FERNANDO GUIMARÃES AGUIAR

UTILIZAÇÃO DE REDES NEURAIS ARTIFICAIS PARA DETECÇÃO DE PADRÕES DE VAZAMENTO EM DUTOS

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do Título de Mestre em Engenharia Mecânica.

Área de Concentração: Térmica e Fluidos

Orientador: Prof. Tit. Paulo Seleghim Júnior

São Carlos

2010

FOLHA DE JULGAMENTO

Candidato(a): Engenheiro **FERNANDO GUIMARÃES AGUIAR.**

Dissertação defendida e julgada em 23/07/2010 perante a Comissão Julgadora:

Prof. Titular **PAULO SELEGHIM JUNIOR – (Orientador)** — Aprovado
(Escola de Engenharia de São Carlos/USP)

Dr. **MARCELO FERNANDO SELLI** — APROVADO
(INSELLI/Mselli Engenharia e Consultoria Ltda)

Dr. **PAULO ROