</b>   | <b>CONTROLE INTELIGENTE COM REDES NEURAIS</b>                              | <b>30</b> |
| <b>3.1</b> | <b>Noções Básicas</b>  | <b>30</b> |
| <b>3.2</b> | <b>Redes Neurais e Controle</b>  | <b>32</b> |
| 3.2.1      | <i>Feedback-Error-Learning</i>   | 33        |
| 3.2.2      | <i>Multi-Network-Feedback-Error-Learning</i>                               | 34        |
| 3.2.2.1    | Critério de parada e inserção das redes pelo desvio padrão do erro         | 36        |
| 3.2.2.2    | Critério de parada e inserção das redes pelo erro quadrático médio         | 37        |
| 3.2.3      | Avaliação do desempenho das redes no controle                              | 37        |
| 3.2.3.1    | Coeficiente de Correlação de Pearson                                       | 38        |
| 3.2.3.2    | Coeficiente de Correlação de Postos de Spearman                            | 38        |
| 3.2.3.3    | Método de avaliação através do Coeficiente de Pearson                      | 40        |
| <b>4</b>   | <b>MÉTRICAS DE AVALIAÇÃO DE DESEMPENHO PARA AS ESTRATÉGIAS FEL E MNFEL</b> | <b>42</b> |
| <b>4.1</b> | <b>Métricas de Avaliação</b>   | <b>42</b> |
| 4.1.1      | Avaliação utilizando o coeficiente de Spearman                             | 44        |
| 4.1.2      | Avaliação utilizando os coeficientes de Spearman e de Pearson              | 46        |
| 4.1.3      | Metodologia de avaliação proposta  | 46        |



|            |  |           |
|------------|--|-----------|
| <b>5</b>   | <b>RESULTADOS E DISCUSSÃO</b>                                      | <b>48</b> |
| <b>5.1</b> | <b>Ambiente de Simulação</b>                                       | <b>48</b> |
| 5.1.1      | Planta do Forno de Pelotização                                     | 49        |
| 5.1.2      | Planta da Serpentina de Refrigeração                               | 50        |
| <b>5.2</b> | <b>Avaliação utilizando Coeficiente de Pearson</b>                 | <b>51</b> |
| <b>5.3</b> | <b>Experimentos Forno de Pelotização</b>                           | <b>56</b> |
| 5.3.1      | Identificação inicial da relação                                   | 57        |
| 5.3.2      | Avaliação do treinamento   | 58        |
| 5.3.2.1    | FEL com critério de parada pelo desvio padrão do erro              | 59        |
| 5.3.2.2    | MNFEL com critério de inserção e parada pelo desvio padrão do erro | 62        |
| 5.3.2.3    | FEL com critério de parada pelo erro quadrático médio              | 65        |
| 5.3.2.4    | MNFEL com critério de inserção e parada pelo erro quadrático médio | 68        |
| 5.3.2.5    | Relação entre EQM e coeficientes de correlação da generalização    | 71        |
| <b>5.4</b> | <b>Experimentos <i>Cooling Coil</i></b>                            | <b>72</b> |
| 5.4.1      | Identificação inicial da relação                                   | 73        |
| 5.4.2      | Avaliação do treinamento   | 74        |
| 5.4.2.1    | FEL com critério de parada pelo desvio padrão do erro              | 74        |
| 5.4.2.2    | MNFEL com critério de inserção e parada pelo desvio padrão do erro | 78        |
| 5.4.2.3    | FEL com critério de parada pelo erro quadrático médio              | 81        |
| 5.4.2.4    | MNFEL com critério de inserção e parada pelo erro quadrático médio | 85        |
| 5.4.2.5    | Relação entre EQM e coeficientes de correlação da generalização    | 88        |
| <b>6</b>   | <b>CONCLUSÃO</b>   | <b>90</b> |
|            | <b>REFERÊNCIAS</b>   | <b>92</b> |

# 1 Introdução

A constante evolução tecnológica tem reflexos benéficos observados em toda a sociedade. O fácil acesso, aliado ao rápido avanço da tecnologia permite que os consumidores anseiem por produtos de maior qualidade em mercados onde o número de opções é cada vez maior. A indústria, por sua vez, para não perder espaço e se manter competitiva, adota processos e sistemas mais complexos e mais precisos.

Visando o controle destes sistemas complexos de alta precisão, a indústria enfrenta dificuldades, que vão desde as técnicas – a dificuldade de projetar um sistema de controle para plantas cujo modelo nominal fornece apenas uma descrição matemática aproximada dos fenômenos que a representam – até mesmo as operacionais, como por exemplo lidar com paradas programadas para troca de componentes. A junção de controladores industriais e técnicas avançadas de representação de conhecimento é um tópico importante na mitigação destas dificuldades, que vem sendo abordado em pesquisas (VYATKIN, 2013).

Impulsionados pelos avanços, na tentativa de atender às novas exigências, à Teoria de Controle uniram-se fundamentos e técnicas de Inteligência Artificial culminando na área de Controle Inteligente. Esta área da Teoria do Controle envolve, dentre outras técnicas, a utilização de sistemas de controle com lógica *fuzzy* (VANSOVITS et al., 2016), algoritmos genéticos (CHIANG, 2010) e redes neurais artificiais (HAMID; JAMIL; BUTT, 2016).

Notavelmente, redes neurais e sistemas de controle convencionais foram combinados em controladores inteligentes aplicados à plantas industriais (SHARMA; KUMAR; RANA, 2017). Uma importante estratégia de controle que envolve estes dois componentes, chamada de *Feedback-Error-Learning* (FEL) (GOMI; KAWATO, 1990; MIYAMOTO et al., 1988), destaca-se pela aplicação de uma rede neural trabalhando ao lado de um controlador convencional (CV), como por exemplo o Proporcional-Integral-Derivativo (PID), onde a rede fornece ajustes à ação de controle do CV, compensando pelas incertezas do controle. O maior atrativo deste método, para a indústria, é a possibilidade de realizar a migração do CV para controle FEL sem que haja parada no processo.

Desde a sua concepção, a estratégia de controle FEL atraiu bastante atenção dos pesquisadores, desenvolvendo-se a literatura com estudos sobre a técnica (NAKANISHI; SCHAAL, 2004; MIYAMURA; KIMURA, 2002), aplicações (TAKAHASHI et al., 2017; RIBEIRO et al., 2009; RODOR et al., 2017) e variações (TAN, 1997; ALMEIDA NETO, 2003). Das variações FEL, destaca-se a estratégia *Multi-Network-Feedback-Error-Learning* (MNFEL) (ALMEIDA NETO, 2003), que aplica várias redes neurais de aprendizado acumulativo acopladas ao controlador convencional.

A estratégia MNFEL é utilizada por facilitar a fuga do mínimo local, dado que

novas redes são inseridas ao processo quando a rede anterior não é mais capaz de fornecer melhoria ao controle. Uma rede treina por vez e as saídas são acumuladas ao final. Desta forma, a estratégia MNFEL permite o aprendizado acumulativo e dispensa a presença de um coordenador (ALMEIDA NETO, 2003). Pesquisadores aplicaram esta técnica com sucesso em plantas industriais (ALMEIDA NETO; GOES; NASCIMENTO, 2010; RIBEIRO; ALMEIDA NETO; OLIVEIRA, 2010), obtendo resultados satisfatórios.

No controle FEL ou MNFEL as redes podem ter diferentes funções, de acordo com a sua configuração de dados de entrada. Pode-se ter, portanto, uma rede que age como reguladora de não-linearidade (NRL, do inglês *Nonlinear Regulator Learning*) ou como aproximadora do modelo inverso da planta (IDML, de *Inverse Dynamics Model Learning*) (GOMI; KAWATO, 1990). Neste trabalho aplica-se a configuração NRL devido a utilização desta configuração em trabalhos similares (RIBEIRO, 2009; RIBEIRO et al., 2009; RIBEIRO; ALMEIDA NETO; OLIVEIRA, 2010).

Todavia, independente da configuração utilizada, as redes produzem saídas, ou *outputs*, que, somados ao controlador convencional, modificam a planta e conseqüentemente o erro entre a referência e a saída da planta. Deste modo, ao utilizar-se de métricas clássicas da teoria de controle, o pesquisador não pode afirmar se as redes da estratégia estão desempenhando a função à qual foram destinadas. Neste contexto, o projetista tem apenas a informação da qualidade do controle e a sua própria intuição para basear seus experimentos e auxiliar na tomada de decisão.

De fato, a definição de métricas específicas para a avaliação de sistemas inteligentes, onde inclui-se os sistemas de controle inteligente, é um problema em aberto que tem inúmeras repercussões na aplicação e estudo destes sistemas (EVANS; MESSINA, 2001). Existe dificuldade na definição destas métricas dado o nível de abstração do problema a ser tratado e a grande variedade de técnicas de inteligência artificial, cada uma com suas particularidades.

Trabalhos prévios propuseram métricas para avaliar o desempenho das redes nas estratégias FEL e MNFEL. Em (RIBEIRO, 2009) propôs-se um método que utiliza o coeficiente de Pearson entre o erro da planta e as ações do controlador convencional. Por este método, a avaliação deve ser feita a cada sessão de treinamento e espera-se um crescimento na correlação em relação à sessão anterior. A lógica por trás deste efeito estaria na diminuição da participação do CV no controle ao mesmo passo que a planta seria operada em menor faixa de erro. Entretanto, devido a utilização do coeficiente de Pearson, presume-se algumas condições que não podem ser garantidas em sistemas não-lineares.

Este trabalho propõe métricas de avaliação do desempenho das funções das redes neurais nas estratégias FEL e MNFEL, baseadas nos coeficientes de correlação de Pearson e Spearman. A motivação para a utilização dos coeficientes é que, a partir de ambos, é possível conhecer a relação entre o erro da planta e as ações do controlador

convencional, inferindo-se, portanto, se as redes estão executando a sua função de acordo com a configuração utilizada. O método proposto é dividido em duas etapas: a) anteriormente à aplicação do controle inteligente, na qual busca-se conhecer as relações da planta e controlador antes de qualquer treinamento; b) durante a fase de treinamento, visando a avaliação em tempo real do comportamento dinâmico, imposto pelas redes neurais, da relação entre planta e CV.

## 1.1 Trabalhos relacionados

A definição de métricas específicas para os sistemas dotados de inteligência é um importante passo para o avanço dos sistemas inteligentes (EVANS; MESSINA, 2001). Alguns trabalhos dedicaram-se a, senão propôr métricas, definir processos para a escolha destas.

Em (DONMEZ; PINA; CUMMINGS, 2009), os autores identificaram uma lista de critérios de avaliação de métricas que ajudam a determinar a qualidade de métricas específicas para aplicações de *Human-Automation*. Aplicações deste tipo envolvem controles inteligentes que atuam de forma autônoma entretanto com supervisão de um humano. O trabalho lista aplicações de exemplo, como robôs para cirurgias, pesquisas geológicas, drones de reconhecimento e veículos autônomos.

Os critérios listados (DONMEZ; PINA; CUMMINGS, 2009), como *restrições experimentais, validade do construto, eficiência estatística*, entre outros, são lógicos para a seleção de métricas e podem, inclusive, serem levados em consideração durante a proposição de novas métricas.

Outro trabalho abordou a definição de métricas para sistemas inteligentes inspiradas na Teoria da Comunicação (HAFEZ, 2012). O autor pauta o seu trabalho na concepção de que a efetividade dos sistemas inteligentes está diretamente relacionada com a capacidade de interação de seus componentes. Estes componentes, e as técnicas aplicadas em sistemas inteligentes, podem variar em suas naturezas e funcionamento, requerendo diferentes métricas específicas. O autor argumenta, no entanto, que é possível medir a performance de um sistema a partir da interação de seus componentes, utilizando conceitos da Teoria da Comunicação.

As conclusões apresentadas por Hafez (HAFEZ, 2012) são teóricas, embasadas na supracitada teoria, dando margem para debate. Todavia, não é claro o modo como a métrica deve ser utilizada, ou se todos os sinais de comunicação devem ser levados em consideração. Em um sistema de controle inteligente, por exemplo, há constante comunicação entre os componentes da malha de controle, de modo que será difícil apontar a efetividade do controlador inteligente apenas analisando-se a interação dos componentes.

Especificamente no campo dos sistemas de controle inteligente FEL e MNFEL, um trabalho (RIBEIRO, 2009) apresentou uma métrica, baseada no Coeficiente de Correlação de Pearson, capaz de apontar a contribuição das redes neurais ao processo. O coeficiente de correlação é calculado entre os dados de erro da planta e ação do controlador convencional. Por utilizar um método de cálculo de correlação linear, a métrica pode não ser capaz de representar a relação de inúmeros sistemas de controle, comprometendo a sua efetividade.

## 1.2 Objetivos

Este trabalho tem por objetivo propor métricas de treinamento das redes neurais das estratégias de controle baseadas em *FEL* e *MNFEL*, que possibilitem mensurar a efetividade da participação das redes neurais no processo de controle, dada a configuração de parâmetros escolhida. Faz-se tal a partir do cálculo dos coeficientes de Pearson e Spearman a partir dos dados coletados durante o treinamento.

Uma vez que o método da proposta é definido, treinam-se as estratégias FEL e MNFEL com diferentes configurações e critérios de parada ou inserção, em duas plantas não-lineares distintas, de modo que se possa experimentar a métrica e observar se os efeitos esperados condizem com os resultados obtidos.

O sistema de controle, as plantas e o método de avaliação foram implementados em C++, utilizando-se a biblioteca de álgebra linear *Armadillo* (SANDERSON; CURTIN, 2016), tendo como maiores benefícios a velocidade, a facilidade de uso e o código aberto com licença permissiva para utilização em várias modalidades (comercial, educacional, etc.). A escolha da linguagem e da biblioteca foram motivadas pela necessidade de celeridade no processamento e facilidade de aplicação, tornando o processo, como um todo, atrativo para a indústria.

## 1.3 Contribuições

As contribuições deste trabalho são:

- Expandir a literatura atual no tema avaliação da participação de redes neurais no processo de controle inteligente;
- Propor métricas de avaliação utilizando-se os coeficientes de correlação de Pearson e Spearman, considerando pontos importantes ainda não cobertos pelo método primeiro.

## 1.4 Organização do trabalho

Este trabalho é composto por seis capítulos, sendo este destinado a uma introdução da proposta e dos assuntos pertinentes à esta, bem como a motivação e os objetivos do trabalho.

No Capítulo 2, abordam-se conceitos fundamentais da Teoria de Controle necessários à compreensão do tema dissertado. Apresentam-se conceitos relativos ao controle convencional, utilizados durante os experimentos, bem como a contextualização do controlador convencional PID, bastante utilizado na indústria e aplicado nos experimentos deste trabalho.

No Capítulo 3, os sistemas de controle inteligente, com enfoque naqueles que utilizam redes neurais artificiais – na figura das estratégias FEL e MNFEL –, são abordados. A teoria e motivação que dão suporte à utilização destas estratégias, bem como os benefícios, são explanados. Avanços recentes na estratégia MNFEL, como a inserção automática e o método de avaliação do treinamento pelo Coeficiente de Pearson (CP) também são brevemente abordados.

Faz-se, no Capítulo 4, a proposta de uma metodologia de avaliação dividida em etapas, sendo estas anterior e durante o treinamento das redes. Dois métodos de avaliação são propostos, o primeiro utilizando o Coeficiente de Spearman e o segundo utilizando o conjugado Coeficiente de Pearson-Coeficiente de Spearman.

O Capítulo 5 é destinado à exposição dos experimentos e seus resultados, acompanhados das devidas discussões. Para tal, apresentam-se os sistemas a controlar utilizados no trabalho e uma breve análise da métrica de avaliação utilizando CP. Conclui-se o presente trabalho no Capítulo 6, no qual destacam-se os principais resultados e as expectativas de trabalhos futuros.

## 2 Teoria de Controle

A Teoria de Controle define conceitos e formulações matemáticas presentes desde o projeto até a análise dos controladores e dos sistemas controlados. Neste capítulo, monta-se um breve referencial teórico sobre a Teoria de Controle, desde a clássica até o método de espaço de estados, a fim de familiarizar e contextualizar o leitor com assunto dissertado. Os principais conceitos são descritos em detalhes na literatura (OGATA, 2011).

### 2.1 Principais conceitos

As variáveis controlada e manipulada são grandezas anteriores ao próprio sistema de controle e demonstram, em sua definição, o propósito deste. A variável controlada é medida e regida de acordo com as ações do sistema controlador. Tais ações são aplicadas à variável manipulada, alterando o seu próprio estado e conseqüentemente o valor da variável controlada (OGATA, 2011).

Naturalmente, quando na modelagem de um sistema de controle, observa-se uma relação, direta ou indireta, entre a variável de controle e manipulada. A exploração deste relacionamento, aliada à necessidade de reger a variável controlada, descreve o conceito de controle. Controle é, neste contexto, o ato de aplicar valores à variável manipulada a partir da leitura da variável controlada, aproximando o valor desta à referência (OGATA, 2011).

Define-se *setpoint*, ou referência, como o valor desejado para a variável controlada. Este pode ser estático ou dinâmico. No primeiro caso, é determinado previamente e não se altera durante o processo. Sendo dinâmico, o *setpoint* é atualizado a cada iteração.

Na área do controle, designa-se como planta o sistema a controlar: parte ou todo de um equipamento ou processo, que desempenha determinada operação (OGATA, 2011). É normalmente um sistema físico, ou um conjunto de objetos em funcionamento conjunto, como por exemplo um forno industrial, um sistema de direção de um robô ou a população de um algoritmo genético.

Define-se sistema como um conjunto de elementos distintos, com características e funções específicas, organizadas de forma natural ou por meios artificiais. O conceito de sistema não é aplicado somente a elementos físicos, mas também remete-se aos conjuntos de princípios, normas ou outros fenômenos abstratos, como por exemplo sistema econômico.

## 2.2 Sistemas de controle

De posse das definições apresentadas na Seção 2.1, pode-se designar um sistema de controle como sendo um ou mais elementos regendo uma planta. Embora possa parecer uma criação humana, os sistemas de controle fazem-se presentes em inúmeros ecossistemas. Um exemplo notável é a homeostase biológica, como a regulação térmica ou química dos seres humanos.

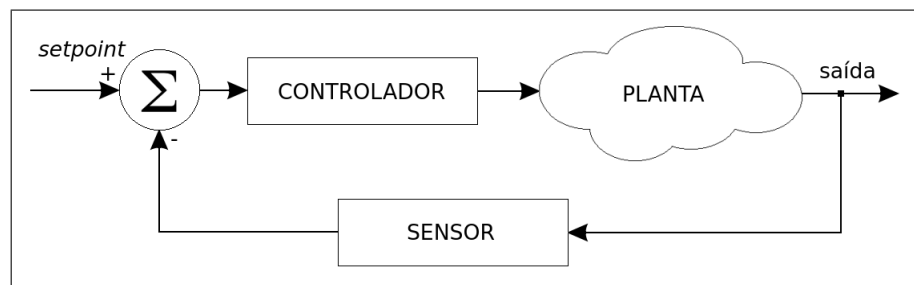
Um sistema de controle pode ser classificado como sendo de malha aberta ou fechada, dependendo da presença de retroação em sua configuração.

### 2.2.1 Controle a malha fechada

Diz-se que um sistema de controle é do tipo malha fechada quando há presença de retroação no esquema. Em outras palavras, o sinal de saída da malha de controle está ligado com o sinal de entrada (referência), seja diretamente ou através de uma função, suas derivadas e integrais (OGATA, 2011).

A Figura 1 mostra o esquema genérico de um controle a malha fechada. Observa-se a presença de um sensor que lê a variável controlada e passa o valor lido para compor a entrada do controlador.

Figura 1 – Esquema de um controle à malha fechada



Fonte: Elaborada pelo autor.

A retroação, ou retroalimentação da variável para o controlador, produzirá um erro através da diferença da referência e a saída medida. Este erro estimula o sistema de controle na produção de um sinal de saída que tende a minimizá-lo, ou seja, reaproxima a variável de controle do *setpoint*. Um controlador, portanto, manipula as entradas do sistema para obter o efeito desejado nas saídas deste sistema.

O controle a malha fechada é indicado quando há presença de perturbações externas e alterações imprevisíveis – ou seja, incerteza – nos parâmetros da planta. A retroalimentação permite que o sistema reaja imediatamente após a variação, tornando-o menos sensível a distúrbios. Em contrapartida, o constante ajuste da variável de mani-



pulação pode extrapolar o valor do erro e provocar oscilações crescentes. Neste caso há instabilidade – característica indesejada em um sistema de controle.

### 2.2.2 Controle a malha aberta

Nos sistemas de controle a malha aberta não existe realimentação, não havendo ação de controle decorrente do estado atual da planta (OGATA, 2011). Neste tipo de controle, todas as ações tomadas são conhecidas previamente – em função do tempo, exclusivamente – e carecem de uma boa calibração para atingirem uma performance aceitável.

Devido à capacidade nula de adaptação a variações e à alta dependência do conhecimento especialista do projetista, este tipo de malha somente pode ser aplicado à plantas que não sofrem distúrbios externos e que seus estados desejados são bem definidos em função do tempo.

Como exemplos, tem-se o conjunto semaforico, onde cada semáforo opera apenas em função do tempo; o controle de um forno micro-ondas, que leva em consideração apenas o tempo de programação; e a programação de lavagem de uma máquina de lavar, a qual não leva em consideração a limpeza das roupas.

## 2.3 Medidas de Desempenho

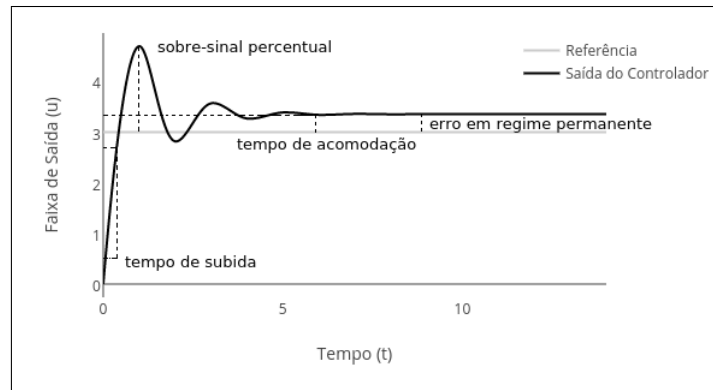
É necessário quantificar determinadas características da saída de um controlador para que seja possível determinar os requisitos de projeto de um sistema de controle, além de avaliar a qualidade deste aplicado à planta. Diferentes sistemas a controlar têm diferentes necessidades e parâmetros de controle. Por exemplo, uma planta necessita reagir extremamente rápido à eventuais alterações, mesmo que isso comprometa momentaneamente a estabilidade; enquanto outras aceitam uma correção mais lenta.

Várias métricas podem ser visualizadas a partir da leitura do gráfico da saída de um controlador. Através da Figura 2 pode-se observar a resposta de um controlador a malha fechada e várias medidas.

O tempo de subida, ou *rise time*, é a medida de tempo que o sistema leva para sair da condição inicial e chegar até o valor final. Esta medida também é utilizada na eletrônica, comumente para apresentar o tempo de subida da tensão em um capacitor. Na prática, o tempo de subida é calculado entre dois pontos, normalmente entre 10% e 90% ou 0% e 100% do valor final.

Observa-se, na Figura 2, que após a escalada do sinal, o controlador excede a referência e precisa agir para trazer o sinal novamente para baixo. Este valor excedido,

Figura 2 – Exemplo de resposta de um controlador de malha fechada com métricas



Fonte: Elaborada pelo autor.

expresso em porcentagem do valor final, é chamado de sobre-sinal percentual (tradução de *percent overshoot*).

Visualiza-se, ainda na Figura 2, que a resposta leva um tempo até que fique virtualmente estática em torno do valor final. Chama-se de *settling time*, termo em inglês para tempo de acomodação, o tempo que a resposta leva para se acomodar na faixa entre  $\pm 2\%$  ou  $\pm 5\%$  do valor final.

À proporção que a resposta tende ao valor de referência, o erro torna-se cada vez menor. Eventualmente, este passa a ser tão pequeno que é incapaz de estimular o controlador o suficiente para produzir uma saída diferente do instante  $t$  anterior – a menos que um distúrbio produza um erro maior. A partir deste ponto, diz-se que o sistema entrou em regime permanente, ou estado estacionário. Neste estado, é possível verificar o valor final da resposta do controle, e a partir deste, encontrar o *steady-state error* (erro em regime permanente). O erro em regime permanente é o valor final do erro no instante de tempo infinito, encontrado a partir da aplicação do teorema do valor final.

## 2.4 Controlador PID

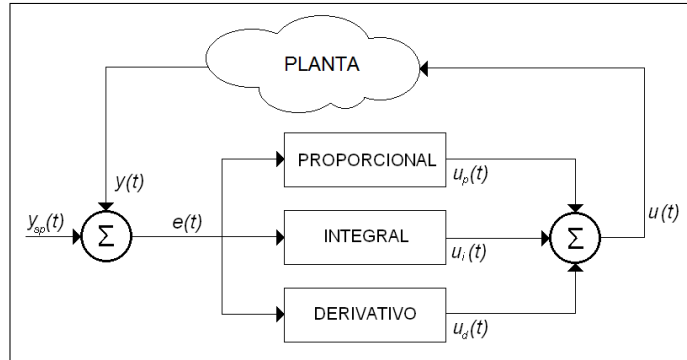
O controlador de três termos – Proporcional, Integral e Derivativo –, comumente chamado de controlador PID, é um mecanismo amplamente adotado devido a sua simplicidade e eficiência. Ele utiliza retroação para tomar as suas ações com base na função, integral e derivada do erro ( $e$ ) entre o *setpoint* e a variável de controle.

A construção deste simples controlador se iniciou pelo termo proporcional. Posteriormente, engenheiros de controle observaram que é possível produzir um melhor efeito de controle a partir da adição dos termos integral e derivativo (FRANKLIN; POWELL; EMANI-NAEINI, 2013).

A Figura 3 traz o exemplo de um esquema utilizando um controlador do tipo PID

em uma planta genérica. Observa-se se tratar de um controle a malha fechada, pois há retroação.

Figura 3 – Esquema de controlador PID



Fonte: Elaborada pelo autor.

### 2.4.1 Ação Proporcional

Esta ação é responsável por gerar um sinal de saída linearmente proporcional ao erro do sistema. A resposta deste termo é usualmente dada por:

$$u_p(t) = K_p \cdot e(t) \quad (2.1)$$

onde  $K_p$  é o ganho proporcional (ASTROM; HAGGLUND, 1995).

Empiricamente, a utilização de valores altos para o ganho proporcional reduz o tamanho do erro em regime permanente. Entretanto, neste caso, o sistema tende a tornar-se mais oscilatório.

### 2.4.2 Ação Integral

O termo integral garante que a saída do processo seja igual à referência quando o tempo  $t$  tende ao infinito. O termo integral é adicionado a um controlador proporcional, criando o controlador proporcional-integral, ou controlador PI. O controlador PI tem saída dada por:

$$u(t) = K_p \cdot e(t) + K_i \cdot \int_{t_0}^t e(t) dt \quad (2.2)$$

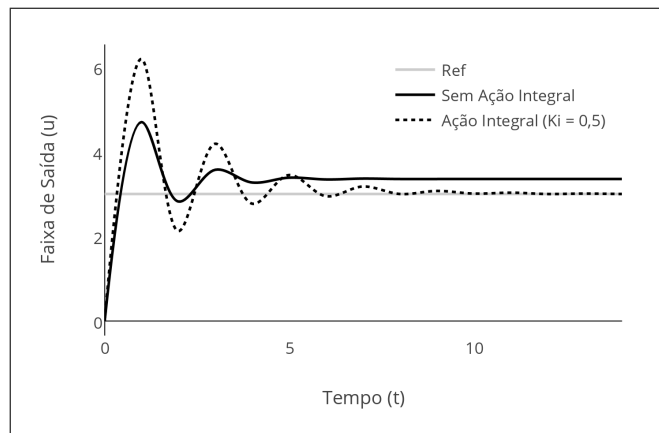
onde  $K_i$  – analogamente a  $K_p$  – é o ganho integral (FRANKLIN; POWELL; EMANI-NAEINI, 2013).

O resíduo do controle, mesmo que muito pequeno na maioria dos casos, é acumulado a cada ciclo do processo e eventualmente torna-se ruído suficiente para provocar uma reação do controle, fazendo com que a resposta assuma o valor da referência.

É sabido que a adoção do termo integral aumenta a oscilação da resposta do controlador, podendo comprometer o controle (MOORE; HETTHESSY; BARS, 2006). Tal

comportamento pode ser observado a partir do gráfico presente na Figura 4, que compara as saídas de um controlador P (menos oscilatório e com  $e_{ss} > 0$ ) e um controlador PI (mais oscilatório, porém eventualmente com  $e_{ss} = 0$ ).

Figura 4 – Comparativo entre as saídas de um controlador P e PI



Fonte: Elaborada pelo autor.

### 2.4.3 Ação Derivativa

O último termo do controlador PID é o derivativo. Este é responsável por reduzir a instabilidade – aumentada pela ação integral – do controle.

A ação derivativa torna o sinal menos oscilatório, tendo função preditiva com relação ao erro. De maneira muito simples, o erro atual é comparado ao erro imediatamente anterior, calculando-se a diferença entre estes.

Após a adição deste termo, a resposta do controle é dada por:

$$u(t) = K_p \cdot e(t) + K_i \cdot \int_{t_0}^t e(t) dt + K_d \cdot \frac{de(t)}{dt} \quad (2.3)$$

onde  $K_d$  é o ganho derivativo. Todos os parâmetros livres (os ganhos) são ajustados pelo projetista a fim da produção de uma melhor saída do controlador.

De forma análoga, a equação discreta do PID em Transformada Z é descrita através:

$$D(z) = K_p + K_i \frac{T}{z-1} + K_d \frac{z-1}{Tz} \quad (2.4)$$

onde o termo integral foi obtido através da integração discreta pelo método trapezoidal; o termo derivativo foi obtido através do método de Euler; e T é o tempo amostral. Os ganhos são os mesmos do método contínuo

## 2.5 Modelagem de Sistemas

A representação de sistemas de controle é parte fundamental da teoria do controle. Tal representação, ou modelagem, é utilizada para análise das características dinâmicas, sendo extremamente determinante para o sucesso ou fracasso do controle. Ogata define a modelagem matemática de um sistema dinâmico como sendo um conjunto de equações diferenciais que visam representar, de forma precisa ou aproximada, a dinâmica dos sistemas (OGATA, 2011).

De maneira superficial, a forma escolhida para se modelar matematicamente um sistema é dependente da aplicação e do compromisso *simplicidade vs precisão* adotado pelo projetista. Modelos simplificados têm simples obtenção, no entanto sua análise fica ineficiente à medida que o comportamento real do sistema torna-se mais complexo.

Obtidas através das leis físicas que governam o sistema modelado, equações diferenciais, também chamadas de equações de movimento, representam a primeira etapa de análise, a partir da qual as demais representações são derivadas (espaço de estados, funções de transferência, etc.).

Em sua grande maioria, as equações diferenciais são não-lineares, tendo análise e solução mais complexa (FRANKLIN; POWELL; EMANI-NAEINI, 2013). Entretanto, é comum que estas equações sejam linearizadas em torno de um ponto de equilíbrio, de modo que se aproxima o sistema não-linear por um linear equivalente em um intervalo de operação limitada. É importante enfatizar que mesmo sistemas físicos modelados por equações lineares (sistemas lineares) são realmente lineares apenas em faixas de operação (OGATA, 2011).

As leis de Newton são ponto inicial para o desenvolvimento das equações de movimento de sistemas mecânicos. Tomando-se por exemplo o movimento de um robô de A para B, as equações de movimento são derivadas a partir da lei de Newton:

$$\vec{F} = m\vec{a} \quad (2.5)$$

onde  $\vec{F}$  é o vetor soma de todas as forças aplicadas no robô,  $\vec{a}$  é o vetor de acelerações de acordo com a referência e  $m$  é a massa do robô. Usualmente, definem-se coordenadas relativas à referências de onde pode-se encontrar valores somente a partir das derivadas – posição ( $x$ ), velocidade ( $\dot{x}$ ) e aceleração ( $\ddot{x}$ ).

Percebe-se que para o caso de sistema de controle de velocidade, a partir da Equação 2.5 e conhecendo-se  $x$  e imaginando-se que a entrada do motor seja a força em N, seria possível realizar o controle. Entretanto o modelo estaria incompleto pois não leva-se em consideração elementos que devido a magnitude/frequência da ação são desprezíveis, como os atritos e a rigidez dos materiais utilizados.

Considere, por exemplo, uma haste flexível móvel. Somente para o caso da deflexão

do corpo, a equação diferencial é uma parcial de quarta-ordem dada por:

$$EI \frac{\partial^4 w}{\partial x^4} + \rho \frac{\partial^2 w}{\partial t^2} = 0 \quad (2.6)$$

onde  $E$  é o módulo de Young (medida de rigidez de um material sólido),  $I$  é a área da haste em repouso,  $\rho$  é a densidade do material da haste e  $w$  é a deflexão da haste no ponto  $x$  ao longo do corpo. A resolução deste sistema é complexa e pode tornar a análise inviável, sendo necessária portanto a modelagem do sistema utilizando métodos da teoria do controle clássico – função de transferência – ou o espaço de estados do controle moderno.

## 3 Controle Inteligente com Redes Neurais

O que conhece-se como Controle Inteligente é a fusão das áreas de Inteligência Artificial e Teoria do Controle, que foi motivada pela alta complexidade de aplicações com significativo nível de incerteza. Segundo alguns autores, o termo *inteligente* está diretamente ligado com a desejada capacidade de generalização, flexibilidade e adaptação de um sistema de controle (PASSINO, 2001; WHITE; SOFGE, 1992).

As áreas mais populares do Controle Inteligente envolvem noções de inteligência inspiradas no cérebro humano e na sua cognição, como as redes neurais e os sistemas *fuzzy*. Entretanto, não limitam-se a tais. Algoritmos genéticos, por exemplo, foram aplicados com sucesso em aplicações de controle (MAN; TANG, 1997).

Neste capítulo, abordam-se conceitos relativos ao Controle Inteligente utilizando estratégias *Feedback-Error-Learning* (FEL) e *Multi-Network-Feedback-Error-Learning* (MN-FEL). Estratégias estas que integram redes neurais em paralelo a controladores convencionais (*Conventional Feedback Controller*) de modo que aquelas sejam capazes de adquirir conhecimento sobre o sistema a ser controlado, melhorando a efetividade do controle.

### 3.1 Noções Básicas


Rede Neural Artificial (RNA) é uma técnica de aprendizado de máquina baseada no funcionamento dos neurônios, suas interconexões e no aprendizado humano. Suas raízes datam à década de 40 quando McCulloch e Pitts publicaram um trabalho (MCCULLOCH; PITTS, 1943) considerado como a base para o posterior desenvolvimento das RNAs. No final dos anos 50, Rosenblatt lança um trabalho formalizando a rede Perceptron de duas camadas (ROSENBLATT, 1958). As pesquisas e publicações na área das redes neurais continuaram frequentes até o apagar das luzes da década de 60, quando Minsky e Papert descobriram problemas graves com a técnica, como a incapacidade de resolver problemas não-linearmente separáveis – replicar o efeito de um circuito XOR (ou-exclusivo) (MINSKY; PAPERT, 1969). Somente em meados dos anos 90, após Werbos propor o algoritmo de aprendizado *backpropagation* (WERBOS, 1975), as redes neurais voltaram a atrair a atenção da comunidade.

Aplicadas às mais variadas áreas, redes neurais se popularizaram devido a sua facilidade de construção e a capacidade de ser um aproximador universal de funções (CYBENKO, 1989). Elas são um conjunto de neurônios artificiais dispostos em camadas interligadas, inspiradas nas sinapses entre os neurônios no cérebro humano.

O neurônio artificial é um elemento básico de uma RNA, estruturado de maneira

similar a um neurônio natural: possui uma entrada líquida inspirada nos dendritos e soma; fornece como saída o sinal através de uma função de ativação, representando os *spikes*. A força sináptica entre os neurônios artificiais é simulada através da utilização de pesos sinápticos que ponderam as entradas antes destas serem agregadas. Na Figura 5, é possível observar um neurônio artificial.


Figura 5 – Exemplo de neurônio artificial. As entradas  $x_i$  são ponderadas através dos pesos sinápticos  $\omega_i$  e posteriormente agregadas no módulo de soma. O resultado, chamado de entrada líquida, é passado pela a função de ativação e dado como *output* do neurônio.



Fonte: Elaborada pelo autor.

Os neurônios são organizados em camadas e apenas se ligam com neurônios de outras camadas (na maioria das RNAs). O número de camadas é variado e depende do tipo de RNA a ser construída. As RNAs *Multilayer Perceptron* (MLP) são as mais comuns de aprendizado supervisionado e contam com três camadas em sua forma básica – camada de entrada, escondida e de saída –, não sendo limitada a tal e podendo ter inúmeras camadas escondidas. A Figura 6 traz o exemplo de uma RNA MLP de três camadas.

Figura 6 – Exemplo estrutural de uma MLP *feedforward* de três camadas, sendo três neurônios na camada de entrada (marcados com I); quatro na camada escondida (H) e um único neurônio na camada de saída (O).



Fonte: Elaborada pelo autor.

É normal a presença de elementos que não possuem poder de processamento mas



estão ligados a neurônios para fornecer um sinal constante. Estes elementos são chamados de *bias* e estão normalmente conectados a neurônios nas camadas escondidas. Grosso modo, o *bias* permite que haja um deslocamento da saída da rede para a esquerda ou para a direita. A conexão de um *bias* e um neurônio é a mesma entre dois neurônios, tendo portanto um peso sináptico.

A função de ativação, ou função de transferência, é normalmente uma função sigmoide. No entanto, outras funções não-lineares, definidas em trecho ou *threshold* – também chamadas de degrau –, ou mesmo lineares podem ser utilizadas.

Formalmente, não existe limitação quanto a utilização de diferentes funções de ativação para diferentes neurônios de uma mesma RNA. Entretanto, tal abordagem é raramente encontrada em aplicações devido ao elevado crescimento de complexidade consequente.

A RNA aprende através do ajuste dos seus pesos sinápticos, o que é feito através do algoritmo de aprendizado. No caso das RNAs de aprendizado supervisionado, como na MLP, o mais comum é o *backpropagation*. Existem outros algoritmos, como por exemplo o aprendizado de Levenberg-Marquardt (MORÉ, 1978), além de métodos híbridos que utilizam técnicas de otimização combinados a algoritmos de aprendizado para acelerar o processo (ERDOGMUS et al., 2005).

O *backpropagation* realiza a atualização dos pesos através da retropropagação do erro através das camadas da rede. Todavia, o único erro conhecido é a diferença entre a saída esperada e a saída efetiva da rede. Logo, uma das maiores virtudes do *backpropagation* foi distribuir o erro entre os neurônios, camada por camada, de modo que ao final de cada época, todos os pesos fossem ajustados na proporção do seu resultado esperado.

Chama-se de época um ciclo completo de passagem de todas as entradas pelas camadas e a posterior atualização dos pesos. Uma época de um aprendizado por lotes compreende a computação da saída da RNA para um lote completo e a atualização dos pesos utilizando os erros. Por outro lado, a época de um aprendizado sequencial abrange a passagem de uma única instância pela rede e a atualização dos pesos de acordo com o erro correspondente.

## 3.2 Redes Neurais e Controle

Por ser uma técnica de aprendizado de máquina muito flexível, o papel da RNA dentro de um sistema de controle pode ser o mais variado o possível. Por exemplo, pode-se utilizar uma rede neural para que se substitua o controlador; pode-se pôr a RNA para trabalhar em paralelo com um controlador convencional (CV); é possível modelar a planta utilizando uma RNA e utilizar este modelo para prever a melhor ação de controle que irá

promover o melhor desempenho do processo e etc.

A utilização de várias redes neurais também é uma possibilidade. Empiricamente, imagina-se que o aprendizado pode ser melhor realizado ou ao menos mais rapidamente alcançado quando são utilizadas mais de uma rede. Isto deve-se ao fato de que o projetista não terá que refazer os testes várias vezes para definir a estrutura *ideal* de uma única rede para o problema.

### 3.2.1 *Feedback-Error-Learning*

*Feedback-Error-Learning* (KAWATO; FURUKAWA; SUZUKI, 1987; MIYAMOTO et al., 1988; GOMI; KAWATO, 1990) é uma estratégia de controle que integra uma RNA em paralelo a um CV de modo que aquela seja capaz de adquirir conhecimento sobre o sistema em controle, auxiliando no controle das incertezas e melhorando o desempenho, enquanto este é responsável por estabilizar a planta e ditar as ações de controle iniciais. Dentre as virtudes do FEL, destaca-se a manutenção do CV (evita que todo o sistema de controle anterior seja descomissionado) e a capacidade de realizar-se aprendizado online e offline, dependendo da realidade do sistema de controle. Não se especifica um tipo de rede para a estratégia FEL, no entanto prevalecem as MLPs nas implementações.


O CV, no entanto, não é capaz de garantir a estabilidade da planta por si só. Ao inserir a rede, por ainda não ter sido treinada, pode-se obter como *output* sinais de controle que instabilizam o controle. Por este motivo, uma inicialização apropriada dos pesos da RNA deve ser realizada, de modo que enquanto a rede treina, o CV possa controlar a planta estavelmente (ALMEIDA NETO, 2003).

Naturalmente, construindo-se um sistema de controle que age de acordo com um sinal de erro da planta e na presença de uma RNA que aprende com o sinal de erro entre a sua resposta e o valor esperado, imagina-se que o aprendizado da RNA utilize o erro da planta. No entanto, o sinal de erro dado à RNA é a saída do CV. Como a saída da rede é acumulada à saída do CV antes de ser passada à planta, ao minimizar o erro (resposta do CV), minimiza-se o erro da planta e aos poucos a RNA toma as ações de controle antes ditadas pelo CV. A Figura 7 traz o esquema básico FEL.

Duas abordagens de controle diferentes foram propostas no trabalho (GOMI; KAWATO, 1990), chamadas de IDML – sigla para *Inverse Dynamic Model Learning* – e NRL – sigla para *Nonlinear Regulator Learning*. Estruturalmente, a única diferença entre elas está nos *inputs*. A abordagem IDML recebe como *input* da RNA apenas as saídas da planta, enquanto a NRL recebe, além das saídas da planta, a referência para o sistema de controle e o erro da planta.

Todavia, em se tratando da função da RNA e do seu aprendizado, a primeira abordagem adquire o modelo dinâmico inverso do sistema controlado, e a NRL torna a

Figura 7 – Esquema básico FEL. Note que o sinal de erro utilizado pela RNA é a saída do CV  $u_{cfc}$ . O sinal enviado à planta é a soma das saídas da rede e do CV.  $u = u_n + u_{cfc}$ .




Fonte: (ALMEIDA NETO, 2003).

RNA um regulador não-linear para compensar pela não-linearidade da planta.

Na estrutura FEL original foi desenvolvida para o controle de manipuladores robóticos. Nascimento, em sua tese de doutorado (NASCIMENTO, 1994), propôs modificações à estrutura original, tornando-a mais geral. A primeira modificação é a inclusão de um *tapped delay line* para passagem de referências atrasadas à RNA. Desta forma, a rede torna-se capaz de perceber as variações na referência – antes, essas variações eram percebidas através de derivadas de alta ordem, normalmente calculadas numericamente em uma central de diferenciação.

A segunda modificação foi a passagem da referência atrasada em  $M$  períodos de tempo para o CV. Com esta sutil modificação, a RNA passa a aprender o modelo inverso atrasado da planta. Nascimento afirma que na estrutural original, a RNA teria uma tarefa mais árdua ao passo que agiria como um preditor, compensando enquanto a planta reage à entrada (NASCIMENTO, 1994). O esquema proposto por Nascimento pode ser visualizado através da Figura 8.

Figura 8 – Estrutura FEL modificada com *tapped delay line* e atraso de referência em  $M$  períodos para o CV.



Fonte: (ALMEIDA NETO, 2003).

### 3.2.2 Multi-Network-Feedback-Error-Learning

A estratégia *Multi-Network-Feedback-Error-Learning* (MNFEL) é um desenvolvimento da estratégia FEL que aplica múltiplas RNAs em paralelo ao CV. Proposta por Almeida Neto em sua tese de doutorado (ALMEIDA NETO, 2003), a estratégia de

controle foi aplicada com sucesso em ambientes simulados (RIBEIRO; ALMEIDA NETO; OLIVEIRA, 2010) e aplicações reais (ALMEIDA NETO; GOES; NASCIMENTO, 2010). O MNFEL difere de outra estratégia de múltiplas redes neurais (YAMAGUCHI; ITAKURA, 1999) no ponto em que esta utiliza um CV para cada RNA associada.

Partindo do princípio de *Dividir para Conquistar*, Almeida Neto propôs uma estrutura FEL onde várias RNAs são empregadas para realizar um aprendizado acumulativo do modelo dinâmico inverso de um sistema a controlar. A motivação está no fato de que este modelo pode ser complexo ao ponto de demandar muito tempo em construção de diferentes configurações de redes.

A estratégia MNFEL permite que uma nova rede seja acrescida ao processo quando percebe-se que a RNA em treinamento não é mais capaz de atingir um aprendizado satisfatório. Acrescentar uma nova rede ao processo levanta a preocupação de que a nova RNA possa deteriorar o aprendizado que está sendo realizado por outra rede. Entretanto, uma RNA só é adicionada após a fase de aprendizado da anterior ter sido parado, ou seja, os pesos sinápticos são congelados. Como as redes são empilhadas, realizando acúmulo das suas saídas, não perde-se a parcela de contribuição que uma RNA anterior deu ao controle.

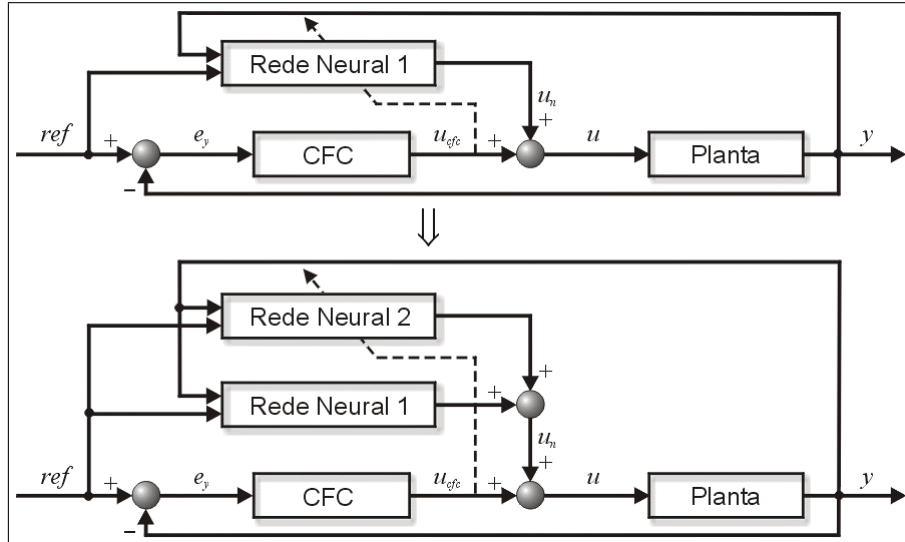
Na Figura 9, é possível acompanhar o momento em que o treinamento da primeira rede é finalizado e uma nova rede é adicionada. Primeiro, na parte superior da imagem, o treinamento com apenas uma RNA. Quando julga-se que esta não é mais capaz de aproximar o modelo inverso da planta, uma nova RNA é adicionada ao processo. No segundo momento, com duas redes, apenas a RNA mais recente está em treinamento enquanto a anterior fornece a sua saída como contribuição para o controle.

É importante frisar – observando-se a Figura 9 – que o sinal ( $u_{cfc}$ ) utilizado para treinar a primeira RNA é o mesmo utilizado no treinamento das demais. Isto não significa que  $u_{cfc}$  tem o mesmo valor em diferentes sessões de treinamento<sup>1</sup>, mesmo para a mesma referência *ref* (ALMEIDA NETO; GOES; NASCIMENTO, 2010). Ao passo que as RNAs vão adquirindo uma aproximação melhor do modelo inverso da planta, a saída do CV diminui.

Se por um lado, na estratégia FEL, existe a preocupação de uma inicialização adequada dos pesos para evitar que a RNA instabilize o sistema, no MNFEL a preocupação é proporcional ao número de redes inseridas. Como cada rede deve ter seus pesos inicializados, empiricamente, teme-se pela eficiência computacional do processo. Entretanto, a inicialização é feita de maneira simples: atribui-se uma matriz de pesos iniciais nulos na camada de saída da nova rede. Este passo, além de garantir a estabilidade do processo durante o treinamento de uma nova RNA, é computacionalmente menos custoso que realizar a atribuição de pesos aleatórios.

<sup>1</sup> Chama-se de sessão de treinamento o conjunto de épocas de treinamento de uma RNA no MNFEL.

Figura 9 – Estratégia MNFEL em treinamento. Note que não há elemento realizando a coordenação das múltiplas redes. Tal efeito só pôde ser alcançado devido à política de treinamento adotada na MNFEL – que congela o treinamento da rede anterior antes de acrescentar uma nova – e à maneira que as redes são integradas.



Fonte: (ALMEIDA NETO, 2003).

Apesar de ser computacionalmente leve, se comparado a outras técnicas de múltiplas redes neurais, a estratégia tem uma grande desvantagem relacionada à inserção de novas redes. A inserção é realizada de maneira manual, supervisionada por um agente externo que identifica quando uma RNA está esgotada. Do ponto de vista das aplicações, este ponto fraco praticamente inviabiliza a utilização em sistemas de controles online industriais, pois requer a contínua alocação de um especialista para assistir o processo.

### 3.2.2.1 Critério de parada e inserção das redes pelo desvio padrão do erro

Como solução para a desvantagem do MNFEL – a inserção manual de redes – Ribeiro propôs um método baseado no desvio padrão do erro da planta que aponta o momento para finalizar o treinamento da rede anterior e acrescentar a nova RNA (RIBEIRO; ALMEIDA NETO; OLIVEIRA, 2010). O método foi comparado com o MNFEL original, onde as adições foram realizadas por um especialista, e mostrou desempenho eficiente.

O simples método analisa o erro da planta a todo instante, identificando se a dispersão está maior ou igual depois de algumas sessões de treinamento. O caso da dispersão estar maior é um indício de que a configuração atual da MNFEL está tendo dificuldades para adquirir o modelo dinâmico inverso da planta. O desvio padrão é dado por:

$$D_p = \sqrt{\frac{1}{N-1} \sum_{t=1}^N (e(t) - e_m)^2} \quad (3.1)$$

onde  $N$  é o número de épocas da sessão de treinamento atual,  $e(t)$  é o erro da planta durante na época  $t$  e  $e_m$  é a média do erro.

### 3.2.2.2 Critério de parada e inserção das redes pelo erro quadrático médio

A inserção de novas redes não necessariamente é realizada pelo método do desvio padrão. Outras métricas, como o erro quadrático médio (EQM), podem ser utilizadas para estimar o momento ideal de inserção de uma nova RNA. Enquanto todos os métodos compartilham do mesmo objetivo, que é adicionar uma nova rede em momento adequado, a execução difere na filosofia abordada para estimar o momento de inserção.

No método pelo erro quadrático médio, uma nova rede é inserida quando identifica-se a não variação ou subida do EQM entre duas sessões de treinamento. Este comportamento, que pode indicar a saturação do treinamento, justifica a inserção de uma nova rede ou a finalização do treinamento da estratégia.

O método do EQM é menos sensível a alterações no erro durante a sessão de treinamento se comparado ao método do desvio padrão. Isto prolonga o treinamento e pode, em alguns casos, levar a uma melhor acurácia na generalização. Entretanto, preocupa-se mais com o efeito de *overfit* – excesso de treinamento de uma técnica, levando à especialização no conjunto de dados treinado mas sem a mesma acurácia utilizando dados novos – quando utiliza-se EQM do que o mesmo treinamento com desvio padrão.

### 3.2.3 Avaliação do desempenho das redes no controle

Ao utilizar uma técnica de controle inteligente – como as apresentadas FEL e MNFEL – pode-se avaliar não somente o controle obtido, mas também a efetividade das técnicas de inteligência artificial aplicadas.

Nas estratégias FEL e MNFEL, pesquisa anterior propôs que a avaliação da efetividade das redes neurais seja medida a partir dos coeficientes de correlação calculados entre dados lidos do controle (RIBEIRO, 2009).

Medidas de correlação são muito úteis para suporte e desenvolvimento de teorias que venham a justificar os eventos observados. O termo correlação, ou associação, é, portanto, interpretado como a interdependência entre duas variáveis (EVERITT; SKRONDAL, 2010), sem qualquer conexão com a causalidade das observações. A medida de correlação, neste contexto, é um coeficiente que quantifica a relação entre pares de variáveis de modo que possa-se afirmar, apenas avaliando a grandeza, que uma observação está relacionada à outra.

### 3.2.3.1 Coeficiente de Correlação de Pearson

Também chamado de Coeficiente de Correlação Produto-Momento de Pearson, o coeficiente de Pearson (CP) é uma medida de correlação linear entre duas variáveis. O coeficiente é, portanto, capaz de apontar o grau de relação e a direção da relação entre os pares quando estes apresentam um comportamento linear.

A equação do coeficiente foi primeiramente descrita no final do século XIX em uma publicação da *Royal Society of London* (PEARSON, 1895) e desde então é vastamente utilizada para quantificar relações lineares de correlação. O coeficiente pode ser descrito para uma população como:

$$\rho_{X,Y} = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} \quad (3.2)$$

onde  $\rho$  denota a correlação linear de Pearson entre as populações  $X$  e  $Y$ , sendo  $\text{Cov}$  a covariância e  $\sigma$  o desvio padrão.

É possível, também, descrever o coeficiente de Pearson para amostras:

$$r_p = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.3)$$

sendo  $n$  o tamanho da amostra,  $x_i$  e  $y_i$  as  $i$ -ésimas observações e  $\bar{x}$  e  $\bar{y}$  as médias amostrais. Pelo denominador das equações 3.2 e 3.3 percebe-se que o coeficiente não poderá ser calculado caso ao menos um dos conjuntos de dados seja completamente homogêneo.

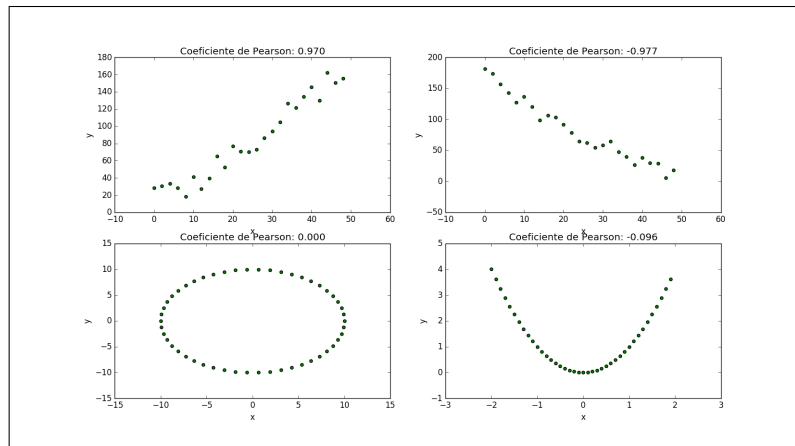
Os coeficientes  $\rho$  e  $r_p$  variam entre  $-1$  e  $1$ , inclusive, onde o sinal indica a direção da relação e o módulo do valor indica o grau do relacionamento. Quando a correlação de Pearson atinge o valor  $-1$  diz-se que há uma correlação perfeitamente negativa entre os pares, de modo que uma variável diminui enquanto a outra aumenta. Analogamente, quando o valor é  $1$ , diz-se que a correlação é perfeita e positiva, indicando que uma variável cresce enquanto a outra também.

Na Figura 10, é possível observar o coeficiente amostral de Pearson calculado para diferentes padrões de dados. É notável que nas amostras dos quadros inferiores, não-lineares, o coeficiente é igual ou muito próximo de zero. Nestas ocasiões, onde o coeficiente é muito próximo de  $0$ , é seguro afirmar que não existe correlação linear entre as variáveis. No entanto, isto não implica que os dados sejam completamente não relacionados. Como observado, é possível que os dados apresentem uma relação não-linear.

### 3.2.3.2 Coeficiente de Correlação de Postos de Spearman

O coeficiente de correlação de postos de Spearman (SPEARMAN, 1904), ou simplesmente coeficiente de Spearman (CS), é um método não paramétrico alternativo ao coeficiente de Pearson capaz de calcular a correlação entre duas variáveis utilizando relações monótonas, sejam elas lineares ou não (HAUKE; KOSSOWSKI, 2011).

Figura 10 – Coeficiente de Pearson calculado para diferentes padrões de dados.



Fonte: Elaborada pelo autor.

O coeficiente de Spearman é um caso especial de aplicação do coeficiente de Pearson onde a correlação é calculada entre os postos<sup>2</sup> ao invés dos dados originais. Deste modo, o método de Spearman torna-se mais robusto à presença de *outliers* e é capaz de medir o grau e direção da relação não-linear monótona de duas variáveis.

O coeficiente de Spearman  $\rho_s$  é, portanto, formalmente definido como

$$\rho_s = \rho_{r_X, r_Y} = \frac{\text{Cov}(r_X, r_Y)}{\sigma_{r_X} \sigma_{r_Y}} \quad (3.4)$$

onde  $r_X$  e  $r_Y$  são os postos dos dados de  $X$  e  $Y$ , respectivamente.

Seja  $X$  contendo  $n$  observações  $x_i$  distintas de modo que  $X = (x_1, x_2, x_3, \dots, x_n)$  é ordenado crescentemente. Os postos de  $X$  são, portanto, os respectivos valores dos subscritos de  $x_i$  onde  $r_X = (1, 2, 3, \dots, n)$ . Em aplicações reais, entretanto, é incomum que os dados contenham apenas valores distintos. Nestes casos, o posto de um valor com repetição é igual à média dos subscritos de todas as ocorrências.

Para os casos onde  $X$  e  $Y$  contêm apenas observações distintas (avaliando-se somente o próprio grupo de observações), isto é, os postos  $r_X$  e  $r_Y$  são valores inteiros distintos respeitando uma distribuição discreta uniforme, tem-se o coeficiente de Spearman conforme

$$\rho_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (3.5)$$

onde  $d_i$  é a diferença dos postos de  $x_i$  e  $y_i$ .

Note que  $\rho_s$  na Equação 3.4 é o CP, conforme definido nas Equações 3.2 e 3.3, para os postos das observações. Desta forma, o intervalo dos valores do coeficiente de Spearman são os mesmos do coeficiente de Pearson. A interpretação dos valores também

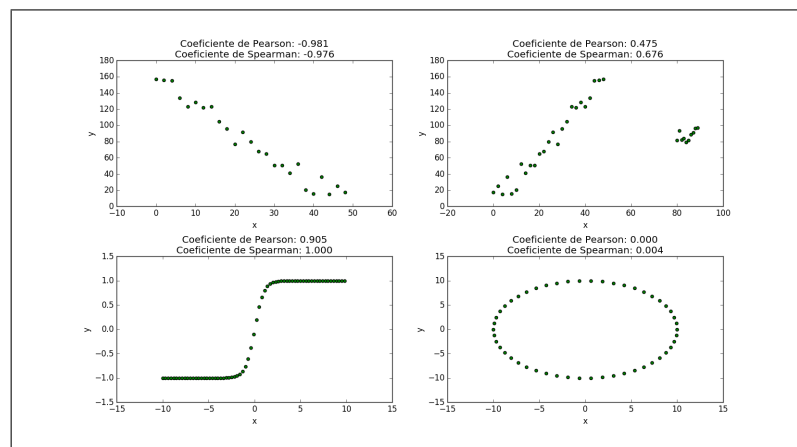
<sup>2</sup> Em estatística, posto ou *rank* é a representação da ordem de um determinado dado na amostra.



leva à classificação em perfeitamente correlacionados, positivamente ou negativamente, divergindo do CP apenas pela relação ser monótona e não apenas linear.

Através da Figura 11, avaliando-se o gráfico superior esquerdo é possível perceber que o coeficiente de Spearman tem comportamento muito similar ao coeficiente de Pearson quando aplicado a dados lineares. Percebe-se pelo gráfico superior direito que o coeficiente de Spearman foi menos afetado pelos *outliers* presentes nos dados. No gráfico inferior esquerdo, CS conseguiu correlacionar perfeitamente a função da tangente hiperbólica por esta ser não-linear. Entretanto, quando apresentado um conjunto de dados que não pode ser correlacionado por funções monótonas, como no gráfico inferior direito, o CS indica a não correlação.

Figura 11 – Coeficiente de Spearman calculado para diferentes padrões de dados em comparação com o coeficiente de Pearson.



Fonte: Elaborada pelo autor.

### 3.2.3.3 Método de avaliação através do Coeficiente de Pearson

O método proposto em (RIBEIRO, 2009) cobriu uma lacuna na literatura a respeito das métricas que descrevem a efetividade da estratégia FEL e MNFEL quando aplicadas a diferentes plantas. O método de avaliação utiliza a correlação entre o erro da planta e a ação do controlador convencional para inferir se as redes foram capazes de desempenhar as suas funções nas estratégias FEL e MNFEL.

O autor argumenta que, durante o treinamento, as redes neurais irão diminuir a ação do controlador convencional ao mesmo passo que melhoram o controle, portanto levando a uma diminuição no erro. Deste modo, pode-se inferir se as redes estão desempenhando as funções definidas de modo efetivo a partir da correlação entre o erro da planta e a ação do controlador convencional.

Adicionalmente, o trabalho aponta o efeito esperado do Coeficiente de Pearson ao longo do treinamento. Espera-se que, como ambos dados (erro e ação do controlador

convencional) devem diminuir devido à aplicação da estratégia, a correlação entre eles apresenta padrão crescente.

O método foi testado em uma planta simulada, obtendo como resultado o efeito esperado para o Coeficiente de Pearson ao longo do treinamento.

## 4 Métricas de avaliação de desempenho para as estratégias FEL e MNFEL

As estratégias *Multi-Network-Feedback-Error-Learning* (MNFEL) e *Feedback-Error-Learning* (FEL) têm sido aplicadas com sucesso em várias plantas, todas com diferentes particularidades quanto ao seu funcionamento – padrões da referência, distúrbio, etc. O desempenho da estratégia, no entanto, tem sido mensurada a partir de métricas clássicas de controle e pela comparação dos *outputs* das plantas (RIBEIRO, 2009; RIBEIRO et al., 2009; RIBEIRO; ALMEIDA NETO; OLIVEIRA, 2010; ALMEIDA NETO; GOES; NASCIMENTO, 2010; RODOR et al., 2017).

Estas métricas, por apenas considerarem os efeitos e a qualidade do controle, não permitem uma avaliação detalhada da técnica de controle inteligente aplicada, ou seja, se as redes desempenham as suas funções como foram estabelecidas durante o projeto do sistema de controle.

Este capítulo apresenta a proposta de métricas de avaliação de qualidade de treinamento de redes neurais em aplicações que utilizam estratégias FEL e MNFEL. As métricas são baseadas nos coeficientes de correlação de Spearman e Pearson, calculados entre os erros das plantas e as ações do controlador convencional.

### 4.1 Métricas de Avaliação

Métricas de avaliação desempenham papel importante em controle inteligente, não somente para expôr resultados e permitir comparações entre técnicas, mas também para auxiliar a tomada de decisão de especialistas, seja durante o projeto ou durante a execução do sistema em questão.

Na literatura, é comum encontrar trabalhos que visam o desenvolvimento de métricas, sejam estas específicas de um problema – como a definição de medidas de performance específicas para a interação *Human-Automation* (DONMEZ; PINA; CUMMINGS, 2009) – ou mais abrangentes – por exemplo, uma métrica para sistemas inteligentes baseada na teoria da comunicação (HAFEZ, 2012).

Em se tratando de sistemas de controle inteligente, as métricas clássicas são comumente aplicadas. Todavia, a avaliação utilizando tais medidas – referentes às estratégias de controle inteligente que, assim como FEL e MNFEL, trabalham lado a lado com técnicas convencionais – fica limitada a avaliar apenas o desempenho do controle. No caso específico de FEL e MNFEL, é difícil para o especialista acompanhar a evolução do treinamento das

redes e perceber a efetividade do método em cada época, dado o fato de que o controlador convencional está sempre atuando.

As técnicas FEL e MNFEL, na maior parte das vezes, são aferidas a partir da comparação das saídas do controle com base em métricas de avaliação de erro, como o erro quadrático médio e dispersão do erro (ALMEIDA NETO; GOES; NASCIMENTO, 2010; RIBEIRO; ALMEIDA NETO; OLIVEIRA, 2010; TAKAHASHI et al., 2017). Desta forma, presume-se que a utilização das redes para a aquisição do modelo dinâmico inverso, na configuração IDML (*Inverse Dynamics Model Learning*), ou para a compensação pela não-linearidade, na NRL (*Nonlinear Regulator Learning*), está sendo efetiva com base simplesmente na diminuição do erro da planta.

Tal avaliação de desempenho é adequada caso se deseje indicar se a técnica está influenciando para a melhoria do sistema de controle. Contudo, do ponto de vista do papel das redes neurais no processo, não é seguro afirmar que as redes estão compensando efetivamente para a não-linearidade da planta, apenas observando-se o erro.

Não é abundante na literatura a presença de trabalhos propondo ou abordando métricas específicas para as estratégias FEL e MNFEL. Por exemplo, o coeficiente de correlação de Pearson tem sido utilizado para quantificar a contribuição de múltiplas redes ao processo (RIBEIRO, 2009), conforme descrito na Seção 3.2.3.3 do Capítulo 3. Todavia, a utilização do Coeficiente de Pearson (CP), como métrica, toma considerações que não podem ser garantidas na maioria dos sistemas de controle, dado que grande parte das plantas reais não são lineares.

Este trabalho propõe duas métricas de avaliação, específicas para as estratégias FEL e MNFEL, que utilizam coeficientes de correlação de Spearman e Pearson para inferir o desempenho das redes neurais no processo. Os coeficientes são calculados entre os erros da planta e as ações do controlador convencional.

O principal coeficiente de correlação a ser utilizado é o de Spearman (CS), com apoio do Coeficiente de Pearson (CP) para que seja possível identificar quando a correlação entre os erros da planta e as ações de CV é linear. Devido a limitação de correlacionar apenas dados monótonos e lineares, os coeficientes não se mostram efetivos em todos os padrões de erro e ações de controle possíveis. Todavia, como é sabido que estes dados são relacionados devido à natureza de funcionamento da planta e do controlador convencional, a intenção não é medir efetivamente a correlação entre as variáveis, mas aferir se há crescimento ou decréscimo no grau de correlação, de acordo com o padrão inicialmente observado no controle, anterior à aplicação da FEL ou MNFEL.

### 4.1.1 Avaliação utilizando o coeficiente de Spearman

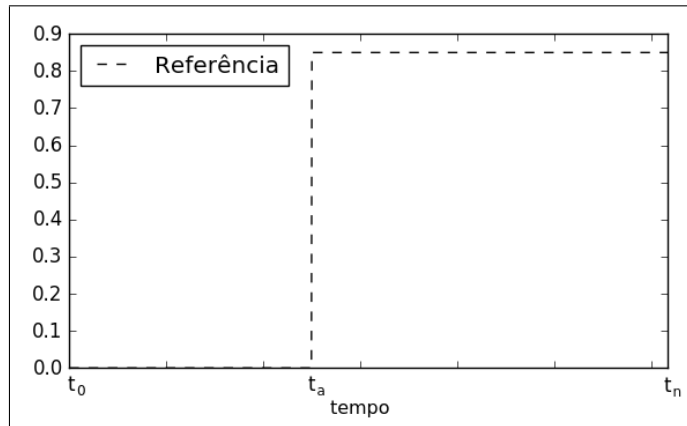
O coeficiente de Spearman é uma alternativa ao Coeficiente de Pearson por ser capaz de medir o grau de correlação entre duas variáveis utilizando funções monótonas. Assim como Pearson, o coeficiente varia no intervalo  $[-1, 1]$  onde os extremos indicam uma correlação negativa perfeita e positiva perfeita, respectivamente.

O cálculo por CS, como abordado na Seção 3.2.3.2 do Capítulo 3, é menos suscetível a ruídos quando na presença de *outliers*, sofre uma influência maior à frequência dos dados e é menos dependente da magnitude dos dados que está correlacionando, quando comparado ao CP.

Como descrito acima, o coeficiente de Spearman recebe os dados de entrada e responde da mesma maneira que CP, além de ter características favoráveis à aplicação em sistemas controlados por FEL ou MNFEL. Deste modo, propõe-se o coeficiente como métrica de avaliação do papel das redes nas estratégias FEL e MNFEL, aqui denominada de avaliação por CS.

Para a aplicação da métrica, se faz necessário utilizar apenas o dados de leitura de determinado período do treinamento. Considere o gráfico da Figura 12 que contém uma referência do tipo degrau, aplicada a uma planta qualquer controlada por FEL ou MNFEL, onde CV é do tipo PID.

Figura 12 – Exemplo de referência do tipo degrau



Fonte: Elaborada pelo autor.

O controle utilizando referência, apresentada na Figura 12, pode ser dividido em dois momentos: anterior e posterior ao degrau. Tem-se, portanto que um instante de tempo  $t_i$  faz parte do conjunto de instantes anteriores ao degrau ( $T_a$ ) quando

$$t_i \in T_a, 0 \leq i \leq a$$

onde  $a$  representa o último subscrito de  $t$  onde a referência  $r$  é  $r(t_a) \neq 0$ . De maneira

análoga, o instante  $t_i$  faz parte do conjunto de instantes posteriores ao degrau ( $T_p$ ) quando

$$t_i \in T_p, \quad a < i \leq n$$

onde  $n$  é o número de instantes de tempo do controle. Deste modo, usa-se a referência  $r$  em função do tempo  $t$ , sendo:

$$r(t) = \begin{cases} 0, & \text{se } t \in T_a \\ > 0, & \text{se } t \in T_p \end{cases}$$

Considerando que a planta em  $t_0$  tem saída  $y(t_0) = 0$ , tem-se que o erro ( $e$ ) é conseqüentemente  $e(t_0) = 0$ , dado que  $e(t) = r(t) - y(t)$ . Visto que o controlador convencional PID – conforme Equações 2.3 e 2.4 descrita na Seção 2.4 do Capítulo 2 – é acionado por  $e$ , então a ação de controle  $u_{cfc}(t)$  do CV é

$$u_{cfc}(t) = 0, \quad \forall t \in T_a$$

Portanto, o sistema está em equilíbrio até que a referência sofra o degrau ou até que as redes da estratégia FEL ou MNFEL produzam um valor diferente de zero. Caso as redes produzam uma oscilação e retirem o controle do seu equilíbrio, o PID será acionado para equilibrar novamente a planta. Conseqüentemente as redes irão *aprender* com a ação do PID – devido ao fato de que o sinal de aprendizado das redes é  $u_{cfc}$  –, compensando pela própria presença no sistema de controle.

Desta forma, argumenta-se que todos os instantes  $t \in T_a$  devem ser desconsiderados da avaliação, visto que as redes estão compensando pela sua existência no controle, não compensando, portanto, pela não-linearidade da planta. Para futuras menções, chama-se este procedimento de DPAD, sigla para *descarte do período anterior ao degrau*.

Os dados de erro da planta, em suas observações naturais  $e(t)$ , podem se alternar entre valores positivos e negativos de um instante  $t_i$  para  $t_{i+1}$ . Esta variação, natural do processo de controle e do dinamismo da planta, não é interessante para a aplicação da métrica, que busca relacionar o erro, independente do sentido, e a ações do CV.

Portanto, calcula-se o coeficiente de Spearman a partir dos erros quadráticos  $e(t)^2$  e das ações de controle  $u(t)$  do controlador convencional. Deste modo, define-se a métrica como sendo:

$$\rho_s = \frac{\sum_{i=1}^N (re_i - \bar{r}e)(ru_i - \bar{r}u)}{\sqrt{\sum_{i=1}^N (re_i - \bar{r}e)^2} \sqrt{\sum_{i=1}^N (ru_i - \bar{r}u)^2}} \quad (4.1)$$

onde  $re_i$  e  $\bar{r}e$  são o  $i$ -ésimo posto e a média dos postos de  $e(t)^2$ , respectivamente. Analogamente,  $ru_i$  e  $\bar{r}u$  são o  $i$ -ésimo posto e a média dos postos de  $u(t)$ . O conjunto de postos tem  $N$  observações para cada variável, obtidas nos instantes  $t \in T_p$ , onde  $T_p$  é o conjunto de instantes posteriores ao degrau da referência.

### 4.1.2 Avaliação utilizando os coeficientes de Spearman e de Pearson

A segunda métrica de avaliação utiliza os dois coeficientes de correlação (Spearman e Pearson) em conjunto, chamada de avaliação por CP-CS conjugados. O coeficiente de Pearson pode ser aliado ao coeficiente de Spearman para auxiliar na descoberta da relação linear. Pelo fato do CS apontar as relações monótonas, dentre elas a linear, a obtenção da correlação perfeita através do CS não dá indícios de que a relação encontrada seja linear, sendo assim necessário o auxílio do CP para a distinção.

Devido a esta característica, o método com os dois coeficientes pode ser capaz de melhor representar o efeito observado no desempenho das redes neurais no controle.

Para a proposta de avaliação com estes dois coeficientes, calcula-se as variáveis nas mesmas condições especificadas na Seção 4.1.1, ou seja, somente após o processo DPAD para desconsiderar as leituras realizadas nos instantes  $t \in T_a$ ; e utiliza os erros quadráticos da planta  $e(t)^2$ .

Portanto, o cálculo do coeficiente de Spearman é feito de acordo com a Equação 4.1. Define-se o Coeficiente de Pearson para a métrica de avaliação, sendo:

$$r_p = \frac{\sum_{i=a+1}^n (e(t_i)^2 - \bar{e}^2)(u(t_i) - \bar{u})}{\sqrt{\sum_{i=a+1}^n (e(t_i)^2 - \bar{e}^2)^2} \sqrt{\sum_{i=a+1}^n (u(t_i) - \bar{u})^2}} \quad (4.2)$$

onde  $a$  é o último subscrito de  $t$  onde a referência  $r$  é  $r(t_a) \neq 0$ ; o instante  $t_i$  está após o degrau, sendo  $t_i \in T_a$ ; o erro quadrático da planta é  $e(t_i)^2$ , enquanto a ação do controlador convencional é  $u(t_i)$ ; o erro quadrático médio e a ação média do CV são  $\bar{e}^2$  e  $\bar{u}$ , respectivamente.

### 4.1.3 Metodologia de avaliação proposta

A aplicação das métricas propostas neste trabalho segue uma metodologia de avaliação dividida em duas etapas. Na primeira etapa, chamada de identificação inicial da correlação (IIC), realiza-se uma investigação da correlação entre  $e(t)$  e  $u(t)$  anterior à aplicação da estratégia de controle inteligente. Na segunda etapa, avaliação do treinamento (AT), faz-se a avaliação dos coeficientes ao longo do treinamento.

Na etapa de identificação inicial da correlação, o projetista deve analisar, visualmente e com o auxílio dos coeficientes de correlação utilizados, os dados  $e(t)$  e  $u(t)$  obtidos a partir do controle da planta apenas com o controlador convencional.

Nesta etapa, o objetivo do projetista é identificar as condições iniciais da correlação entre as variáveis em questão, de modo que, para os coeficientes de correlação, possa-se inferir um ou mais comportamentos que indiquem o bom desempenho da função das redes no processo (aquisição do modelo inverso da planta ou a compensação pela não-linearidade).

Num cenário onde o projetista identifica que a correlação inicial dos dados aponta uma forte relação linear, é esperado que, após a inserção da estratégia FEL ou MNFEL, as redes passem a compensar por eventuais não-linearidades da planta. Portanto, é esperado que durante o treinamento, os coeficientes de correlação apontem a perda de linearidade na relação.

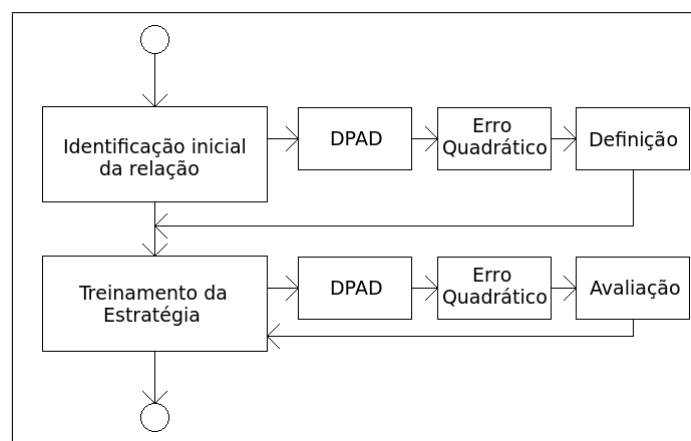
Em um outro cenário, o projetista constata uma correlação inicial não-linear, onde o coeficiente de Spearman é mais próximo de zero. Neste caso, imagina-se que a não-linearidade na relação entre  $e(t)$  e  $u(t)$  deve-se à forte não-linearidade da planta que será compensada pelas redes, ao passo que estas treinam. Com a compensação das redes, o erro da planta e a ação do controlador convencional tendem a reduzir e estarem mais estáveis, o que provavelmente levará a um aumento no módulo dos coeficientes de correlação.

Ao final da etapa IIC, os comportamentos esperados dos coeficientes de correlação ao longo do treinamento devem ser definidos. Na etapa AT, ao final de cada sessão de treinamento, o projetista deve confrontar o comportamento esperado dos coeficientes de correlação com o comportamento observado.

Quando o comportamento observado durante a etapa AT está de acordo com o definido na etapa IIC, infere-se que as redes utilizadas na estratégia FEL ou MNFEL obtiveram êxito no desempenho das suas funções. Caso contrário, as redes não foram capazes de executar efetivamente a função para a qual foram projetadas.

A Figura 13 mostra a metodologia de avaliação a ser utilizada para aferir se as redes estão desempenhando o seu papel com êxito durante o treinamento.

Figura 13 – Fluxograma das etapas necessárias à avaliação.



Fonte: Elaborada pelo autor.



## 5 Resultados e Discussão

Este capítulo expõe os resultados executados nos dois sistemas a controlar escolhidos – Forno de Pelotização e Serpentina de Refrigeração – com características diferentes para validar as métricas de avaliação propostas. Nas seções subsequentes, o funcionamento das plantas é detalhado, bem como discutem-se diferentes estratégias de avaliação: Coeficiente de Pearson; Coeficiente de Spearman; Coeficientes de Pearson e Spearman conjugados.

Os experimentos realizados utilizaram redes neurais agindo como reguladores de não-linearidade, ou seja, configuração NRL. Todas as redes neurais são do tipo *Multilayer Perceptron* (MLP) de uma camada escondida. O número de neurônios nas camadas de entrada e escondida, bem como o intervalo de geração de pesos sinápticos aleatórios são variados dependendo do experimento e da planta. O número de neurônios na camada de saída é padronizado para as técnicas FEL e MNFEL, sendo apenas um. A função de ativação utilizada nos neurônios da camada escondida é tangente hiperbólica, enquanto a função da camada de saída é linear.

O treinamento segue o algoritmo padrão para as estratégias FEL e MNFEL, sendo *backpropagation* onde a ação de controle da planta é utilizada como estímulo para o aprendizado. O critério de parada e de inserção de novas redes é o método habitual do desvio padrão e do erro quadrático médio. Cada experimento foi executado 30 vezes a fim de garantir-se a robustez dos resultados.

Diferentes configurações de redes foram escolhidas para cada uma das plantas, sempre baseando-se na performance do controle alcançada. As particularidades de cada uma das plantas experimentadas são expostas abaixo, bem como os resultados e efeitos observados nas execuções.

### 5.1 Ambiente de Simulação

Baseando-se em trabalhos anteriores relacionados a esta pesquisa, foram escolhidos dois sistemas a controlar distintos para efeito de validação das métricas propostas. A primeira planta é um modelo neural de um forno de um grupo queimador de uma usina de pelotização, enquanto a outra planta é um modelo não-linear de uma serpentina de refrigeração. Ambos sistemas a controlar são partes integrantes de grandes plantas industriais, tendo portanto relevância para a indústria.

### 5.1.1 Planta do Forno de Pelotização


A planta do forno de pelletização descreve o funcionamento de um forno integrante de um grupo queimador de uma usina de pelletização. Define-se pelletização como o processo de aglomeração de minério de ferro em esferas ou pelotas (MORAES; KAWATRA, 2011). Para que o fino do minério, ou *pellet-feed*, seja transformado em pelota é necessário, basicamente, a aplicação de compostos aglomerantes, o cozimento e a secagem.

No processo de cozimento das pelotas cruas, é necessário que estas sejam dispostas em fornos organizados em grupos queimadores, onde cada forno opera numa faixa de temperatura determinada previamente e controlada através de sistemas de controles. A planta aqui abordada é o modelo neural de um destes fornos, adquirido a partir do aprendizado das entradas e saídas – observados ao longo de turnos de funcionamento – por uma rede neural do tipo *Multilayer Perceptron* (MLP) de uma camada escondida (RIBEIRO et al., 2009). Utilizou-se uma modelagem neural devido a ausência de equações que descrevem o sistema real.

O forno é alimentado por combustível, mais precisamente óleo. A variável manipulada neste sistema é, portanto, a válvula de vazão que controla o despejo de óleo no sistema. A variável controlada do sistema é a temperatura interna do forno.

A Figura 14 mostra um comparativo entre os dados de leitura do forno e a generalização obtida pela rede MLP. Percebe-se pela figura que a configuração utilizada conseguiu aproximar suficientemente a planta. A configuração utilizada tem 10 neurônios na camada de entrada, 150 neurônios na única camada escondida e um neurônio na camada de saída. A rede neural recebe como *input* uma quantidade igual de leituras de temperatura do forno e grau de abertura da válvula de despejo, ambos em configuração *delay line*, ou seja, uma curta série histórica.

Figura 14 – Generalização da MLP utilizada para aquisição do modelo da planta da pelletização.



Fonte: (RIBEIRO et al., 2009).

A válvula de vazão é percentual, ou seja, varia no intervalo entre  $[0, 1]$  sendo 0 o corte total de combustível e 1 a vazão máxima para o forno. A temperatura do forno, entretanto, vai até  $1380\text{ }^\circ\text{C}$  – temperatura esta que causaria o desligamento automático de todos os equipamentos para evitar danos –, apresentando intervalo diferente da válvula de vazão. Os dados de entrada e saída do modelo são, portanto, normalizados para o intervalo  $[-0,5; 0,5]$

Esta planta foi aplicada com sucesso em trabalhos prévios que utilizaram controle inteligente por estratégia FEL e MNFEL (RIBEIRO et al., 2009; RIBEIRO; ALMEIDA NETO; OLIVEIRA, 2010), portanto mostrou-se importante para a validação desta pesquisa.

### 5.1.2 Planta da Serpentina de Refrigeração


Presente em inúmeras aplicações que variam desde grandes plantas industriais até simples sistemas de ar-condicionado domésticos, a planta da serpentina de refrigeração, ou *cooling coil* em inglês, é comumente parte integrante de um modelo maior de sistema de refrigeração (WANG, 1999).

O processo de resfriamento acontece quando o conteúdo, comumente água ou ar, move-se através da serpentina, entrando em contato com a superfície desta. A eficiência do resfriamento é dependente do tamanho da serpentina, fato este que justifica a grande extensão de seus tubos quando avalia-se a peça inteira.

Esta planta é altamente não-linear e, devido a grande possibilidade de configurações e funcionamento, possui inúmeras modelagens diferentes (THEERAKULPISUT; PRIPREM, 1998; JIN et al., 2006; NAZARI; GHAFARI, 2016).

Uma modelagem simples (WU; DEXTER, 2003) é obtida através da utilização de um modelo de Hammerstein (NARENDRA; GALLMAN, 1966), que trata a não-linearidade da planta como uma composição em série de não-linearidades estáticas anteriores ao sistema dinâmico linear. Representando-se um sistema através do diagrama de blocos, como visto na Figura 15, um modelo de Hammerstein tem um bloco não-linear estático sem memória ligado em série com um bloco linear.

Figura 15 – Diagrama de blocos de um modelo de Hammerstein.



Fonte: Elaborada pelo autor.

O sistema é representado pela Equação 5.1, enquanto a não-linearidade estática

$f(u(t))$  é disposta na Equação 5.2.

$$Y(s) = \mathcal{L}\{f(u(t))\}e^{-sT_d} \frac{1}{\tau s + 1} \quad (5.1)$$

$$f(u(t)) = \frac{1}{3,433} \ln(30u(t) + 1) \quad (5.2)$$

onde  $Y(s)$  é a transformada de Laplace da diferença de temperatura através da serpentina,  $u(t)$  é o sinal de controle determinado pela posição ou abertura da válvula,  $T_d$  é o tempo de atraso da planta e  $\tau$  é uma constante de tempo associada com a serpentina. A não-linearidade é dada em função do sinal de controle. Neste trabalho, os valores adotados para  $T_d$  e  $\tau$  são 10 s e 200 s, respectivamente.

É possível aproximar através de equação a diferença o modelo dado pelas Equações 5.1 e 5.2 (WU; DEXTER, 2003):

$$y[n] = (1 - e^{-\frac{T_d}{\tau}})f(u[n - 3]) + e^{-\frac{T_d}{\tau}}y[n - 1] \quad (5.3)$$

onde  $n$  indica a ordem discreta da observação.

Esta planta foi escolhida devido a sua natureza não-linear. Esta característica acrescenta dificuldade ao controle, pondo à prova o funcionamento da estratégia e a avaliação pela métrica proposta. Adicionalmente, há presença na literatura de trabalhos utilizando estratégias baseadas em FEL para a realização do controle da planta da serpentina de resfriamento (KADRI; DEXTER, 2009; KADRI, 2012).

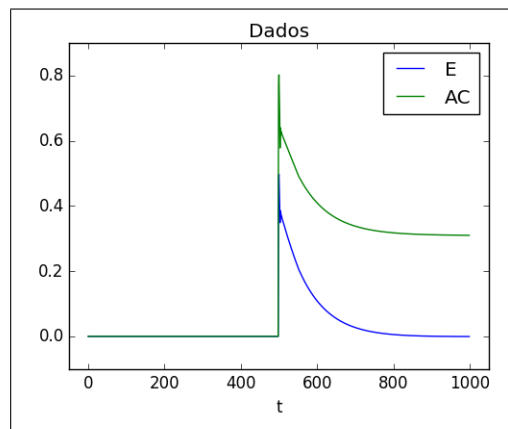
## 5.2 Avaliação utilizando Coeficiente de Pearson

Conduziu-se um experimento a fim de realizar-se uma avaliação apenas com o coeficiente de Pearson, seguindo o método proposto em (RIBEIRO, 2009). Esta discussão foi realizada com a finalidade de demonstrar a necessidade dos passos adotados na metodologia de avaliação.

Considere os dados de erro ( $E$ ) e da ação de controle ( $AC$ ) – como observados na Figura 16 – obtidos a partir de um controle convencional, utilizando somente PID, na planta do forno de pelletização. É sabido, pelo fato do controlador PID ser diretamente afetado pelo erro ao mesmo tempo que o erro é influenciado pelo controlador, que uma forte relação deve ser expressada entre as variáveis. Visualmente, pode-se observar que a planta da pelletização age de acordo com o esperado, onde as duas variáveis têm praticamente o mesmo comportamento durante toda simulação.

Todavia, o coeficiente de Pearson calculado para os dados da Figura 16 é de, aproximadamente, 0,674. Em variáveis sabidamente relacionadas e com coeficiente não

Figura 16 – Gráfico contendo os dados do erro e da ação de controle PID na planta de pelotização.




Fonte: Dados da pesquisa.

suficientemente expressivo, imagina-se que: (a) há presença significativa de *outliers* perturbando o coeficiente; ou (b) a relação entre o erro e a ação do controlador não pode ser expressada efetivamente por uma correlação linear; não mutuamente exclusivos.

Investigando-se a possibilidade da presença de *outliers* nos dados, observa-se novamente o gráfico na Figura 16. É notável que, apesar da referência degrau apenas ser ativada por volta do meio da simulação, todos os dados são utilizados para o cálculo do valor do coeficiente de Pearson. Com o auxílio do histograma presente na Figura 17, percebe-se o elevado número de ocorrências nulas de erro e ação de controle. Simultaneamente, as duas observações zeradas – nesta planta e com este padrão de referência – só serão possíveis em dois momentos: no período da simulação anterior ao degrau e no regime estacionário do controle.

Figura 17 – Histograma dos dados do erro e da ação de controle PID na planta de pelotização.



Fonte: Dados da pesquisa.


O período anterior ao degrau produz sinais que alimentam as redes neurais da

estratégia MNFEL. Estes sinais são importantes para a técnica por *ensinarem* as redes a se comportar a fim de não perturbar o controle quando este atingir o regime estacionário. Teoricamente, todas as redes se beneficiam deste aprendizado, pois podem treinar por mais de uma simulação. Entretanto, é apenas após o treinamento da primeira rede que o conjunto de redes irá aprender a compensar pelo distúrbio produzido pelas redes anteriores. A partir da segunda rede, o eventual distúrbio gerado pela primeira rede é compensado, mesmo que parcialmente, pelo controlador convencional. Assim, todas as redes podem aprender a compensar pelo distúrbio das anteriores, não perturbando o regime estacionário.

Entretanto, durante este período as redes estão compensando pela sua existência na técnica e não pela eventual não-linearidade da planta, influenciando tão somente no resultado do controle e não no desempenho do papel de regulador da não-linearidade, no caso específico da configuração NRL.

A Figura 18 contém dois gráficos. O primeiro, grifado por 1), mostra graficamente a relação entre o erro e a ação de controle do PID. O gráfico 2) mostra a relação entre as mesmas variáveis do mesmo experimento, entretanto excluindo-se as leituras referentes à A). A não consideração deste período faz com que o coeficiente de Pearson, que antes era 0,674 salte para 0,999. O novo valor calculado de Pearson é expressivo, sendo um forte indício de que a relação entre o erro da planta e o controlador PID após o degrau é muito próxima de ser linear.

Figura 18 – Comparação entre a relação do erro da planta e da ação de controle do PID com e sem a remoção das observações anteriores ao degrau do *setpoint*, nos gráficos 1) e 2), respectivamente. Os dados destacados por A) são correspondentes às observações no período anterior ao degrau.



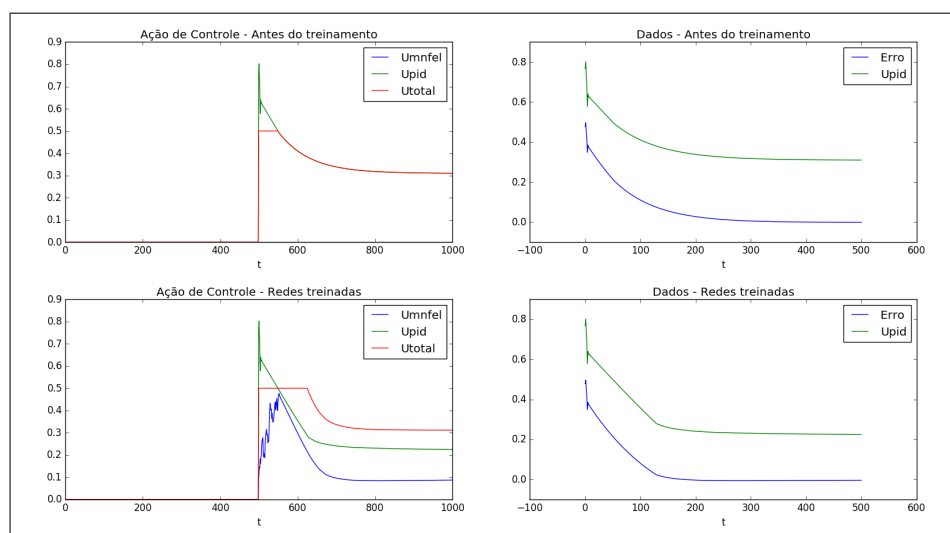
Fonte: Dados da pesquisa.

Uma vez que viu-se que a correlação de Pearson entre o erro e o controlador PID é expressiva, estuda-se a avaliação durante o treinamento das redes. Pela lógica inicial, se o coeficiente de Pearson aumentar, ao passo que as redes minimizam o PID e o erro cai, então estes estão ficando cada vez mais dependentes e as redes estão obtendo êxito em minimizar o controlador convencional e diminuir o erro do sistema a controlar.

Entretanto, deve-se discutir e avaliar o contexto de aplicação da técnica. Considere, por exemplo, um sistema a controlar com módulo do coeficiente de Pearson muito próximo de 1 e onde deseja-se aplicar a estratégia MNFEL para agir como regulador para a não-linearidade. Ao adicionar a primeira rede no processo, esta passa a participar do controle e isto irá impactar no PID devido a alteração no erro. O momento onde a rede neural tem maior estímulo ao aprendizado é na presença de grandes faixas de erro, como o período de subida do controle após o degrau. Nestes pontos, o PID ditará ações de maior magnitude e a rede é induzida a fazer o mesmo. Com o aprendizado, a técnica como um todo é que irá reger o erro da planta. A partir do momento em que as redes passam a compensar por pontos de não-linearidade da planta, o erro e a ação de controle do PID perdem expressividade na relação e espera-se uma diminuição no valor do módulo do coeficiente.

Através dos gráficos presentes na Figura 19 é possível acompanhar o efeito descrito anteriormente. Antes do treinamento das redes, o PID controla a planta sozinho e, visualmente, tem uma correlação elevada com o erro da planta. Após o treinamento, o PID, que passa a dividir o controle com as redes neurais, apresenta uma relação positiva na primeira parte do controle enquanto apresenta uma relação negativa na segunda parte. Esta não-linearidade na correlação provoca um valor menor do coeficiente de Pearson (0,994 neste contra 0,999 no experimento anterior ao treinamento), levando a crer que as redes desempenharam o seu papel de regulador para a não-linearidade ao mesmo tempo que diminuíram o erro do controle.

Figura 19 – Comparação entre as ações de controle e o erro antes e depois do treinamento das redes na estratégia MNFEL.




Fonte: Dados da pesquisa.

Em alternativa, se a relação inicial do erro da planta e as ações de controle não tem valor expressivo, tem-se um indicativo de que o controlador convencional não está operando em faixa linear com a planta. Neste caso, é esperado que a compensação pela

não-linearidade dada pelas redes possa levar o PID a operar com relação linear. A avaliação deve, portanto, não observar tão somente o efeito de crescimento ou decréscimo do coeficiente de correlação após as sessões de treinamento, mas determinar o efeito entre as ações de controle convencional e o erro da planta antes da aplicação da estratégia FEL ou MNFEL.

Apesar do efeito observado na Figura 19 e dos valores calculados para o coeficiente de Pearson, antes e depois do treinamento, estarem de acordo com a hipótese levantada, estranha-se o fato do valor da correlação ter decaído tão pouco enquanto percebe-se – visualizando-se o gráfico inferior direito da Figura 19 – que durante considerável parte do controle a ação do controlador tem direção de crescimento oposta ao erro. Graficamente analisa-se o histograma de ocorrências do erro e da ação de controle, com auxílio do gráfico com os dados ampliados do erro da planta ( $E$ ) e da ação de controle ( $AC$ ), presentes na Figura 20 a fim de verificar se de fato os dados têm direções opostas.

Figura 20 – Detalhes entre o erro da planta e a ação de controle do controlador convencional.



Fonte: Dados da pesquisa.


Nitidamente, os dados dispostos no gráfico da esquerda da Figura 20 apresentam direções de crescimento diferentes. Os histogramas, apesar de não indicarem a direção do crescimento, mostram que a maior parte dos dados do erro é negativa enquanto a ação de controle é positiva.

A Figura 21 traz gráficos da relação entre o erro da planta e o controlador PID para os mesmo dados da Figura 20. Fazendo-se uma comparação visual com o gráfico direito da Figura 18 – que contém os dados antes do treinamento das redes – percebe-se que a relação atual perdeu parte da linearidade que tinha antes mas que ainda está muito próxima da linearidade. Todavia, deve-se atentar para a ampliação do setor A) fornecida no gráfico direito. Neste ponto do gráfico de dispersão, os dados estão muito mais próximos, tendo uma grande concentração de pontos onde o sentido do crescimento é oposto aos demais, que estão mais espaçados e visíveis no gráfico da esquerda.

Devido ao grande número de dados com direção oposta, esperava-se que o coeficiente refletisse um resultado de magnitude inferior ou até mesmo negativo. O coeficiente de Pearson, por si, não foi capaz de transmitir a dimensão na alteração no modo que as duas



Figura 21 – Detalhes entre a relação do erro da planta e a ação de controle do controlador convencional. O gráfico da direita traz a ampliação dos dados destacados por A) no gráfico da esquerda.



Fonte: Dados da pesquisa.

variáveis se relacionam. Esta limitação está relacionada ao fato do coeficiente ser fortemente afetado pela magnitude dos dados, e não pelo número de repetições ou concentrações próximas; e ao fato dos dados não serem linearmente relacionados. Considerando estas características, tem-se violações que inviabilizam este tipo de avaliação tão somente com o coeficiente de Pearson.

### 5.3 Experimentos Forno de Pelotização

Os experimentos FEL e MNFEL executados na planta do forno de pelotização, ou simplesmente pelotização, utilizaram um controlador Proporcional-Integral-Derivativo (PID) como controlador convencional. O controlador tem as suas ações de controle normalizadas para o intervalo  $u \in [-0,5; 0,5]$  de modo a adequar-se à faixa de valores aceita pelo simulador da planta. Para permitir a reprodução de experimentos prévios, os ganhos do PID são os mesmos utilizados em experimentos de outros autores (RIBEIRO et al., 2009; RIBEIRO; ALMEIDA NETO; OLIVEIRA, 2010). Os valores dos ganhos proporcional, integral e derivativo são, respectivamente:

$$K_p = 2$$

$$K_i = 0,004$$

$$K_d = 1$$

Cada simulação da planta não considerou distúrbios e foi executada durante 1000 iterações, ou unidades discretas de tempo. Reforça-se que, durante o controle, é importante que a planta não atinja a temperatura máxima de 1380 °C visto que causaria o desligamento automático da planta real. Deste modo, o *overshoot* deve ser mínimo nestes experimentos, não podendo passar de 2%. O *rise time* também deve ser minimizado a fim


de minimizar o consumo de combustível que alimenta o forno. A referência utilizada em todos os experimentos foi do tipo degrau, fixada em  $r = 1350$ , sendo ativada em  $t = 500$ .

### 5.3.1 Identificação inicial da relação

Realiza-se primeiramente uma simulação de controle utilizando apenas o controlador convencional para identificação inicial da relação entre o PID e a planta em questão. Inicia-se pelo descarte dos dados anteriores ao degrau da referência e cálculo dos coeficientes de Pearson e Spearman com os erros ( $e$ ) da planta e ações de controle ( $u$ ) restantes.

Os gráficos e os correspondentes valores de CP e CS estão dispostos na Figura 22. Do lado esquerdo da figura, o método de Pearson indica que os dados têm uma relação linear quase que perfeita – devido à observação do gráfico e à leitura do valor 0,999 de CP –, não respeitando a linearidade apenas nos valores da extrema direita da ação de controle. O coeficiente de Spearman, no gráfico direito, confirma a relação monótona perfeita e positiva, ou seja com valor 1.

Figura 22 – Relação inicial do erro e ação de controle do PID na planta da pelletização.



Fonte: Dados da pesquisa.

Como a relação inicial aponta que a planta e o PID operam com linearidade entre  $e$  e  $u$ , na maior parte do tempo, é provável que, durante a compensação pela eventual não-linearidade da planta, as estratégias FEL e MNFEL alterem a ação de controle final, de modo que o PID passe a interagir com o erro da planta em menor grau de relação, monótona e linear. Espera-se, portanto, que ao longo dos experimentos, a correlação (CP e CS) torne-se menos expressiva.

Do ponto de vista do controle, calculam-se métricas usuais da teoria de controle. Estas métricas não fazem parte do processo de identificação inicial da relação, mas são importantes para a posterior comparação do controle com e sem as estratégias FEL e MNFEL. Na Tabela 1, encontram-se o *rise time* (RT), *percentage overshoot* (PO), *settling time* (ST) e erro quadrático médio (EQM).

Tabela 1 – Métricas clássicas de controle a partir do controle convencional com PID na planta do Forno de Pelotização.

| RT  | PO | ST  | EQM             |
|-----|----|-----|-----------------|
| 109 | 0% | 222 | $6,377.10^{-3}$ |

Fonte: Dados da pesquisa.

As medidas RT e ST, que envolvem tempo, tem o tempo de simulação da planta da Pelotização como unidade de medida. Todos os resultados de RT apresentados nesta seção foram calculados considerando-se o intervalo entre 10% e 90% da referência, após o degrau. A faixa utilizada para ST foi de  $\pm 2\%$  do valor final do controle, ou seja, a referência.

Como a relação inicial é feita no controle somente com PID, e este não tem ganhos alterados de uma execução para a outra, não é necessário refazer o processo de identificação para os demais experimentos com diferentes estratégias ou configurações.

### 5.3.2 Avaliação do treinamento

A avaliação do treinamento é realizada para cada experimento executado. Várias configurações de redes neurais foram escolhidas para esta etapa, todas elas baseadas em *trial and error*. A Tabela 2 a seguir dispõe os números de neurônios de entrada  $n_i$  e neurônios da camada escondida  $n_h$ ; o coeficiente de aprendizado  $\mu_{ih}$  entre as camadas de entrada e escondida e  $\mu_{ho}$  entre as camadas escondida e de saída para cada rede neural (RNA) utilizada. O intervalo de geração de pesos sinápticos aleatórios é dependente do *ensemble* de redes neurais utilizado.

Tabela 2 – Detalhes das redes neurais utilizadas nos experimentos da planta Pelotização. Cada RNA tem números de neurônios na camada de entrada ( $n_i$ ) e camada escondida ( $n_h$ ), além de coeficientes de aprendizado entre as camadas de entrada e escondida ( $\mu_{ih}$ ) e entre as camadas escondida e de saída ( $\mu_{ho}$ ).

| RNA      | $n_i$ | $n_h$ | $\mu_{ih}$  | $\mu_{ho}$  |
|----------|-------|-------|-------------|-------------|
| <b>A</b> | 55    | 15    | $1.10^{-5}$ | $5.10^{-5}$ |
| <b>B</b> | 40    | 15    | $1.10^{-6}$ | $5.10^{-6}$ |
| <b>C</b> | 20    | 15    | $1.10^{-5}$ | $5.10^{-5}$ |


Fonte: Elaborada pelo autor.

Os *ensembles*, no caso da estratégia MNFEL, são formados a partir da combinação de diferentes RNAs apresentadas na Tabela 2. Para a estratégia FEL, utilizou-se as mesmas RNAs mas com intervalo de geração de pesos sinápticos constante, definido entre  $[-0, 4; 0, 4]$ .

### 5.3.2.1 FEL com critério de parada pelo desvio padrão do erro

O controle alcançado a partir da utilização da estratégia FEL com critério de parada pelo desvio padrão do erro da planta, aqui chamado de FEL DESVPAD é exemplificado através da Figura 23. Nela constam os gráficos do controle FEL utilizando, respectivamente, as redes A, B e C. Estas redes foram escolhidas por apresentarem os melhores resultados obtidos dentre as demais.


Figura 23 – Controle FEL DESVPAD na planta da Pelotização utilizando diferentes RNAs.



Fonte: Dados da pesquisa.

Acompanha-se os sinais de controle, emitidos pelas diferentes configurações da estratégia FEL com critério de inserção e parada pelo desvio padrão do erro da planta, a partir do gráfico apresentado na Figura 24. A ação do controlador PID é denotada por  $u_{cfc}$  enquanto a ação da rede neural é  $u_n$ . A combinação das ações é denotada por  $u$ . Através dos gráficos visualiza-se que as redes participaram do controle fornecendo sinais de compensação durante todos os instantes  $t$  ao longo da simulação.

Figura 24 – Sinais de controle FEL DESVPAD na planta de Pelotização.  $u_{cfc}$  é a ação de controle do PID,  $u_n$  a ação de controle da rede neural e  $u$  o combinado das ações.



Fonte: Dados da pesquisa.

A Tabela 3 sumariza os experimentos, apresentando a média, desvio padrão, mediana, mínimo e máximo de indicadores importantes da teoria do controle.

A partir dos gráficos presentes na Figura 23, e dos dados apresentados nas Tabelas 1 (métricas clássicas de controle para o experimento contendo apenas PID) e 3 é possível notar que o FEL apresentou desempenho superior ao PID, do ponto das métricas relacionadas

Tabela 3 – Dados de métricas de controle para os experimentos FEL DESVPAD na planta da Pelotização.


| RNA | Ind. | Média           | Mediana         | Desv. Pad.      | Mínimo          | Máximo          |
|-----|------|-----------------|-----------------|-----------------|-----------------|-----------------|
| A   | RT   | 92,366          | 92              | 1,033           | 92              | 97              |
|     | PO   | 0%              | 0%              | 0,135%          | 0%              | 0,348%          |
|     | ST   | 176,133         | 176             | 2,674           | 171             | 184             |
|     | EQM  | $6,320.10^{-3}$ | $6,313.10^{-3}$ | $2,344.10^{-5}$ | $6,297.10^{-3}$ | $6,409.10^{-3}$ |
| B   | RT   | 94,900          | 95              | 1,516           | 92              | 97              |
|     | PO   | 0,048%          | 0,061%          | 0,079%          | 0%              | 0,187%          |
|     | ST   | 187,166         | 187,500         | 2,889           | 182             | 192             |
|     | EQM  | $6,383.10^{-3}$ | $6,381.10^{-3}$ | $2,547.10^{-5}$ | $6,336.10^{-3}$ | $6,431.10^{-3}$ |
| C   | RT   | 95,800          | 96              | 1,808           | 93              | 101             |
|     | PO   | 0,273%          | 0,295%          | 0,088%          | 0,047%          | 0,413%          |
|     | ST   | 183,166         | 183             | 2,547           | 180             | 192             |
|     | EQM  | $6,390.10^{-3}$ | $6,388.10^{-3}$ | $3,214.10^{-5}$ | $6,344.10^{-3}$ | $6,499.10^{-3}$ |

Fonte: Dados da pesquisa.

ao tempo. Na redes A, a estratégia foi capaz de melhorar o controle convencional em várias execuções e apresentou um tempo de subida inferior, sem que houvesse *overshoot* excessivo, em todas execuções. As redes B e C, entretanto, tiveram dificuldades para fornecer um RT menor ao mesmo tempo que minimizavam o erro da planta. É evidente que, devido ao fato do sistema a controlar ser isolado de distúrbios externos, a melhoria no controle se deu pela aplicação da estratégia FEL.

Verifica-se, portanto, o comportamento dos coeficientes de Pearson e Spearman ao longo do treinamento. Através dos gráficos na Figura 25 é possível acompanhar a evolução dos coeficientes durante o período de treinamento.

Figura 25 – Evolução dos coeficientes de correlação de Pearson e Spearman ao longo do treinamento da estratégia FEL DESVPAD na planta Pelotização.



Fonte: Dados da pesquisa.

Lendo-se os gráficos da Figura 25 percebe-se que houve queda, ainda que discreta, do coeficiente de Spearman, enquanto o coeficiente de Pearson permanece quase que estático com o passar das sessões de treinamento. Este comportamento indica que houve efetiva compensação de intensidade leve, corroborado pelos resultados da Tabela 3.

É necessário, entretanto, atestar se o comportamento visualizado nos gráficos da Figura 25 descreve o efeito do experimento. Visto que cada execução do experimento não terá o mesmo número de sessões de treinamento, resolveu-se dividir a execução em quatro segmentos, ou quartos, ordenados de acordo com a ordem cronológica do treinamento. Deste modo, sumarizam-se as observações dos coeficientes de Spearman e Pearson nas Tabelas 4 e 5, respectivamente.

Tabela 4 – Dados sumarizados das observações do coeficiente de Spearman no controle FEL DESVPAD do Forno de Pelotização.

| RNA | Q | Média | Mediana | Desv. Pad.            | Mínimo | Máximo |
|-----|---|-------|---------|-----------------------|--------|--------|
| A   | 1 | 0,991 | 0,995   | $9,395 \cdot 10^{-3}$ | 0,951  | 0,999  |
|     | 2 | 0,984 | 0,999   | $2,744 \cdot 10^{-2}$ | 0,863  | 0,999  |
|     | 3 | 0,950 | 0,985   | $6,893 \cdot 10^{-2}$ | 0,727  | 0,999  |
|     | 4 | 0,906 | 0,935   | $9,866 \cdot 10^{-2}$ | 0,641  | 0,999  |
| B   | 1 | 0,990 | 0,989   | $5,805 \cdot 10^{-3}$ | 0,971  | 0,999  |
|     | 2 | 0,989 | 0,991   | $1,190 \cdot 10^{-2}$ | 0,941  | 0,999  |
|     | 3 | 0,977 | 0,983   | $2,283 \cdot 10^{-2}$ | 0,898  | 0,999  |
|     | 4 | 0,951 | 0,951   | $3,593 \cdot 10^{-2}$ | 0,856  | 0,999  |
| C   | 1 | 0,971 | 0,973   | $1,132 \cdot 10^{-2}$ | 0,935  | 0,998  |
|     | 2 | 0,938 | 0,936   | $2,736 \cdot 10^{-2}$ | 0,881  | 0,999  |
|     | 3 | 0,889 | 0,882   | $3,697 \cdot 10^{-2}$ | 0,836  | 0,999  |
|     | 4 | 0,840 | 0,831   | $3,577 \cdot 10^{-2}$ | 0,798  | 0,989  |

Fonte: Dados da pesquisa.

Tabela 5 – Dados sumarizados das observações do coeficiente de Pearson no controle FEL DESVPAD do Forno de Pelotização.

| RNA | Q | Média  | Mediana | Desv. Pad.            | Mínimo | Máximo |
|-----|---|--------|---------|-----------------------|--------|--------|
| A   | 1 | 0,9989 | 0,9989  | $8,549 \cdot 10^{-5}$ | 0,9987 | 0,9990 |
|     | 2 | 0,9990 | 0,9990  | $1,336 \cdot 10^{-4}$ | 0,9985 | 0,9991 |
|     | 3 | 0,9988 | 0,9989  | $2,158 \cdot 10^{-4}$ | 0,9982 | 0,9990 |
|     | 4 | 0,9985 | 0,9986  | $2,477 \cdot 10^{-4}$ | 0,9977 | 0,9989 |
| B   | 1 | 0,9989 | 0,9989  | $7,100 \cdot 10^{-5}$ | 0,9987 | 0,9990 |
|     | 2 | 0,9990 | 0,9990  | $4,790 \cdot 10^{-5}$ | 0,9988 | 0,9991 |
|     | 3 | 0,9990 | 0,9990  | $6,260 \cdot 10^{-5}$ | 0,9987 | 0,9991 |
|     | 4 | 0,9988 | 0,9989  | $1,038 \cdot 10^{-4}$ | 0,9984 | 0,9990 |
| C   | 1 | 0,9988 | 0,9988  | $6,189 \cdot 10^{-5}$ | 0,9986 | 0,9990 |
|     | 2 | 0,9988 | 0,9988  | $1,284 \cdot 10^{-4}$ | 0,9984 | 0,9991 |
|     | 3 | 0,9986 | 0,9986  | $2,171 \cdot 10^{-4}$ | 0,9979 | 0,9990 |
|     | 4 | 0,9981 | 0,9981  | $3,145 \cdot 10^{-4}$ | 0,9974 | 0,9989 |

Fonte: Dados da pesquisa.

A partir da análise dos dados presentes nas Tabelas 4 (dados do coeficiente de Spearman) e 5 (dados do coeficiente de Pearson), é possível perceber que há um padrão de queda nos coeficientes de correlação durante o treinamento. Esta observação corresponde

com a expectativa traçada durante a fase de identificação inicial da relação. Como o controlador e a planta já operam produzindo uma relação fortemente monótona – entre os dados do erro quadrático e das ações de controle do PID – quase que linear, era esperado que a rede da estratégia FEL fornecesse compensação pela não-linearidade de modo que a relação entre erro da planta e ação do PID tornaria-se mais não-linear.

### 5.3.2.2 MNFEL com critério de inserção e parada pelo desvio padrão do erro

Os experimentos aqui destacados utilizaram combinações de redes neurais apresentadas nas Tabela 2, formando diferentes configurações. As configurações selecionadas – devido a melhor performance, no geral – com as respectivas redes e o valor de  $\gamma$  utilizado para estabelecer o intervalo de geração de pesos sinápticos aleatórios, do tipo  $[-\gamma, \gamma]$ , estão dispostas na Tabela 6. As redes que compõem as configurações aparecem na Tabela 6 na mesma ordem de inserção na estratégia. Devido ao critério de parada e inserção adotado para estes experimentos, e para facilitar a leitura e entendimento, nomeia-se a técnica empregada de MNFEL DESVPAD.


Tabela 6 – Configurações MNFEL utilizadas no experimento da Pelotização.

| Configuração   | Tipo   | Redes    | $\gamma$ |
|----------------|--------|----------|----------|
| <b>CONFIG1</b> | MNFEL3 | A, B e C | 0,4      |
| <b>CONFIG2</b> | MNFEL2 | A e C    | 0,4      |
| <b>CONFIG3</b> | MNFEL2 | C e A    | 0,4      |

Fonte: Elaborada pelo autor.

A partir dos gráficos presentes na Figura 26, pode-se acompanhar o controle aplicado pela estratégia MNFEL na planta da pelotização. É evidente que houve uma melhoria alcançada a partir da implementação do MNFEL ante ao controle com somente PID. Expõem-se as métricas de controle para este experimento na Tabela 7.


Figura 26 – Controle MNFEL DESVPAD na planta da Pelotização utilizando diferentes configurações.



Fonte: Dados da pesquisa.

Na Figura 27 dispõem-se os gráficos do sinal de controle para as configurações utilizadas nestes experimentos. É possível acompanhar como as redes compensaram pela eventual não-linearidade da planta, logo após o degrau.

Figura 27 – Sinais de controle MNFEL DESVPAD na planta de Pelotização.  $u_{cfc}$  é a ação de controle do PID,  $u_n$  a ação de controle das redes neurais e  $u$  o combinado das ações.



Fonte: Dados da pesquisa.

Fazendo-se a leitura da Tabela 7, percebe-se que neste experimento as configurações MNFEL foram superiores à todas as execuções FEL com o mesmo critério de parada – vide Tabela 3, que expõe os números do controle FEL DESVPAD – no que diz respeito ao tempo de subida (RT), tempo de acomodação (ST) e ao EQM. Entretanto, a *percentage overshoot* apresentou números superiores ao FEL e PID, pela Tabela 1 de métricas clássicas do PID. Este resultado é esperado visto que é comum observar-se aumento em PO quando há diminuição em RT. Ressalta-se, no entanto, que o PO observado ainda é muito baixo e não é aproximado do valor máximo permitido pela simulação (1380 C° ou aproximadamente 2% de PO).

Tabela 7 – Dados de métricas de controle para os experimentos MNFEL DESVPAD na planta da Pelotização.

| Conf. | Ind. | Média                 | Mediana               | Desv. Pad.            | Mínimo                | Máximo                |
|-------|------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|
| 1     | RT   | 92,2                  | 92                    | 0,484                 | 92                    | 94                    |
|       | PO   | 0,046%                | 0,034%                | 0,140%                | 0%                    | 0,430%                |
|       | ST   | 171,833               | 171,500               | 2,450                 | 167                   | 178                   |
|       | EQM  | $6,305 \cdot 10^{-3}$ | $6,298 \cdot 10^{-3}$ | $1,751 \cdot 10^{-5}$ | $6,277 \cdot 10^{-3}$ | $6,344 \cdot 10^{-3}$ |
| 2     | RT   | 92,233                | 92                    | 0,678                 | 92                    | 95                    |
|       | PO   | 0,069%                | 0,048%                | 0,110%                | 0%                    | 0,449%                |
|       | ST   | 172,433               | 172                   | 3,202                 | 166                   | 181                   |
|       | EQM  | $6,309 \cdot 10^{-3}$ | $6,302 \cdot 10^{-3}$ | $1,989 \cdot 10^{-5}$ | $6,279 \cdot 10^{-3}$ | $6,362 \cdot 10^{-3}$ |
| 3     | RT   | 92,400                | 92                    | 0,855                 | 92                    | 95                    |
|       | PO   | 0,333%                | 0,339%                | 0,081%                | 0,179%                | 0,488%                |
|       | ST   | 169,033               | 168                   | 4,679                 | 163                   | 180                   |
|       | EQM  | $6,311 \cdot 10^{-3}$ | $6,307 \cdot 10^{-3}$ | $2,347 \cdot 10^{-5}$ | $6,281 \cdot 10^{-3}$ | $6,368 \cdot 10^{-3}$ |


Fonte: Dados da pesquisa.

A Figura 28 dispõe graficamente o efeito dos coeficientes de correlação ao longo do treinamento da estratégia para uma das execuções deste experimento de cada configuração. Percebe-se claramente o padrão de queda dos coeficientes, assim como observado nos experimentos utilizando FEL. Recorre-se às Tabelas 8 e 9 para verificar se este efeito é



também observado nas demais execuções do experimento.

Figura 28 – Evolução dos coeficientes de correlação de Pearson e Spearman ao longo do treinamento da estratégia MNFEL DESVPAD na planta Pelotização.



Fonte: Dados da pesquisa.

Através dos dados presentes nas Tabelas 8 (observações do coeficiente de Spearman) vê-se que o mesmo comportamento observado nos experimentos FEL com critério de inserção e parada pelo desvio padrão foi alcançado nestes experimentos MNFEL. Nota-se que CONFIG3 foi a que apresentou maior queda, embora esta não tenha a melhor performance de controle. Os coeficientes apontam a perda de parte da relação entre o erro e ação do controlador convencional, o que não envolve diretamente a qualidade do controle aplicado.

Tabela 8 – Dados sumarizados das observações do coeficiente de Spearman no controle MNFEL DESVPAD do Forno de Pelotização.

| Conf.    | Q | Média | Mediana | Desv. Pad.      | Mínimo | Máximo |
|----------|---|-------|---------|-----------------|--------|--------|
| <b>1</b> | 1 | 0,982 | 0,993   | $3,388.10^{-2}$ | 0,818  | 0,999  |
|          | 2 | 0,963 | 0,997   | $6,291.10^{-2}$ | 0,784  | 0,999  |
|          | 3 | 0,929 | 0,960   | $8,297.10^{-2}$ | 0,649  | 0,999  |
|          | 4 | 0,896 | 0,907   | $9,333.10^{-2}$ | 0,611  | 0,999  |
| <b>2</b> | 1 | 0,990 | 0,992   | $1,049.10^{-2}$ | 0,935  | 0,999  |
|          | 2 | 0,988 | 0,999   | $2,498.10^{-2}$ | 0,862  | 0,999  |
|          | 3 | 0,966 | 0,987   | $4,572.10^{-2}$ | 0,803  | 0,999  |
|          | 4 | 0,924 | 0,938   | $6,456.10^{-2}$ | 0,775  | 0,999  |
| <b>3</b> | 1 | 0,964 | 0,967   | $1,737.10^{-2}$ | 0,876  | 0,986  |
|          | 2 | 0,909 | 0,911   | $3,664.10^{-2}$ | 0,794  | 0,985  |
|          | 3 | 0,845 | 0,839   | $3,747.10^{-2}$ | 0,782  | 0,962  |
|          | 4 | 0,800 | 0,795   | $2,609.10^{-2}$ | 0,760  | 0,901  |

Fonte: Dados da pesquisa.

A Tabela 9, que expõe os dados para o Coeficiente de Pearson, no entanto, não demonstra tão evidentemente o comportamento esperado, que foi observado no Coeficiente de Spearman.

Tabela 9 – Dados sumarizados das observações do coeficiente de Pearson no controle MNFEL DESVPAD do Forno de Pelotização.

| Conf.    | Q | Média  | Mediana | Desv. Pad.      | Mínimo | Máximo |
|----------|---|--------|---------|-----------------|--------|--------|
| <b>1</b> | 1 | 0,9989 | 0,9989  | $1,721.10^{-4}$ | 0,9979 | 0,9991 |
|          | 2 | 0,9988 | 0,9990  | $4,164.10^{-4}$ | 0,9976 | 0,9991 |
|          | 3 | 0,9986 | 0,9987  | $3,988.10^{-4}$ | 0,9975 | 0,9990 |
|          | 4 | 0,9983 | 0,9984  | $3,650.10^{-4}$ | 0,9970 | 0,9988 |
| <b>2</b> | 1 | 0,9989 | 0,9989  | $9,407.10^{-5}$ | 0,9987 | 0,9991 |
|          | 2 | 0,9990 | 0,9990  | $1,035.10^{-4}$ | 0,9984 | 0,9991 |
|          | 3 | 0,9988 | 0,9988  | $2,167.10^{-4}$ | 0,9977 | 0,9990 |
|          | 4 | 0,9984 | 0,9985  | $3,225.10^{-4}$ | 0,9970 | 0,9989 |
| <b>3</b> | 1 | 0,9988 | 0,9988  | $7,424.10^{-5}$ | 0,9983 | 0,9990 |
|          | 2 | 0,9987 | 0,9987  | $2,456.10^{-4}$ | 0,9972 | 0,9990 |
|          | 3 | 0,9982 | 0,9983  | $3,814.10^{-4}$ | 0,9973 | 0,9990 |
|          | 4 | 0,9976 | 0,9976  | $4,315.10^{-4}$ | 0,9967 | 0,9987 |


Fonte: Dados da pesquisa.

### 5.3.2.3 FEL com critério de parada pelo erro quadrático médio

Assim como nos experimentos anteriores, as redes utilizadas nesta experimentação estão incluídas na Tabela 2. As redes A, B e C foram escolhidas, mais uma vez, devido ao bom controle obtido e por permitir uma comparação mais justa dos resultados da métrica proposta e das métricas clássicas de controle. A estratégia, aliada ao critério do erro quadrático médio, foi nomeada FEL EQM.

Os gráficos da Figura 29 – resultados selecionados aleatoriamente para exposição – mostram o controle obtido controlando-se a planta pela estratégia FEL, que teve nestes experimentos o critério de parada pelo erro quadrático médio, com cada uma das três redes escolhidas. Observando-se os gráficos, vê-se que o controle é muito similar às demais redes, sendo superior ao controle somente com PID (dados dispostos na Tabela 1).

Figura 29 – Controle FEL na planta Pelotização utilizando critério de parada pelo erro quadrático médio.




Fonte: Dados da pesquisa.

Observa-se, através dos gráficos da Figura 30, os sinais de controle emitidos pela estratégia. Percebe-se com clareza que cada uma das redes neurais forneceu sinais de

controle com maior intensidade durante a fase inicial do controle, logo após o degrau.

Figura 30 – Sinais de controle FEL EQM na planta de Pelotização.  $u_{cfc}$  é a ação de controle do PID,  $u_n$  a ação de controle da rede neural e  $u$  o combinado das ações.



Fonte: Dados da pesquisa.

Observa-se, através dos dados presentes na Tabela 10, que o controle obtido nestes experimentos foi superior aos equivalentes utilizando-se FEL e MNFEL com método de parada ou inserção de redes pelo desvio padrão (a partir dos dados das Tabelas 3 e 7, respectivamente). Percebe-se, entretanto, que PO é maior, chegando a 1,698% no pior resultado de experimento da rede C.


Tabela 10 – Dados de métricas de controle para os experimentos FEL EQM na planta da Pelotização.

| RNA | Ind. | Média           | Mediana         | Desv. Pad.      | Mínimo          | Máximo          |
|-----|------|-----------------|-----------------|-----------------|-----------------|-----------------|
| A   | RT   | 92              | 92              | 0               | 92              | 92              |
|     | PO   | 0,582%          | 0,579%          | 0,245%          | 0,131%          | 1,09%           |
|     | ST   | 133,100         | 132             | 4,261           | 129             | 143             |
|     | EQM  | $6,227.10^{-3}$ | $6,224.10^{-3}$ | $1,039.10^{-5}$ | $6,214.10^{-3}$ | $6,255.10^{-3}$ |
| B   | RT   | 92              | 92              | 0               | 92              | 92              |
|     | PO   | 0,838%          | 0,840%          | 0,256%          | 0,358%          | 1,453%          |
|     | ST   | 139,533         | 140,500         | 5,137           | 129             | 149             |
|     | EQM  | $6,242.10^{-3}$ | $6,241.10^{-3}$ | $1,702.10^{-5}$ | $6,218.10^{-3}$ | $6,292.10^{-3}$ |
| C   | RT   | 92              | 92              | 0               | 92              | 92              |
|     | PO   | 1,297%          | 1,290%          | 0,188%          | 0,910%          | 1,698%          |
|     | ST   | 146,266         | 146             | 2,391           | 141             | 150             |
|     | EQM  | $6,275.10^{-3}$ | $6,273.10^{-3}$ | $1,774.10^{-5}$ | $6,244.10^{-3}$ | $6,315.10^{-3}$ |

Fonte: Dados da pesquisa.

A evolução dos coeficientes de correlação, presente na Figura 31, apresenta efeito decrescente pelo menos a partir do último quarto do treinamento. O efeito está de acordo com o expectativa esboçada na fase de identificação inicial da relação. As Tabelas 11 e 12 resumem os dados de correlação – Sperman e Pearson, respectivamente – de todas as execuções deste experimento, de modo que se possa verificar o estado da correlação em diferentes momento do treinamento.

Figura 31 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia FEL EQM na planta Pelotização.



Fonte: Dados da pesquisa.

Pelos dados da Tabela 11, nota-se a clara queda do coeficiente de Spearman ao longo do treinamento. Faz-se uma comparação com os resultados obtidos pelos experimentos anteriores. Os resultados deste experimento apresentaram, no geral, coeficientes de Spearman de menor magnitude, indicando que a diminuição ao longo do treinamento foi superior aos experimentos FEL e MNFEL com método do desvio padrão.

Tabela 11 – Dados sumarizados das observações do coeficiente de Spearman no controle FEL EQM do Forno de Pelotização.

| RNA | Q | Média | Mediana | Desv. Pad.            | Mínimo | Máximo |
|-----|---|-------|---------|-----------------------|--------|--------|
| A   | 1 | 0,979 | 0,999   | $4,493 \cdot 10^{-2}$ | 0,716  | 0,999  |
|     | 2 | 0,891 | 0,923   | $1,139 \cdot 10^{-1}$ | 0,565  | 0,999  |
|     | 3 | 0,787 | 0,784   | $8,375 \cdot 10^{-2}$ | 0,561  | 0,999  |
|     | 4 | 0,742 | 0,736   | $4,366 \cdot 10^{-2}$ | 0,615  | 0,999  |
| B   | 1 | 0,981 | 0,992   | $2,725 \cdot 10^{-2}$ | 0,857  | 0,999  |
|     | 2 | 0,894 | 0,880   | $6,393 \cdot 10^{-2}$ | 0,761  | 0,999  |
|     | 3 | 0,804 | 0,785   | $6,585 \cdot 10^{-2}$ | 0,707  | 0,999  |
|     | 4 | 0,730 | 0,727   | $2,609 \cdot 10^{-2}$ | 0,675  | 0,833  |
| C   | 1 | 0,934 | 0,942   | $3,748 \cdot 10^{-2}$ | 0,833  | 0,990  |
|     | 2 | 0,812 | 0,808   | $3,653 \cdot 10^{-2}$ | 0,744  | 0,947  |
|     | 3 | 0,733 | 0,731   | $1,863 \cdot 10^{-2}$ | 0,695  | 0,789  |
|     | 4 | 0,690 | 0,689   | $1,140 \cdot 10^{-2}$ | 0,666  | 0,722  |

Fonte: Dados da pesquisa.

Os dados para o Coeficiente de Pearson, presentes na Tabela 12, obtiveram queda não substancial. Não sendo, portanto, muito adequados para a análise.

Tal efeito era esperado, visto que os experimentos pelo método do desvio padrão tiveram número menor de sessões de treinamento, enquanto os experimentos pelo método do EQM treinam até que a aproximação da rede leve à um mínimo local.

Tabela 12 – Dados sumarizados das observações do coeficiente de Pearson no controle FEL EQM do Forno de Pelotização.


| RNA | Q | Média  | Mediana | Desv. Pad.      | Mínimo | Máximo |
|-----|---|--------|---------|-----------------|--------|--------|
| A   | 1 | 0,9989 | 0,9990  | $1,394.10^{-4}$ | 0,9982 | 0,9991 |
|     | 2 | 0,9984 | 0,9984  | $3,280.10^{-4}$ | 0,9974 | 0,9990 |
|     | 3 | 0,9971 | 0,9972  | $5,616.10^{-4}$ | 0,9950 | 0,9981 |
|     | 4 | 0,9953 | 0,9955  | $9,892.10^{-4}$ | 0,9920 | 0,9969 |
| B   | 1 | 0,9989 | 0,9990  | $1,113.10^{-4}$ | 0,9983 | 0,9991 |
|     | 2 | 0,9984 | 0,9985  | $4,148.10^{-4}$ | 0,9964 | 0,9990 |
|     | 3 | 0,9969 | 0,9971  | $8,671.10^{-4}$ | 0,9934 | 0,9983 |
|     | 4 | 0,9948 | 0,9950  | $1,385.10^{-3}$ | 0,9896 | 0,9970 |
| C   | 1 | 0,9987 | 0,9988  | $1,609.10^{-4}$ | 0,9979 | 0,9990 |
|     | 2 | 0,9977 | 0,9978  | $6,269.10^{-4}$ | 0,9955 | 0,9988 |
|     | 3 | 0,9954 | 0,9955  | $1,055.10^{-3}$ | 0,9920 | 0,9975 |
|     | 4 | 0,9922 | 0,9923  | $1,447.10^{-3}$ | 0,9878 | 0,9954 |

Fonte: Dados da pesquisa.

#### 5.3.2.4 MNFEL com critério de inserção e parada pelo erro quadrático médio

Mantendo o mesmo critério utilizado para a escolha de redes para os experimentos FEL com método EQM, mantêm-se para os experimentos MNFEL EQM as mesmas configurações expostas na Tabela 6. Através dos gráficos presentes na Figura 32 pode-se acompanhar exemplos, selecionados aleatoriamente dentre as execuções deste experimento, de controles obtidos a partir da aplicação da estratégia MNFEL com critério de inserção e parada pelo erro quadrático médio.

Figura 32 – Controle MNFEL na planta Pelotização utilizando critério de parada pelo erro quadrático médio.




Fonte: Dados da pesquisa.

Nos experimentos selecionados aleatoriamente como exemplos nos gráficos da Figura 32, vê-se que configuração CONFIG2 apresentou controle muito próximo do ideal. Ao mesmo tempo, CONFIG1 apresentou controle similar mas com PO superior. Todavia, o resultado observado de CONFIG3 parece ter *overshoot* suficiente para não ser adequado para esta planta.

De posse dos gráficos dispostos na Figura 33, analisa-se as ações de controle tomadas pela estratégia. É evidente que as redes neurais compensaram na ação de controle  $u$  em todas as configurações. CONFIG3, por sua vez, apresenta um padrão diferente dos demais, onde o sinal imediatamente após o degrau tem magnitude substancialmente superior aos demais instantes  $t$  da simulação.

Figura 33 – Sinais de controle MNFEL EQM na planta de Pelotização.  $u_{cfc}$  é a ação de controle do PID,  $u_n$  a ação de controle das redes neurais e  $u$  o combinado das ações.



Fonte: Dados da pesquisa.

Através dos dados presentes na Tabela 13, observa-se que CONFIG3 não apresentou PO superior à 2%, entretanto o valor máximo de 1,828% é considerado alto se comparado aos demais resultados alcançados pelos demais experimentos. Os resultados obtidos pela estratégia MNFEL são positivos e apresentaram resultados superiores aos experimentos FEL equivalentes (presentes na Tabela 10), com exceção da estratégia FEL com rede A.

Tabela 13 – Dados de métricas de controle para os experimentos MNFEL EQM com critério de parada pelo erro quadrático médio na planta da Pelotização.


| Conf. | Ind. | Média           | Mediana         | Desv. Pad.      | Mínimo          | Máximo          |
|-------|------|-----------------|-----------------|-----------------|-----------------|-----------------|
| 1     | RT   | 92              | 92              | 0               | 92              | 92              |
|       | PO   | 0,850%          | 0,820%          | 0,233%          | 0,316%          | 1,312%          |
|       | ST   | 134,533         | 134             | 4,057           | 129             | 144             |
|       | EQM  | $6,236.10^{-3}$ | $6,233.10^{-3}$ | $1,219.10^{-5}$ | $6,216.10^{-3}$ | $6,269.10^{-3}$ |
| 2     | RT   | 92              | 92              | 0               | 92              | 92              |
|       | PO   | 0,695%          | 0,667%          | 0,243%          | 0,186%          | 1,426%          |
|       | ST   | 133,100         | 132             | 4,285           | 129             | 145             |
|       | EQM  | $6,230.10^{-3}$ | $6,227.10^{-3}$ | $1,238.10^{-5}$ | $6,214.10^{-3}$ | $6,277.10^{-3}$ |
| 3     | RT   | 92              | 92              | 0               | 92              | 92              |
|       | PO   | 1,387%          | 1,337%          | 0,254%          | 0,970%          | 1,828%          |
|       | ST   | 138,933         | 139,500         | 3,300           | 132             | 145             |
|       | EQM  | $6,266.10^{-3}$ | $6,259.10^{-3}$ | $1,808.10^{-5}$ | $6,239.10^{-3}$ | $6,303.10^{-3}$ |

Fonte: Dados da pesquisa.

O comportamento dos coeficientes de correlação pode ser observado através da Figura 34. É possível observar a tendência de queda do coeficiente de Spearman, enquanto

o de Pearson parece ter variação mais sutil. O gráfico que representa CONFIG2 apresenta padrão de queda acentuado logo após um breve período de crescimento da correlação.

Figura 34 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia MNFEL EQM na planta Pelotização.



Fonte: Dados da pesquisa.

As Tabelas 14 (dados do coeficiente de Spearman) e 15 (dados do Coeficiente de Pearson) apresentam os resultados da avaliação dos coeficientes de correlação sumarizados. Percebe-se que o efeito da correlação observado nos demais experimentos se repete neste. O comportamento dos coeficientes neste experimento é muito similar à observada nos experimentos FEL com método EQM, a partir da leitura dos coeficientes de Spearman na Tabela 11 e Pearson na Tabela 12.

Tabela 14 – Dados sumarizados das observações do coeficiente de Spearman no controle MNFEL EQM do Forno de Pelotização.

| Conf. | Q | Média | Mediana | Desv. Pad.            | Mínimo | Máximo |
|-------|---|-------|---------|-----------------------|--------|--------|
| 1     | 1 | 0,945 | 0,989   | $8,768 \cdot 10^{-2}$ | 0,707  | 0,999  |
|       | 2 | 0,832 | 0,819   | $1,026 \cdot 10^{-1}$ | 0,680  | 0,999  |
|       | 3 | 0,743 | 0,733   | $4,296 \cdot 10^{-2}$ | 0,673  | 0,999  |
|       | 4 | 0,712 | 0,709   | $1,948 \cdot 10^{-2}$ | 0,664  | 0,786  |
| 2     | 1 | 0,985 | 0,999   | $3,945 \cdot 10^{-2}$ | 0,689  | 0,999  |
|       | 2 | 0,913 | 0,946   | $9,627 \cdot 10^{-2}$ | 0,563  | 0,999  |
|       | 3 | 0,792 | 0,782   | $8,031 \cdot 10^{-2}$ | 0,563  | 0,999  |
|       | 4 | 0,728 | 0,724   | $3,095 \cdot 10^{-2}$ | 0,633  | 0,994  |
| 3     | 1 | 0,937 | 0,952   | $4,776 \cdot 10^{-2}$ | 0,779  | 0,997  |
|       | 2 | 0,806 | 0,800   | $5,221 \cdot 10^{-2}$ | 0,687  | 0,968  |
|       | 3 | 0,722 | 0,720   | $2,626 \cdot 10^{-2}$ | 0,668  | 0,795  |
|       | 4 | 0,684 | 0,682   | $1,323 \cdot 10^{-2}$ | 0,657  | 0,721  |

Fonte: Dados da pesquisa.

Em todos os experimentos executados nesta planta, observou-se que o Coeficiente de Pearson teve pouca expressividade ao compor a avaliação do treinamento. Embora esta inexpressividade tenha sido claramente visualizada nos dados, defende-se a utilização do método com ambos coeficientes de correlação apresentados. A utilização conjunta dos métodos de Pearson e Spearman permite que se perceba perda na correlação quando esta deixar de ser linear enquanto torna-se não-linear monótona. De modo análogo, como

observado nestes experimentos, utilizando-se os dois métodos também é possível apontar a perda de relação monótona.

Tabela 15 – Dados sumarizados das observações do coeficiente de Pearson no controle MNFEL EQM do Forno de Pelotização.

| Conf. | Q | Média  | Mediana | Desv. Pad.      | Mínimo | Máximo |
|-------|---|--------|---------|-----------------|--------|--------|
| 1     | 1 | 0,9985 | 0,9989  | $1,232.10^{-3}$ | 0,9941 | 0,9991 |
|       | 2 | 0,9970 | 0,9978  | $1,851.10^{-3}$ | 0,9914 | 0,9989 |
|       | 3 | 0,9951 | 0,9955  | $1,807.10^{-3}$ | 0,9910 | 0,9979 |
|       | 4 | 0,9936 | 0,9937  | $1,304.10^{-3}$ | 0,9903 | 0,9964 |
| 2     | 1 | 0,9989 | 0,9990  | $1,417.10^{-4}$ | 0,9981 | 0,9991 |
|       | 2 | 0,9984 | 0,9984  | $3,961.10^{-4}$ | 0,9963 | 0,9990 |
|       | 3 | 0,9969 | 0,9970  | $7,404.10^{-4}$ | 0,9930 | 0,9981 |
|       | 4 | 0,9948 | 0,9950  | $1,195.10^{-3}$ | 0,9897 | 0,9968 |
| 3     | 1 | 0,9987 | 0,9988  | $2,583.10^{-4}$ | 0,9971 | 0,9990 |
|       | 2 | 0,9974 | 0,9977  | $1,071.10^{-3}$ | 0,9920 | 0,9989 |
|       | 3 | 0,9946 | 0,9950  | $1,837.10^{-3}$ | 0,9893 | 0,9976 |
|       | 4 | 0,9913 | 0,9914  | $2,018.10^{-3}$ | 0,9865 | 0,9954 |


Fonte: Dados da pesquisa.

### 5.3.2.5 Relação entre EQM e coeficientes de correlação da generalização

Faz-se a análise do EQM e dos coeficientes de correlação finais de cada experimento executado, ou seja, da generalização das RNAs no controle. Esta análise tem como finalidade relacionar o valor final dos coeficientes de correlação com o erro quadrático médio da planta, de modo que se possa verificar se existe uma relação direta ou inversa entre as métricas.

Os gráficos de dispersão presentes na Figura 35 dispõem os dados observados de EQM e coeficientes de Spearman e Pearson para as generalizações das redes A, B e C utilizadas nos experimentos FEL.

Figura 35 – Dispersão dos EQMs finais pelos coeficientes de correlação finais para os experimentos FEL na planta Forno de Pelotização.




Fonte: Dados da pesquisa.



Não existe um padrão claro entre o EQM final e o coeficiente de correlação, tanto de Pearson quanto de Spearman. Os dados do coeficiente de Spearman, no entanto, são geralmente maiores quando os dados do EQM são menores.

Considerando os resultados de dispersão, presentes nos gráficos da Figura 36, percebe-se não haver diferença significativa entre o observado nos experimentos FEL para os experimentos MNFEL, relativamente aos dados de dispersão de EQM pelos coeficientes de correlação.

Figura 36 – Dispersão dos EQMs finais pelos coeficientes de correlação finais para os experimentos MNFEL na planta Forno de Pelotização.



Fonte: Dados da pesquisa.

## 5.4 Experimentos *Cooling Coil*

Para os experimentos FEL e MNFEL executados na planta da Serpentina de Refrigeração, ou *Cooling Coil* em inglês, utilizou-se um controlador Proporcional-Integral-Derivativo (PID). O controlador tem as suas ações de controle limitadas ao intervalo  $[-1, 1]$  de modo a se adequar aos valores recebidos pela planta. Os ganhos foram calculados de modo que a planta obtivesse tempo de subida e *overshoot* mínimos. Os valores dos ganhos proporcional, integral e derivativo são, respectivamente:

$$K_p = 2$$

$$K_i = 0,004$$

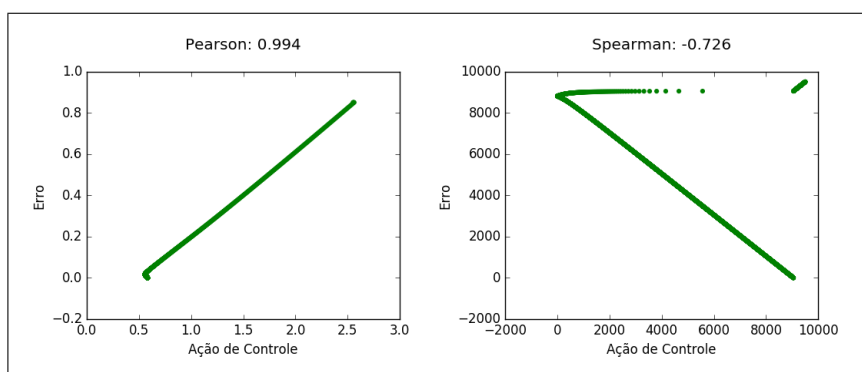
$$K_d = 1$$

Distúrbios também não foram considerados durante toda a simulação de 10000 iterações ou unidades de tempo. Pelo fato da planta se tratar de uma simulação de processo industrial que requer precisão, define-se que o *overshoot* não deve ser superior a 3%. A referência utilizada é do tipo degrau, normalizada, definida em  $r = 0,85$  com ativação em  $t = 500$ .

### 5.4.1 Identificação inicial da relação

Inicialmente, faz-se a identificação da relação inicial do erro da planta *cooling coil* e da ação de controle do PID. Após o descarte dos dados referentes ao período anterior ao degrau da referência, calculam-se os coeficientes de Pearson e Spearman e recorre-se aos gráfico dos dados para verificar a relação.

Figura 37 – Relação inicial do erro e ação de controle do PID na planta da Serpentina de Refrigeração.



Fonte: Dados da pesquisa.

Na Figura 37, encontram-se os gráficos da relação entre a ação de controle  $u$  do PID e o erro  $e$  da planta e a relação dos postos destes dados, respectivamente o gráfico esquerdo e direito. Visualmente, através do gráfico esquerdo, e considerando o alto coeficiente de Pearson calculado (0,994 para estes dados), é possível enganar-se e classificar a relação como sendo linear. Entretanto, observando-se ainda o gráfico esquerdo, percebe-se uma não-linearidade presente na cauda esquerda. Neste ponto, os dados têm sentido de crescimento contrário aos demais.

Através do gráfico direito, que relaciona os postos do erro e da ação de controle, é que se verifica o crescimento inverso dos dados em sua maior fração. Devido à grande diferença entre os dois métodos de mensurar a correlação, avalia-se que a relação entre os dados não pode ser descrita monotonicamente, nem tão pouco linearmente.

A operação entre PID e planta acontece, portanto, em regime não-linear. Deste modo, espera-se que a aplicação de estratégia inteligente de controle FEL ou MNFEL compense por estas não-linearidades, levando o controlador convencional a operar com maior grau de linearidade entre  $e$  e  $u$ .

Em relação ao controle, as métricas usuais da teoria do controle foram calculadas a parte do processo de identificação inicial da relação. Utiliza-se estas métricas para comparar, com maior precisão que visualmente, a qualidade do controle convencional com a qualidade do controle inteligente. As métricas – *rise time* (RT), *percentage overshoot* (PO), *settling time* (ST) e erro quadrático médio (EQM) estão dispostas na Tabela 16.

Tabela 16 – Métricas clássicas de controle a partir do controle convencional com PID na planta da Serpentina de Refrigeração.

| RT  | PO | ST  | EQM                   |
|-----|----|-----|-----------------------|
| 290 | 0% | 676 | $5,852 \cdot 10^{-3}$ |

Fonte: Dados da pesquisa.

As métricas de tempo de subida (RT) e tempo de acomodação (ST) envolvem tempo e são medidas em unidades de tempo da simulação, neste caso segundos. O tempo de subida, para esta métrica e os demais experimentos, foi medido no intervalo entre 10% e 90% da referência ( $r$ ), somente após o degrau. Considerou-se a faixa de 2% de  $r$ , para mais ou menos, no cálculo da métrica ST.

#### 5.4.2 Avaliação do treinamento

Bem como nos experimentos anteriores, realizados na planta do Forno de Pelotização, a avaliação deve ser realizada a cada experimento. As configurações de RNAs utilizadas estão dispostas na Tabela 17, onde  $n_i$  e  $n_k$  é o número de neurônios das camadas de entrada e escondida, respectivamente;  $\mu_{ih}$  é o coeficiente de aprendizado entre as camadas de entrada e escondida; e  $\mu_{ho}$  é o coeficiente de aprendizado entre as camadas escondida e de saída.

Tabela 17 – Detalhes das redes utilizadas nos experimentos da planta *Cooling Coil*. Cada RNA tem números de neurônios na camada de entrada ( $n_i$ ) e camada escondida ( $n_h$ ), além de coeficientes de aprendizado entre as camadas de entrada e escondida ( $\mu_{ih}$ ) e entre as camadas escondida e de saída ( $\mu_{ho}$ ).

| RNA      | $n_i$ | $n_h$ | $\mu_{ih}$        | $\mu_{ho}$        |
|----------|-------|-------|-------------------|-------------------|
| <b>A</b> | 20    | 5     | $1 \cdot 10^{-5}$ | $3 \cdot 10^{-6}$ |
| <b>B</b> | 10    | 15    | $9 \cdot 10^{-6}$ | $8 \cdot 10^{-6}$ |
| <b>C</b> | 5     | 3     | $1 \cdot 10^{-6}$ | $1 \cdot 10^{-6}$ |
| <b>D</b> | 3     | 2     | $1 \cdot 10^{-6}$ | $1 \cdot 10^{-6}$ |

Fonte: Elaborada pelo autor.

Para a estratégia MNFEL, os *ensembles* tiveram seus intervalos de geração de pesos sinápticos aleatórios definidos para cada configuração. Entretanto, nos experimentos FEL, o valor  $\gamma$  utilizado para definir o intervalo, do tipo  $[-\gamma, \gamma]$ , foi fixado em 0,4.


##### 5.4.2.1 FEL com critério de parada pelo desvio padrão do erro

Para os experimentos FEL DESVPAD, ou seja, com critério de parada pelo desvio padrão do erro, escolheu-se as redes A, B e C dentre todas as presentes na Tabela 17. A escolha destas redes foi com base na performance geral destas em todos os outros experimentos realizados na mesma planta.

Inicialmente, percebe-se que as redes são menores que as RNAs utilizadas nos experimentos da planta Pelotização. Isto deve-se ao fato de que experimentos prévios, utilizando-se redes maiores, obtiveram resultados com EQM e PO inadequados de acordo com os padrões definidos no início da Seção 5.4. Por outro lado, as redes menores podem sofrer de *underfit* – quando treina-se por tempo insuficiente para adquirir um aprendizado satisfatório – dependendo do critério de parada escolhido.

Observa-se, nos gráficos da Figura 38, que o controle FEL pouco avançou, quando comparado com o PID. O resultado da rede A foi o melhor dentre as três redes selecionadas. O critério de parada experimentado não favoreceu o controle, finalizando o treinamento precocemente. Portanto, a RNA A pode ter obtido melhor resultado por ter maiores coeficientes de aprendizado  $\mu_{ih}$  e  $\mu_{io}$  e mais neurônios artificiais no geral.


Figura 38 – Controle FEL na planta da Serpentina de Refrigeração utilizando critério de parada pelo desvio padrão do erro.



Fonte: Dados da pesquisa.

Visualizando-se os gráficos dos sinais de controle da Figura 39, é perceptível que a compensação das redes não foi efetiva. Observa-se que a rede A forneceu a maior compensação dentre os três experimentos, entretanto insuficientemente.

Figura 39 – Sinais de controle FEL DESVPAD na planta da Serpentina de Refrigeração.  $u_{cfc}$  é a ação de controle do PID,  $u_n$  a ação de controle da rede neural e  $u$  o combinado das ações.



Fonte: Dados da pesquisa.

A partir da leitura da Tabela 18, que dispõe as métricas clássicas de controle para estes experimentos, percebe-se que a estratégia FEL contribuiu para a melhoria do controle, entretanto de maneira muito discreta, compara-se aos dados do controle apenas com PID dispostos na Tabela 16.


Tabela 18 – Dados de métricas de controle para os experimentos FEL com critério de parada pelo desvio padrão do erro na planta da Serpentina de Refrigeração.

| RNA | Ind. | Média           | Mediana         | Desv. Pad.      | Mínimo          | Máximo          |
|-----|------|-----------------|-----------------|-----------------|-----------------|-----------------|
| A   | RT   | 281,133         | 281             | 1,870           | 277             | 285             |
|     | PO   | 0,004%          | 0%              | 0,020           | 0%              | 0,108%          |
|     | ST   | 474,466         | 470             | 20,548          | 439             | 526             |
|     | EQM  | $5,811.10^{-3}$ | $5,809.10^{-3}$ | $6,578.10^{-6}$ | $5,799.10^{-3}$ | $5,826.10^{-3}$ |
| B   | RT   | 287,366         | 288             | 2,125           | 281             | 290             |
|     | PO   | 0%              | 0%              | 0%              | 0%              | 0%              |
|     | ST   | 601,600         | 604,500         | 41,317          | 519             | 666             |
|     | EQM  | $5,841.10^{-3}$ | $5,843.10^{-3}$ | $8,107.10^{-6}$ | $5,821.10^{-3}$ | $5,852.10^{-3}$ |
| C   | RT   | 289,400         | 289             | 0,498           | 289             | 290             |
|     | PO   | 0%              | 0%              | 0%              | 0%              | 0%              |
|     | ST   | 663,533         | 663,500         | 6,284           | 648             | 676             |
|     | EQM  | $5,851.10^{-3}$ | $5,851.10^{-3}$ | $1,808.10^{-5}$ | $5,849.10^{-3}$ | $5,853.10^{-3}$ |

Fonte: Dados da pesquisa.

Observando-se os gráficos presentes na Figura 40, nota-se claramente que o efeito esperado, de crescimento do coeficiente de correlação de Spearman, é apenas obtido no experimento da rede neural A. Curiosamente, as demais redes, que não foram capazes de controlar a planta efetivamente mesmo treinando por número de sessões similar à rede A, obtiveram padrão completamente diferente do esperado. O coeficiente de Pearson, por outro lado, permaneceu praticamente estático, muito próximo do valor 1 que indica correlação perfeita e positiva.

Figura 40 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia FEL DESVPAD na planta *Cooling Coil*.



Fonte: Dados da pesquisa.

No entanto, o efeito da correlação observado no experimento da rede A – exposta no primeiro gráfico da Figura 40 – não foi predominante dentre todos os experimentos executados para esta mesma RNA. Ou seja, mesmo que a estratégia tenha sido capaz de melhorar minimamente o controle, ela não estava sendo efetiva na compensação pela não-linearidade da planta. Confirma-se o explanado a partir leitura das Tabelas 19 e 20 que trazem os dados dos coeficientes de Spearman e Pearson, respectivamente, para estes

experimentos.

Tabela 19 – Dados sumarizados das observações do coeficiente de Spearman no controle FEL DESVPAD da planta *Cooling Coil*.

| RNA | Q | Média  | Mediana | Desv. Pad.            | Mínimo | Máximo |
|-----|---|--------|---------|-----------------------|--------|--------|
| A   | 1 | -0,113 | -0,104  | $7,501 \cdot 10^{-2}$ | -0,293 | 0,031  |
|     | 2 | -0,026 | -0,006  | $9,677 \cdot 10^{-2}$ | -0,267 | 0,113  |
|     | 3 | 0,042  | 0,088   | $9,524 \cdot 10^{-2}$ | -0,234 | 0,132  |
|     | 4 | -0,529 | -0,649  | $4,095 \cdot 10^{-1}$ | -0,696 | 0,996  |
| B   | 1 | -0,558 | -0,569  | $6,148 \cdot 10^{-2}$ | -0,681 | -0,409 |
|     | 2 | -0,552 | -0,564  | $6,139 \cdot 10^{-2}$ | -0,680 | -0,395 |
|     | 3 | -0,543 | -0,553  | $6,606 \cdot 10^{-2}$ | -0,678 | -0,380 |
|     | 4 | -0,626 | -0,707  | $1,056 \cdot 10^{-1}$ | -0,724 | -0,363 |
| C   | 1 | -0,684 | -0,682  | $2,717 \cdot 10^{-2}$ | -0,725 | -0,617 |
|     | 2 | -0,683 | -0,681  | $2,763 \cdot 10^{-2}$ | -0,725 | -0,615 |
|     | 3 | -0,682 | -0,680  | $2,809 \cdot 10^{-2}$ | -0,725 | -0,613 |
|     | 4 | -0,724 | -0,724  | $6,320 \cdot 10^{-4}$ | -0,725 | -0,723 |

Fonte: Dados da pesquisa.

Lendo-se os resultados presentes na Tabela 19, que organiza os dados do coeficiente de Spearman (CS), percebe-se que o comportamento definido não foi obtido. Esperava-se obter um padrão crescente para CS, entretanto o observado foi um padrão de queda. Este padrão irregular ao definido, indica que as redes não foram capazes de contribuir para o controle, não compensando efetivamente pela não-linearidade da planta.

Tabela 20 – Dados sumarizados das observações do coeficiente de Pearson no controle FEL DESVPAD da planta *Cooling Coil*.

| RNA | Q | Média  | Mediana | Desv. Pad.            | Mínimo | Máximo |
|-----|---|--------|---------|-----------------------|--------|--------|
| A   | 1 | 0,9964 | 0,9965  | $4,045 \cdot 10^{-4}$ | 0,9955 | 0,9972 |
|     | 2 | 0,9982 | 0,9983  | $5,901 \cdot 10^{-4}$ | 0,9966 | 0,9991 |
|     | 3 | 0,9991 | 0,9993  | $4,917 \cdot 10^{-4}$ | 0,9976 | 0,9995 |
|     | 4 | 0,9993 | 0,9995  | $4,917 \cdot 10^{-4}$ | 0,9979 | 0,9998 |
| B   | 1 | 0,9946 | 0,9946  | $1,942 \cdot 10^{-4}$ | 0,9943 | 0,9952 |
|     | 2 | 0,9951 | 0,9951  | $3,976 \cdot 10^{-4}$ | 0,9944 | 0,9961 |
|     | 3 | 0,9956 | 0,9956  | $6,109 \cdot 10^{-4}$ | 0,9944 | 0,9968 |
|     | 4 | 0,9961 | 0,9960  | $8,252 \cdot 10^{-4}$ | 0,9945 | 0,9975 |
| C   | 1 | 0,9943 | 0,9943  | $3,875 \cdot 10^{-5}$ | 0,9942 | 0,9944 |
|     | 2 | 0,9944 | 0,9944  | $7,811 \cdot 10^{-5}$ | 0,9942 | 0,9946 |
|     | 3 | 0,9945 | 0,9945  | $1,167 \cdot 10^{-4}$ | 0,9942 | 0,9948 |
|     | 4 | 0,9945 | 0,9945  | $1,181 \cdot 10^{-4}$ | 0,9942 | 0,9948 |

Fonte: Dados da pesquisa.

A partir dos dados da Tabela 20 – observações do Coeficiente de Pearson durante o treinamento – não é possível obter um padrão claro de crescimento ou decrescimento.

Este é mais um forte indício de que o Coeficiente de Pearson deve ser utilizado, durante o treinamento, apenas como método para atestar a linearidade da relação quando CS indicar uma correlação perfeita.

Neste experimento, portanto, nenhuma rede foi capaz de compensar efetivamente pela não-linearidade da planta, visto que os coeficientes de correlação – coeficiente de Spearman, mais especificamente – não apresentaram padrão de crescimento esperado.

#### 5.4.2.2 MNFEL com critério de inserção e parada pelo desvio padrão do erro

Experimentos MNFEL com critério de inserção e parada pelo desvio padrão do erro (MNFEL DESVPAD) também foram executados a fim de se averiguar o comportamento da métrica proposta, de acordo com a performance de controle obtida pela estratégia de controle inteligente.

As rede utilizadas neste experimento são as mesmas presentes na Tabela 17, entretanto organizadas em diferentes configurações. O valor de  $\gamma$  utilizado – para definição do intervalo de geração de pesos sinápticos – foi fixado em  $\gamma = 0,4$ . O referido intervalo é, portanto,  $[-0,4; 0,4]$ . A Tabela 21 destaca as configurações utilizadas.


Tabela 21 – Configurações MNFEL utilizadas no experimento da Serpentina de Refrigeração.

| Configuração   | Tipo   | Redes    | $\gamma$ |
|----------------|--------|----------|----------|
| <b>CONFIG1</b> | MNFEL2 | A e D    | 0,4      |
| <b>CONFIG2</b> | MNFEL3 | A, C e D | 0,4      |
| <b>CONFIG3</b> | MNFEL2 | C e D    | 0,4      |

Fonte: Elaborada pelo autor.

Assim como no experimento FEL anterior, o tempo de treinamento dado pelo critério de inserção e parada não foi suficiente para obter-se qualidade de controle superior. Visualizando-se os gráficos da Figura 41, percebe-se que o controle MNFEL de 3 e de 2 redes ficou muito próximo do controle utilizando-se apenas PID.

Figura 41 – Controle MNFEL na planta da Serpentina de Refrigeração utilizando critério de inserção e parada pelo desvio padrão do erro.




Fonte: Dados da pesquisa.

Os gráficos de controle sugerem que as RNAs pouco compensaram pela não-linearidade da planta, apresentando melhoria mínima no controle. Neste cenário, espera-se que a métrica não aponte a compensação efetiva, ou seja, não apresente padrão de crescimento de grande magnitude, podendo apresentar uma queda ou estabilidade relativa no coeficiente de Spearman, principalmente.

Assim como os dados da estratégia FEL com critério DESVPAD, os gráficos da Figura 42 apontam que houve pouca participação das redes na ação de controle.

Figura 42 – Sinais de controle MNFEL DESVPAD na planta da Serpentina de Refrigeração.  $u_{cfc}$  é a ação de controle do PID,  $u_n$  a ação de controle das redes neurais e  $u$  o combinado das ações.



Fonte: Dados da pesquisa.

A partir dos dados apresentados na Tabela 22, confirma-se que os experimentos MNFEL tiveram desempenho inferior aos experimentos FEL equivalentes. Nestes experimentos, a melhor configuração foi CONFIG2, embora com desempenho inferior à maioria dos experimentos FEL de mesmo critério. Comparando-se estes resultados aos equivalentes utilizando PID, dispostos na Tabela 16, observa-se que houve uma melhora irrisória das métricas.

Tabela 22 – Dados de métricas de controle para os experimentos MNFEL com critério de inserção e parada pelo desvio padrão do erro da planta *Cooling Coil*.


| Conf. | Ind. | Média           | Mediana         | Desv. Pad.      | Mínimo          | Máximo          |
|-------|------|-----------------|-----------------|-----------------|-----------------|-----------------|
| 1     | RT   | 286,700         | 287,500         | 1,803           | 283             | 289             |
|       | PO   | 0%              | 0%              | 0%              | 0%              | 0%              |
|       | ST   | 581,566         | 590             | 35,584          | 525             | 650             |
|       | EQM  | $5,838.10^{-3}$ | $5,841.10^{-3}$ | $7,562.10^{-6}$ | $5,825.10^{-3}$ | $5,849.10^{-3}$ |
| 2     | RT   | 286,466         | 287             | 1,995           | 281             | 289             |
|       | PO   | 0%              | 0%              | 0%              | 0%              | 0%              |
|       | ST   | 581             | 584,500         | 34,516          | 510             | 627             |
|       | EQM  | $5,837.10^{-3}$ | $5,839.10^{-3}$ | $7,638.10^{-6}$ | $5,819.10^{-3}$ | $5,847.10^{-3}$ |
| 3     | RT   | 289,100         | 289             | 0,305           | 289             | 290             |
|       | PO   | 0%              | 0%              | 0%              | 0%              | 0%              |
|       | ST   | 657,800         | 659             | 7,438           | 640             | 671             |
|       | EQM  | $5,850.10^{-3}$ | $5,851.10^{-3}$ | $9,543.10^{-7}$ | $5,849.10^{-3}$ | $5,852.10^{-3}$ |

Fonte: Dados da pesquisa.



Na Figura 43, estão presentes dos gráficos da evolução dos coeficientes de correlação de Pearson e Spearman para três experimentos do controle utilizando-se MNFEL, selecionados aleatoriamente. Através dos gráficos é possível confirmar que o padrão, que indicaria a efetiva compensação pela não-linearidade da planta, não está presente.

Figura 43 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia MNFEL DESVPAD na planta *Cooling Coil*.



Fonte: Dados da pesquisa.

Nas Tabelas 23 e 24, que dispõem os dados de CS e CP respectivamente, pode-se acompanhar informações sumarizadas das execuções. Assim como nos experimentos anteriores, as diferentes reproduções têm diferentes números de sessões de treinamento. Portanto, para permitir melhor entendimento sobre o comportamento geral, dividiu-se cada experimento em quatro quadrantes, calculando-se ao final a média, mediana, desvio padrão, valor mínimo e máximo.

Tabela 23 – Dados sumarizados das observações do coeficiente de Spearman no controle MNFEL DESVPAD da planta *Cooling Coil*.

| Conf. | Q | Média   | Mediana | Desv. Pad.      | Mínimo  | Máximo  |
|-------|---|---------|---------|-----------------|---------|---------|
| 1     | 1 | -0,1530 | -0,1523 | $5,521.10^{-2}$ | -0,1691 | -0,1416 |
|       | 2 | -0,1513 | -0,1506 | $6,308.10^{-2}$ | -0,1690 | -0,1381 |
|       | 3 | -0,1604 | -0,1633 | $9,894.10^{-2}$ | -0,1720 | -0,1406 |
|       | 4 | -0,1694 | -0,1706 | $2,578.10^{-2}$ | -0,1723 | -0,1629 |
| 2     | 1 | -0,1565 | -0,1560 | $6,148.10^{-2}$ | -0,1709 | -0,1450 |
|       | 2 | -0,1583 | -0,1563 | $8,123.10^{-2}$ | -0,1720 | -0,1418 |
|       | 3 | -0,1653 | -0,1665 | $4,812.10^{-2}$ | -0,1720 | -0,1501 |
|       | 4 | -0,1696 | -0,1706 | $2,295.10^{-2}$ | -0,1720 | -0,1640 |
| 3     | 1 | -0,1690 | -0,1692 | $3,061.10^{-2}$ | -0,1725 | -0,1624 |
|       | 2 | -0,1689 | -0,1690 | $3,142.10^{-2}$ | -0,1725 | -0,1621 |
|       | 3 | -0,1706 | -0,1713 | $1,873.10^{-2}$ | -0,1725 | -0,1657 |
|       | 4 | -0,1715 | -0,1723 | $1,618.10^{-2}$ | -0,1725 | -0,1656 |

Fonte: Dados da pesquisa.

Confirma-se que o efeito, acompanhado nestas três reproduções do experimento, é predominante em todo o experimento, para todas as configurações. Fica claro que o coeficiente de Spearman, pelos dados da Tabela 23, manteve comportamento estável,

Tabela 24 – Dados sumarizados das observações do coeficiente de Pearson no controle MNFEL DESVPAD da planta *Cooling Coil*.

| Conf.    | Q | Média  | Mediana | Desv. Pad.            | Mínimo | Máximo |
|----------|---|--------|---------|-----------------------|--------|--------|
| <b>1</b> | 1 | 0,9948 | 0,9948  | $2,724 \cdot 10^{-4}$ | 0,9943 | 0,9954 |
|          | 2 | 0,9956 | 0,9956  | $5,280 \cdot 10^{-4}$ | 0,9944 | 0,9969 |
|          | 3 | 0,9962 | 0,9961  | $7,336 \cdot 10^{-4}$ | 0,9945 | 0,9975 |
|          | 4 | 0,9964 | 0,9965  | $7,694 \cdot 10^{-4}$ | 0,9947 | 0,9976 |
| <b>2</b> | 1 | 0,9948 | 0,9948  | $3,219 \cdot 10^{-4}$ | 0,9943 | 0,9958 |
|          | 2 | 0,9956 | 0,9955  | $5,692 \cdot 10^{-4}$ | 0,9946 | 0,9971 |
|          | 3 | 0,9961 | 0,9960  | $7,159 \cdot 10^{-4}$ | 0,9951 | 0,9974 |
|          | 4 | 0,9963 | 0,9963  | $7,253 \cdot 10^{-4}$ | 0,9953 | 0,9975 |
| <b>3</b> | 1 | 0,9943 | 0,9943  | $4,068 \cdot 10^{-5}$ | 0,9942 | 0,9944 |
|          | 2 | 0,9944 | 0,9944  | $1,109 \cdot 10^{-4}$ | 0,9943 | 0,9947 |
|          | 3 | 0,9945 | 0,9945  | $1,327 \cdot 10^{-4}$ | 0,9943 | 0,9949 |
|          | 4 | 0,9946 | 0,9946  | $1,473 \cdot 10^{-4}$ | 0,9943 | 0,9950 |

Fonte: Dados da pesquisa.

apresentando uma leve queda nos últimos quadrantes. Deste modo, argumenta-se que o treinamento das redes não foi efetivo, de modo que não houve crescimento do coeficiente de Spearman, indicando a compensação pela não-linearidade, como esperado da estratégia MNFEL com redes em configuração NRL.

Mais uma vez, os dados do Coeficiente de Pearson, presentes na Tabela 24, devem ser utilizados apenas para apontar uma eventual linearidade na correlação obtida. Isto pois não observou-se padrão condizente com o esperado para os experimentos executados.


#### 5.4.2.3 FEL com critério de parada pelo erro quadrático médio

Nestes experimentos, utilizam-se as mesmas redes neurais (A, B e C), definidas na Tabela 17, presentes no experimento FEL anterior, com diferente critério de parada. Por ter critério de parada pelo erro quadrático médio, à estratégia aplicada nestes experimentos foi dado o nome FEL EQM.

A partir da Figura 44, observando-se os gráficos presentes, percebe-se que o controle obtido é mais próximo da referência que o PID. Analisando-se graficamente o controle, tem-se claramente uma melhora às estratégias FEL e MNFEL (analisando-se as Figuras 38 e 41, respectivamente) utilizando critério de parada pelo desvio padrão do erro.

Para estas execuções, portanto, há menor preocupação com o efeito do *underfit* – quando a técnica inteligente treina por tempo insuficiente ou numa quantidade insuficiente de dados. Todavia, preocupa-se mais com o sobre-sinal percentual desde que este torna-se visivelmente presente no controle atual.


Figura 44 – Controle FEL na planta da Serpentina de Refrigeração utilizando critério de parada pelo erro quadrático médio.



Fonte: Dados da pesquisa.

Observa-se os gráficos dos sinais de controle – a partir da Figura 45 – para estes experimentos. É possível observar que, comparando-se aos gráficos dos experimentos FEL e MNFEL DESVPAD, a estratégia FEL com critério EQM foi capaz de fornecer um sinal de controle de magnitude superior.

Figura 45 – Sinais de controle FEL EQM na planta da Serpentina de Refrigeração.  $u_{cfc}$  é a ação de controle do PID,  $u_n$  a ação de controle da rede neural e  $u$  o combinado das ações.



Fonte: Dados da pesquisa.

Analisando-se os dados presentes na Tabela 25 observa-se que há uma considerável melhora no controle convencional a partir da aplicação da estratégia inteligente FEL e MNFEL com critério do erro quadrático médio (Tabelas 18 e 22, em ordem). Percebe-se a melhora, inclusive, aos dados da execução com PID apenas, dispostos na Tabela 16. Os maiores valores de RT, PO, ST e EQM, por exemplo, são menores que a maioria dos respectivos menores valores obtidos em experimentos anteriores, incluindo-se FEL e MNFEL.

Nestes experimentos, devido à presença de *overshoot* – que até então não havia sido experienciado na planta –, acompanhou-se de perto a métrica clássica PO. Ressalta-se, no entanto, que o máximo valor de PO alcançado em todos os experimentos não se aproximou em demasia de 3%, definido como o limite aceitável de *overshoot*.

Avaliando-se o comportamento dos coeficientes de correlação, presentes nos gráficos da Figura 46, é perceptível o crescimento do coeficiente de Spearman. No início do


Tabela 25 – Dados de métricas de controle para os experimentos FEL com critério de parada pelo erro quadrático médio na planta da Serpentina de Refrigeração.

| RNA | Ind. | Média           | Mediana         | Desv. Pad.      | Mínimo          | Máximo          |
|-----|------|-----------------|-----------------|-----------------|-----------------|-----------------|
| A   | RT   | 274,933         | 275             | 1,552           | 273             | 278             |
|     | PO   | 0,897%          | 0,889%          | 0,076%          | 0,769%          | 1,072           |
|     | ST   | 410,433         | 409             | 5,468           | 401             | 421             |
|     | EQM  | $5,797.10^{-3}$ | $5,796.10^{-3}$ | $3,391.10^{-6}$ | $5,791.10^{-3}$ | $5,804.10^{-3}$ |
| B   | RT   | 273,966         | 274             | 0,850           | 273             | 276             |
|     | PO   | 1,337%          | 1,286%          | 0,181%          | 1,076%          | 1,771%          |
|     | ST   | 401             | 401             | 4,405           | 393             | 412             |
|     | EQM  | $5,800.10^{-3}$ | $5,799.10^{-3}$ | $2,723.10^{-6}$ | $5,796.10^{-3}$ | $5,806.10^{-3}$ |
| C   | RT   | 275,533         | 275,500         | 0,776           | 274             | 277             |
|     | PO   | 0,735%          | 0,734%          | 0,029%          | 0,676%          | 0,800%          |
|     | ST   | 416,266         | 416             | 2,531           | 411             | 421             |
|     | EQM  | $5,797.10^{-3}$ | $5,796.10^{-3}$ | $1,503.10^{-6}$ | $5,794.10^{-3}$ | $5,800.10^{-3}$ |

Fonte: Dados da pesquisa.

treinamento, conforme verificado a partir da análise inicial da relação, a planta e o PID têm relação não-linear. Conforme a estratégia treina na planta com a informação de controle do PID, a RNA passa a compensar pelas não-linearidades que antes atrapalhavam a relação entre PID e o erro da planta.

Figura 46 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia FEL EQM na planta *Cooling Coil*.



Fonte: Dados da pesquisa.

O crescimento desta relação, indicando que ao final do treinamento o erro da planta e as ações do PID se correlacionam monotonamente, quase que linear, aponta que a compensação das redes foi efetiva, garantindo que a melhoria observada através das métricas clássicas de controle estão de fato relacionadas ao papel desempenhado pela RNA.

Curiosamente, no gráfico da Figura 46, a rede B treinou por curto período de tempo (apenas 10 sessões de treinamento), assim como alguns experimentos FEL e MNFEL com critério pelo desvio padrão. Entretanto, o comportamento do seu coeficiente de Spearman teve crescimento positivo durante a maior parte do tempo, culminando numa correlação praticamente perfeita.

Analisando-se a Tabela 26, visualiza-se que o coeficiente de Spearman tem o crescimento esperado somente no último quarto do treinamento. É possível perceber, também, através dos valores do desvio padrão, máximo e mínimo, que houve oscilação nos resultados no quadrante. Recorre-se novamente à Figura 46 para observar o comportamento do coeficiente de Spearman. Percebe-se que este cresce de maneira abrupta, provocando uma grande variação entre mínimo e máximo dentro de um mesmo quadrante.

Tabela 26 – Dados sumarizados das observações do coeficiente de Spearman no controle FEL EQM da planta *Cooling Coil*.

| RNA | Q | Média  | Mediana | Desv. Pad.            | Mínimo | Máximo |
|-----|---|--------|---------|-----------------------|--------|--------|
| A   | 1 | -0,523 | -0,510  | $8,064 \cdot 10^{-2}$ | -0,693 | -0,307 |
|     | 2 | -0,413 | -0,406  | $1,198 \cdot 10^{-1}$ | -0,661 | 0,005  |
|     | 3 | -0,084 | -0,144  | $3,403 \cdot 10^{-1}$ | -0,559 | 0,989  |
|     | 4 | 0,904  | 0,993   | $2,989 \cdot 10^{-1}$ | -0,525 | 0,996  |
| B   | 1 | -0,080 | -0,085  | $8,396 \cdot 10^{-2}$ | -0,258 | 0,091  |
|     | 2 | 0,048  | 0,087   | $1,077 \cdot 10^{-2}$ | -0,481 | 0,158  |
|     | 3 | 0,600  | 0,971   | $5,812 \cdot 10^{-1}$ | -0,546 | 0,988  |
|     | 4 | 0,992  | 0,991   | $2,805 \cdot 10^{-3}$ | 0,987  | 0,996  |
| C   | 1 | -0,670 | -0,671  | $3,312 \cdot 10^{-2}$ | -0,725 | -0,560 |
|     | 2 | -0,605 | -0,607  | $5,550 \cdot 10^{-2}$ | -0,715 | -0,416 |
|     | 3 | -0,352 | -0,432  | $2,913 \cdot 10^{-1}$ | -0,674 | 0,993  |
|     | 4 | 0,881  | 0,995   | $3,431 \cdot 10^{-1}$ | -0,493 | 0,996  |

Fonte: Dados da pesquisa.

Tabela 27 – Dados sumarizados das observações do coeficiente de Pearson no controle FEL EQM da planta *Cooling Coil*.

| RNA | Q | Média  | Mediana | Desv. Pad.            | Mínimo | Máximo |
|-----|---|--------|---------|-----------------------|--------|--------|
| A   | 1 | 0,9958 | 0,9957  | $8,882 \cdot 10^{-4}$ | 0,9943 | 0,9980 |
|     | 2 | 0,9981 | 0,9982  | $9,573 \cdot 10^{-4}$ | 0,9954 | 0,9997 |
|     | 3 | 0,9995 | 0,9997  | $4,672 \cdot 10^{-4}$ | 0,9974 | 0,9998 |
|     | 4 | 0,9987 | 0,9989  | $7,789 \cdot 10^{-4}$ | 0,9971 | 0,9998 |
| B   | 1 | 0,9973 | 0,9972  | $9,618 \cdot 10^{-4}$ | 0,9955 | 0,9988 |
|     | 2 | 0,9994 | 0,9995  | $2,965 \cdot 10^{-4}$ | 0,9985 | 0,9998 |
|     | 3 | 0,9987 | 0,9990  | $8,247 \cdot 10^{-4}$ | 0,9958 | 0,9997 |
|     | 4 | 0,9960 | 0,9962  | $1,222 \cdot 10^{-3}$ | 0,9929 | 0,9985 |
| C   | 1 | 0,9957 | 0,9957  | $8,625 \cdot 10^{-4}$ | 0,9943 | 0,9977 |
|     | 2 | 0,9981 | 0,9981  | $7,715 \cdot 10^{-4}$ | 0,9958 | 0,9995 |
|     | 3 | 0,9995 | 0,9996  | $3,655 \cdot 10^{-4}$ | 0,9978 | 0,9998 |
|     | 4 | 0,9992 | 0,9993  | $5,012 \cdot 10^{-4}$ | 0,9981 | 0,9998 |

Fonte: Dados da pesquisa.

O coeficiente de Pearson, durante esta etapa de experimentação de acordo com a Tabela 27, permaneceu praticamente estável. Sua consideração no processo está relacionada à capacidade de afirmação de uma relação como linear ou não. Esta afirmação não pode ser


feita apenas utilizando-se o coeficiente de Spearman, visto que este mensura correlações monótonas.

#### 5.4.2.4 MNFEL com critério de inserção e parada pelo erro quadrático médio

Os experimentos aqui descritos utilizam as mesmas configurações descritas na Tabela 21 de modo que se possa comparar os resultados da estratégia MNFEL, com diferentes critérios de inserção e parada, nas mesmas condições. As configurações 1, 2 e 3 foram, portanto, aplicadas para o controle da planta. Denominou-se por MNFEL EQM a estratégia em conjunto com o critério de inserção e parada utilizado.

Acompanha-se, pelos gráficos da Figura 47, que o controle MNFEL apresentou resultados melhores que os experimentos equivalentes, utilizando as mesmas configurações, com diferente critério de inserção e parada (Figuras 38 referente ao FEL e 41 referente ao MNFEL).


Figura 47 – Controle MNFEL na planta da Serpentina de Refrigeração utilizando critério de parada pelo erro quadrático médio.



Fonte: Dados da pesquisa.

Os dados dos sinais de controle, presentes nos gráficos da Figura 48 evidenciam que houve compensação por parte das redes neurais. A participação das redes é bem mais evidente que os experimentos MNFEL equivalentes, utilizando-se critério DESVPAD.

Figura 48 – Sinais de controle MNFEL EQM na planta da Serpentina de Refrigeração.  $u_{cfc}$  é a ação de controle do PID,  $u_n$  a ação de controle das redes neurais e  $u$  o combinado das ações.



Fonte: Dados da pesquisa.

Na Tabela 28, os dados do controle obtidos nos experimentos executados são dispostos. Comparando-se os números aos resultados FEL com o mesmo critério (Tabela 25), vê-se que, na média, o MNFEL foi capaz de diminuir o erro, sem provocar aumento no *overshoot*. O maior PO obtido foi de 1,049%, em CONFIG1, não atingindo o valor máximo permitido para esta planta.


Tabela 28 – Dados de métricas de controle para os experimentos MNFEL com critério de parada pelo erro quadrático médio na planta da Serpentina de Refrigeração.

| Conf. | Ind. | Média           | Mediana         | Desv. Pad.      | Mínimo          | Máximo          |
|-------|------|-----------------|-----------------|-----------------|-----------------|-----------------|
| 1     | RT   | 274,966         | 275             | 1,325           | 273             | 278             |
|       | PO   | 0,889%          | 0,893%          | 0,091%          | 0,680%          | 1,049%          |
|       | ST   | 410,166         | 409             | 4,878           | 401             | 420             |
|       | EQM  | $5,796.10^{-3}$ | $5,796.10^{-3}$ | $3,134.10^{-6}$ | $5,790.10^{-3}$ | $5,803.10^{-3}$ |
| 2     | RT   | 274,333         | 274             | 1,093           | 272             | 277             |
|       | PO   | 0,891%          | 0,887%          | 0,065%          | 0,701%          | 1,003%          |
|       | ST   | 407,333         | 407,500         | 4,188           | 397             | 416             |
|       | EQM  | $5,795.10^{-3}$ | $5,795.10^{-3}$ | $2,359.10^{-6}$ | $5,789.10^{-3}$ | $5,800.10^{-3}$ |
| 3     | RT   | 275,700         | 276             | 0,836           | 274             | 277             |
|       | PO   | 0,770%          | 0,760%          | 0,049%          | 0,699%          | 0,905%          |
|       | ST   | 416,166         | 417             | 2,841           | 409             | 420             |
|       | EQM  | $5,797.10^{-3}$ | $5,797.10^{-3}$ | $1,728.10^{-6}$ | $5,793.10^{-3}$ | $5,800.10^{-3}$ |

Fonte: Dados da pesquisa.

A partir da leitura dos gráficos da Figura 49, observa-se que o comportamento do coeficiente de correlação está de acordo com o esperado, traçado durante a etapa de identificação da relação inicial. Nota-se que CONFIG3, por ser uma configuração com duas redes pequenas, teve padrão de crescimento mais lento que as demais configurações, que continham ao menos uma rede maior.

Figura 49 – Evolução dos coeficientes de Pearson e Spearman ao longo do treinamento da estratégia MNFEL EQM na planta *Cooling Coil*.



Fonte: Dados da pesquisa.

Os experimentos, destacados pela Tabela 28 e Figura 49, obtiveram resultados promissores e satisfatórios. A comparação com os resultados MNFEL de inserção/parada pelo desvio padrão (na Tabela 22 e Figura 43) não deixa dúvidas de que o critério pelo EQM permitiu uma melhor compensação das redes.

A avaliação do coeficiente de Pearson, na Figura 49, é impossibilitada devido a baixa variabilidade apresentada, e a proximidade do valor 1. Nestes experimentos, a etapa de avaliação dos coeficientes de correlação levou em consideração principalmente o coeficiente de Spearman. Mais uma vez, a presença do CP limitou-se à capacidade de afirmação de uma relação como linear.

Através da Tabela 29, pode-se acompanhar os dados sumarizados dos coeficientes de correlação. Perceptivelmente, no geral, o coeficiente de Spearman apresentou padrão crescente, indicando que todo o experimento seguiu o comportamento observado nos gráficos da Figura 49.

Tabela 29 – Dados sumarizados das observações do coeficiente de Spearman no controle MNFEL EQM na planta *Cooling Coil*.

| Conf.    | Q | Média  | Mediana | Desv. Pad.            | Mínimo | Máximo |
|----------|---|--------|---------|-----------------------|--------|--------|
| <b>1</b> | 1 | -0,413 | -0,507  | $3,684 \cdot 10^{-1}$ | -0,661 | 0,996  |
|          | 2 | -0,180 | -0,373  | $5,104 \cdot 10^{-1}$ | -0,625 | 0,996  |
|          | 3 | 0,232  | 0,046   | $5,455 \cdot 10^{-1}$ | -0,524 | 0,996  |
|          | 4 | 0,982  | 0,994   | $1,014 \cdot 10^{-1}$ | -0,036 | 0,996  |
| <b>2</b> | 1 | -0,514 | -0,512  | $5,715 \cdot 10^{-2}$ | -0,638 | -0,352 |
|          | 2 | -0,371 | -0,387  | $1,133 \cdot 10^{-2}$ | -0,583 | 0,049  |
|          | 3 | 0,334  | 0,123   | $5,401 \cdot 10^{-2}$ | -0,522 | 0,993  |
|          | 4 | 0,994  | 0,995   | $1,370 \cdot 10^{-3}$ | 0,984  | 0,996  |
| <b>3</b> | 1 | -0,682 | -0,690  | $3,763 \cdot 10^{-2}$ | -0,725 | -0,556 |
|          | 2 | -0,575 | -0,623  | $2,602 \cdot 10^{-1}$ | -0,718 | 0,995  |
|          | 3 | -0,211 | -0,439  | $5,450 \cdot 10^{-1}$ | -0,688 | 0,996  |
|          | 4 | 0,832  | 0,995   | $4,174 \cdot 10^{-1}$ | -0,518 | 0,996  |

Fonte: Dados da pesquisa.

Mais uma vez, através dos dados da Tabela 29, observa-se que há desvio padrão elevado para os dados do coeficiente de Spearman. Explica-se novamente o observado através do rápido crescimento do coeficiente de Spearman dentro de um mesmo quadrante, associado aos diferentes números de sessões de treinamentos alcançados pelos experimentos.

Bem como nos experimentos realizados na planta do Forno de Pelotização, os dados apontam pouca efetividade na avaliação pelo Coeficiente de Pearson durante a avaliação do treinamento. Isto deve-se ao fato de que o coeficiente não apresenta padrão claro de crescimento ou decréscimo, conforme observado na Tabela 30.



Tabela 30 – Dados sumarizados das observações do coeficiente de Pearson no controle MNFEL EQM na planta Serpentina de Refrigeração.

| Conf. | Q | Média  | Mediana | Desv. Pad.      | Mínimo | Máximo |
|-------|---|--------|---------|-----------------|--------|--------|
| 1     | 1 | 0,9962 | 0,9960  | $1,259.10^{-3}$ | 0,9943 | 0,9998 |
|       | 2 | 0,9982 | 0,9982  | $8,365.10^{-4}$ | 0,9959 | 0,9997 |
|       | 3 | 0,9992 | 0,9996  | $8,953.10^{-4}$ | 0,9972 | 0,9998 |
|       | 4 | 0,9981 | 0,9979  | $8,123.10^{-4}$ | 0,9971 | 0,9998 |
| 2     | 1 | 0,9960 | 0,9960  | $9,447.10^{-4}$ | 0,9944 | 0,9982 |
|       | 2 | 0,9986 | 0,9987  | $7,414.10^{-4}$ | 0,9964 | 0,9998 |
|       | 3 | 0,9996 | 0,9997  | $2,682.10^{-4}$ | 0,9984 | 0,9998 |
|       | 4 | 0,9979 | 0,9976  | $5,660.10^{-4}$ | 0,9972 | 0,9996 |
| 3     | 1 | 0,9956 | 0,9955  | $9,543.10^{-4}$ | 0,9942 | 0,9989 |
|       | 2 | 0,9979 | 0,9980  | $1,060.10^{-3}$ | 0,9955 | 0,9998 |
|       | 3 | 0,9992 | 0,9995  | $6,114.10^{-4}$ | 0,9973 | 0,9998 |
|       | 4 | 0,9990 | 0,9991  | $6,596.10^{-4}$ | 0,9976 | 0,9998 |

Fonte: Dados da pesquisa.


#### 5.4.2.5 Relação entre EQM e coeficientes de correlação da generalização

Os valores finais de EQM, obtidos na planta a partir do controle MNFEL, são correlacionados aos coeficientes de correlação finais. Busca-se verificar a presença ou ausência de uma correlação, direta ou inversa, entre os dados.

Diferentemente da análise realizada para a planta Forno de Pelotização, para a planta *Cooling Coil* optou-se por não exibir informação do coeficiente de Pearson, dado que este não foi utilizado na avaliação da métrica, exceto para indicar a proximidade de uma relação linear entre os dados.

Através dos gráficos da Figura 50 faz-se clara a distinção entre os dados coletados a partir dos controles com critério pelo desvio padrão e por EQM. Os dados deste estão mais próximos de 1, com EQM menor, enquanto os dados obtidos com critério de parada pelo desvio padrão se concentram na porção negativa do coeficiente de correlação.


Figura 50 – Dispersão dos EQMs finais pelos coeficientes de Spearman finais para os experimentos FEL na planta *Cooling Coil*.



Fonte: Dados da pesquisa.

Pelos gráficos da Figura 51 vê-se que o mesmo efeito observado nos experimentos FEL é presente nos experimentos MNFEL. Nos dois experimentos, o que se observa é que o coeficiente de correlação não tem um efeito claramente tendencioso dado um erro quadrático médio, o que leva à constatação de que a métrica proposta, apesar de indicar se o papel das redes foi desempenhado de acordo com o esperado, não pode ser utilizada para aferir a qualidade do controle produzido pela estratégia.

Figura 51 – Dispersão dos EQMs finais pelos coeficientes de Spearman finais para os experimentos MNFEL na planta *Cooling Coil*.



Fonte: Dados da pesquisa.

É importante enfatizar, portanto, que a utilização do coeficiente de Spearman na avaliação durante o treinamento tem finalidade diferente das métricas clássicas da teoria de controle, não podendo substituir a utilização destas na avaliação de um sistema de controle.

## 6 Conclusão

Este trabalho apresentou uma proposta de métricas de avaliação das estratégias *Feedback-Error-Learning* (FEL) e *Multi-Network-Feedback-Error-Learning* (MNFEL) como um mecanismo capaz de permitir ao especialista acompanhar o desempenho específico das redes neurais dentro do sistema de controle. Tais métricas são uma alternativa aos métodos usuais de avaliação que são voltados para a avaliação global da estratégia de controle. As métricas propostas são inspiradas em um trabalho anterior (RIBEIRO, 2009) no qual utiliza-se apenas o coeficiente de Pearson para o acompanhamento do progresso da rede neural durante o treinamento.

Durante o presente trabalho fez-se uma abrangente análise do comportamento desse coeficiente em sistemas de controle visando identificar pontos falhos dessa estratégia. A pesquisa realizada previamente supôs condições de funcionamento que não estavam de acordo com a relação entre a ação do controlador e o erro da planta. No entanto, o presente trabalho demonstrou os fatores de insucesso: dados anteriores ao degrau; e a presença de relação não-linear entre os dados estudados.

Desta forma, a avaliação pelo método anterior do coeficiente de Pearson não se mostrou capaz de apontar efetivamente a correlação entre os dados, podendo levar a conclusões precipitadas sobre o sistema em análise. Propôs-se, por conseguinte, que a avaliação seja realizada utilizando o coeficiente de correlação de postos de Spearman, somente após o degrau da referência. A proposta envolve o cálculo do coeficiente entre o erro quadrático da planta – para evitar que a oscilação entre positivo e negativo influencie demais na correlação – e a ação de controle do controlador PID. Isto é, diferentemente do proposto anteriormente: cálculo do coeficiente de Pearson entre o erro da planta e ação de controle do PID.

O estudo aponta a necessidade da identificação inicial da relação da planta e do controlador convencional, isto é, anterior à aplicação da estratégia de controle inteligente. A partir da relação inicial, pode-se estimar como será a relação futura com a compensação fornecida pelas redes neurais. Sendo assim, é na identificação inicial que se define o comportamento esperado do coeficiente de Spearman, que é utilizado para apontar êxito, ou não, no desempenho do papel das redes no processo.

A proposta foi testada a partir da aplicação das estratégias FEL e MNFEL em duas diferentes plantas: Forno de Pelotização e Serpentina de Refrigeração. Estas plantas foram escolhidas devido a sua não-linearidade e por terem sido utilizadas em trabalhos relacionados com estratégias FEL e variantes. Os resultados dos experimentos estiveram de acordo com o esperado: com padrões de crescimento quando a relação inicial entre

o erro quadrático da planta e a ação de controle do PID é não-linear; ou decréscimo quando a relação inicial entre essas variáveis é linear. Sendo que essa etapa é realizada na identificação inicial.

O coeficiente de Spearman obteve padrão decrescente na planta do Forno de Pelotização – conforme esperado dado que a relação inicial da planta e do controlador convencional é linear – indicando que as redes compensaram pela eventual não-linearidade, melhorando assim as métricas de controle.

Na planta da Serpentina de Refrigeração, onde a relação inicial é não-linear, os experimentos FEL e MNFEL com critério por EQM obtiveram padrão crescente – conforme esperado – para o coeficiente de Spearman. Similarmente, como para o caso da planta do Forno de Pelotização, houve compensação pela não-linearidade e melhoria no controle. No entanto, devido o padrão crescente do coeficiente de Spearman, obteve-se uma mudança da relação entre o erro quadrático e as ações de controle, que era inicialmente não-linear, para uma relação linear.

Adicionalmente, ressalta-se que os valores dos coeficientes de Spearman – durante o treinamento das redes neurais – podem antecipar que o uso dessas redes não irá melhorar substancialmente o controle do sistema. Nomeadamente no caso da planta da Serpentina de Refrigeração com critério de inserção e parada pelo desvio padrão do erro da planta, onde não houve melhoria evidente no controle.

Assim sendo, constata-se que as métricas propostas são capaz de avaliar a contribuição das redes neurais para as estratégias de controle FEL e MNFEL, conforme idealizado.

Em trabalhos futuros, pretende-se investigar o comportamento da métrica em diferentes plantas de modo a estender a literatura e aferir o funcionamento do método em outras condições, por exemplo na presença de distúrbio. Pode-se também investigar diferentes padrões iniciais de relação, visando tornar mais preciso o processo de estimação do comportamento esperado ao longo do treinamento.

Diferentes métodos de cálculo de correlação podem ser abordados em trabalhos futuros. Outros padrões de referência, além de degrau, devem ser testados, visto que a métrica pode ser influenciada por estes devido o efeito do erro.

A métrica aqui proposta pode ser adaptada e experimentada, para investigações futuras, em outros sistemas de controle inteligente inspirados na estratégia FEL.

# Referências

- ALMEIDA NETO, A. *Aplicações de Múltiplas Redes Neurais em Sistemas Mecatrônicos*. Tese (Doutorado) — Instituto Tecnológico de Aeronáutica, São José dos Campos, SP, Brasil, 2003. Citado 5 vezes nas páginas 17, 18, 33, 34 e 36.
- ALMEIDA NETO, A.; GOES, L. C. S.; NASCIMENTO, C. L. Accumulative learning using multiple ann for flexible link control. *IEEE Transactions on Aerospace and Electronic Systems*, IEEE, v. 46, n. 2, p. 508–524, Abril 2010. ISSN 0018-9251. Citado 4 vezes nas páginas 18, 35, 42 e 43.
- ASTROM, K. J.; HAGGLUND, T. *PID Controllers: Theory, Design, and Tuning*. 2<sup>a</sup>. ed. [S.l.]: Instrument Society of America, 1995. 353 p. ISBN 1-55617-516-7. Citado na página 26.
- CHIANG, C.-H. A genetic programming based rule generation approach for intelligent control systems. In: *2010 International Symposium on Computer, Communication, Control and Automation (3CA)*. [S.l.]: IEEE, 2010. v. 1, p. 104–107. ISSN 2324-7983. Citado na página 17.
- CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, Springer, v. 2, n. 4, p. 303–314, Dezembro 1989. ISSN 1435-568X. Citado na página 30.
- DONMEZ, B.; PINA, P. E.; CUMMINGS, M. Evaluation criteria for human-automation performance metrics. In: MADHAVAN, R.; TUNSTEL, E.; MESSINA, E. (Ed.). *Performance Evaluation and Benchmarking of Intelligent Systems*. Boston, MA, EUA: Springer, 2009. p. 21–40. ISBN 978-1-4419-0492-8. Citado 2 vezes nas páginas 19 e 42.
- ERDOGMUS, D.; FONTENLA-ROMERO, O.; PRINCIPE, J. C.; ALONSO-BETANZOS, A.; CASTILLO, E. Linear-least-squares initialization of multilayer perceptrons through backpropagation of the desired response. *IEEE Transactions on Neural Networks*, IEEE, v. 16, n. 2, p. 325–337, Março 2005. ISSN 1045-9227. Citado na página 32.
- EVANS, J. M.; MESSINA, E. R. Performance metrics for intelligent systems. In: *Proceedings of a NIST conference on Performance Metrics for Intelligent Systems*. Gaithersburg, MD, EUA: NATIONAL INSTITUTE OF STANDARDS & TECHNOLOGY, 2001. p. 101–104. Citado 2 vezes nas páginas 18 e 19.
- EVERITT, B.; SKRONDAL, A. *The Cambridge dictionary of statistics*. 4<sup>a</sup>. ed. [S.l.]: Cambridge University Press Cambridge, 2010. 480 p. ISBN 978-0-521-76699-9. Citado na página 37.
- FRANKLIN, G.; POWELL, J. D.; EMANI-NAEINI, A. *Sistemas de Controle para Engenharia*. 6<sup>a</sup>. ed. [S.l.]: Bookman, 2013. 702 p. ISBN 978-85-8260-067-2. Citado 3 vezes nas páginas 25, 26 e 28.
- GOMI, H.; KAWATO, M. Learning control for a closed loop system using feedback-error-learning. In: *29th IEEE Conference on Decision and Control*. Honolulu, HI, EUA: IEEE, 1990. v. 6, p. 3289–3294. Citado 3 vezes nas páginas 17, 18 e 33.

HAFEZ, W. Approach for defining intelligent systems technical performance metrics. In: NIST. *2012 Proceedings of the Workshop on Performance Metrics for Intelligent Systems*. [S.l.]: National Institute of Standards and Technology, 2012. p. 41–46. Citado 2 vezes nas páginas 19 e 42.

HAMID, M.; JAMIL, M.; BUTT, S. I. Intelligent control of industrial robotic three degree of freedom crane using artificial neural network. In: *2016 IEEE Information Technology, Networking, Electronic and Automation Control Conference*. Chongqing, China: IEEE, 2016. p. 113–117. ISBN 978-1-4673-9194-8. Citado na página 17.

HAUKE, J.; KOSSOWSKI, T. Comparison of values of pearson's and spearman's correlation coefficients on the same sets of data. *Quaestiones geographicae*, Bogucki Wydawnictwo Naukowe, v. 30, n. 2, p. 87–93, 2011. ISSN 0137-477X. Citado na página 38.

JIN, G.-Y.; CAI, W.-J.; WANG, Y.-W.; YAO, Y. A simple dynamic model of cooling coil unit. *Energy Conversion and Management*, Elsevier, v. 47, n. 15, p. 2659–2672, 2006. ISSN 0196-8904. Citado na página 50.

KADRI, M. B. Robust model free fuzzy adaptive controller with fuzzy and crisp feedback error learning schemes. In: IEEE. *Control, Automation and Systems (ICCAS), 2012 12th International Conference on*. [S.l.]: IEEE, 2012. p. 384–388. Citado na página 51.

KADRI, M. B.; DEXTER, A. L. Disturbance rejection in information-poor systems using an adaptive model-free fuzzy controller. In: *NAFIPS 2009 - 2009 Annual Meeting of the North American Fuzzy Information Processing Society*. Cincinnati, OH, EUA: IEEE, 2009. p. 1–6. ISBN 978-1-4244-4575-2. Citado na página 51.

KAWATO, M.; FURUKAWA, K.; SUZUKI, R. A hierarchical neural-network model for control and learning of voluntary movement. *Biological Cybernetics*, v. 57, n. 3, p. 169–185, Oct 1987. ISSN 1432-0770. Citado na página 33.

MAN, K. F.; TANG, K. S. Genetic algorithms for control and signal processing. In: *Industrial Electronics, Control and Instrumentation, 1997. IECON 97. 23rd International Conference on*. [S.l.]: IEEE, 1997. v. 4, p. 1541–1555. ISBN 0-7803-3932-0. Citado na página 30.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943. Citado na página 30.

MINSKY, M.; PAPER, S. *Perceptrons: An Introduction to Computational Geometry*. [S.l.]: MIT Press, 1969. 316 p. ISBN 0262630222. Citado na página 30.

MIYAMOTO, H.; KAWATO, M.; SETOYAMA, T.; SUZUKI, R. Feedback-error-learning neural network for trajectory control of a robotic manipulator. *Neural Networks*, Elsevier, v. 1, n. 3, p. 251–265, 1988. ISSN 0893-6080. Citado 2 vezes nas páginas 17 e 33.

MIYAMURA, A.; KIMURA, H. Stability of feedback error learning scheme. *Systems & Control Letters*, Elsevier, v. 45, n. 4, p. 303–316, 2002. ISSN 0167-6911. Citado na página 17.

- MOORE, C.; HETTHESSY, J.; BARS, R. Control modes - closed-loop response. In: LIPTÁK, B. G. (Ed.). *Instrument Engineers' Handbook: Process Control and Optimization*. 4<sup>a</sup>. ed. [S.l.]: CRC Press, 2006. v. 2<sup>o</sup>, cap. 2.5, p. 135–147. ISBN 0-8493-1081-4. Citado na página 26.
- MORAES, S. L. d.; KAWATRA, S. K. Avaliação do uso de combinações de aglomerantes na pelotização de concentrado de magnetita pela tecnologia de aglomeração em tambor (balling drum). *Tecnologia em Metalurgia Materiais e Mineração*, ABM, v. 8, p. 168–173, 2011. ISSN 2176-1523. Citado na página 49.
- MORÉ, J. J. The levenberg-marquardt algorithm: implementation and theory. In: WATSON, G. A. (Ed.). *Numerical Analysis*. Berlin, Heidelberg: Springer, 1978. p. 105–116. ISBN 978-3-540-35972-2. Citado na página 32.
- NAKANISHI, J.; SCHAAL, S. Feedback error learning and nonlinear adaptive control. *Neural Networks*, Elsevier, v. 17, n. 10, p. 1453–1465, 2004. ISSN 0893-608. Citado na página 17.
- NARENDRA, K.; GALLMAN, P. An iterative method for the identification of nonlinear systems using a hammerstein model. *IEEE Transactions on Automatic Control*, IEEE, v. 11, n. 3, p. 546–550, Julho 1966. ISSN 0018-9286. Citado na página 50.
- NASCIMENTO, C. L. *Artificial neural networks in control and optimization*. Tese (Doutorado) — Universidade de Manchester, Manchester, GB, 1994. Citado na página 34.
- NAZARI, M.; GHAFFARI, A. Modeling and analysis of cooling coil for control system design using gray box approach. *Modern Applied Science*, Canadian Center of Science and Education, v. 10, n. 10, p. 23, 2016. ISSN 1913-1852. Citado na página 50.
- OGATA, K. *Engenharia de Controle Moderno*. 5<sup>a</sup>. ed. [S.l.]: Pearson Prentice Hall, 2011. 824 p. ISBN 978-85-7605-810-6. Citado 4 vezes nas páginas 22, 23, 24 e 28.
- PASSINO, K. M. Intelligent control: An overview of techniques. In: SAMAD, T. (Ed.). *Perspectives in Control Engineering: Technologies, Applications, and New Directions*. 1<sup>a</sup>. ed. [S.l.]: Wiley-IEEE Press, 2001. cap. 5, p. 104–133. ISBN 9780470545485. Citado na página 30.
- PEARSON, K. Vii. note on regression and inheritance in the case of two parents. In: *Proceedings of the Royal Society of London*. [S.l.]: Royal Society of London, 1895. v. 58, n. 347-352, p. 240–242. ISSN 0370-1662. Citado na página 38.
- RIBEIRO, P. R. A. *Múltiplas Redes Neurais Artificiais para Controle do Forno da Usina de Pelotização da Vale em São Luís*. 47 p. Monografia (Bacharelado em Ciência da Computação) — Universidade Federal do Maranhão, São Luís, MA, Brasil, 2009. Citado 8 vezes nas páginas 18, 20, 37, 40, 42, 43, 51 e 90.
- RIBEIRO, P. R. A.; ALMEIDA NETO, A.; OLIVEIRA, A. C. M. Multi-network-feedback-error-learning in pelletizing plant control. In: *2010 2nd International Conference on Advanced Computer Control*. Shenyang, China: IEEE, 2010. v. 2, p. 340–344. ISBN 978-1-4244-5848-6. Citado 7 vezes nas páginas 18, 35, 36, 42, 43, 50 e 56.

RIBEIRO, P. R. A.; COSTA, T. S.; BARROS, V. H.; ALMEIDA NETO, A.; OLIVEIRA, A. C. M. Feedback-error-learning in pelletizing plant control. In: *VII Encontro Nacional de Inteligência Artificial - ENIA*. Bento Gonçalves, RS, Brasil: UFRGS, 2009. p. 879–888. Citado 6 vezes nas páginas 17, 18, 42, 49, 50 e 56.

RODOR, F. F.; PUGLIESE, L. F.; PEREIRA, R. L.; GUARACY, F. H. D.; KOZAN, R. F. Controle de posição de pessoas híidas utilizando feedback error learning. In: *Proceedings of XIII Simpósio Brasileiro de Automação Inteligente*. [S.l.]: SBA, 2017. p. 1184–1189. Citado 2 vezes nas páginas 17 e 42.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, American Psychological Association, v. 65, n. 6, p. 386–408, 1958. Citado na página 30.

SANDERSON, C.; CURTIN, R. Armadillo: a template-based c++ library for linear algebra. *Journal of Open Source Software*, Journal of Open Source Software, 2016. Citado na página 20.

SHARMA, S.; KUMAR, V.; RANA, K. P. S. Pneumatic control valve stiction modeling using artificial neural network. In: *2017 International Conference on Emerging Trends in Computing and Communication Technologies (ICETCCT)*. [S.l.]: IEEE, 2017. p. 1–6. ISBN 978-1-5386-1147-0. Citado na página 17.

SPEARMAN, C. The proof and measurement of association between two things. *The American Journal of Psychology*, University of Illinois Press, v. 15, n. 1, p. 72–101, Janeiro 1904. ISSN 00029556. Citado na página 38.

TAKAHASHI, K.; ISAKA, A.; FUDABA, T.; HASHIMOTO, M. Remarks on quaternion neural network-based controller trained by feedback error learning. In: *2017 IEEE/SICE International Symposium on System Integration (SII)*. [S.l.]: IEEE, 2017. p. 875–880. ISBN 978-1-5386-2263-6. ISSN 2474-2325. Citado 2 vezes nas páginas 17 e 43.

TAN, W. W. *Self-learning Neurofuzzy Control of Non-linear Systems*. Tese (Doutorado) — Universidade de Oxford, Oxford, Inglaterra, 1997. Citado na página 17.

THEERAKULPISUT, S.; PRIPREM, S. Modeling cooling coils. *International Communications in Heat and Mass Transfer*, Elsevier, v. 25, n. 1, p. 127–137, 1998. ISSN 0735-1933. Citado na página 50.

VANSOVITS, V.; TEPLJAKOV, A.; VASSILJEVA, K.; PETLENKOV, E. Towards an intelligent control system for district heating plants: Design and implementation of a fuzzy logic based control loop. In: *2016 IEEE 14th International Conference on Industrial Informatics (INDIN)*. [S.l.]: IEEE, 2016. p. 405–410. ISBN 978-1-5090-2870-2. ISSN 2378-363X. Citado na página 17.

VYATKIN, V. Software engineering in industrial automation: State-of-the-art review. *IEEE Transactions on Industrial Informatics*, v. 9, n. 3, p. 1234–1249, Agosto 2013. ISSN 1551-3203. Citado na página 17.

WANG, S. Dynamic simulation of building vav air-conditioning system and evaluation of emcs on-line control strategies. *Building and Environment*, Elsevier, v. 34, n. 6, p. 681–705, 1999. ISSN 0360-1323. Citado na página 50.



WERBOS, P. *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Tese (Doutorado) — Universidade de Harvard, Cambridge, MA, EUA, 1975. Citado na página 30.

WHITE, D. A.; SOFGE, D. A. *Handbook of Intelligent Control: Neural, Fuzzy, and Adaptive Approaches*. [S.l.]: Van Nostrand Reinhold, 1992. 250 p. ISBN 0442308574. Citado na página 30.

WU, Y.; DEXTER, A. Modelling capabilities of fuzzy relational models. In: *Fuzzy Systems, 2003. FUZZ '03. The 12th IEEE International Conference on*. [S.l.]: IEEE, 2003. v. 1, p. 430–435. ISBN 0-7803-7810-5. Citado 2 vezes nas páginas 50 e 51.

YAMAGUCHI, S.; ITAKURA, H. A modular neural network for control of mobile robots. In: *Neural Information Processing, 1999. Proceedings. ICONIP '99. 6th International Conference on*. [S.l.]: IEEE, 1999. v. 2, p. 661–666. ISBN 0-7803-5871-6. Citado na página 35.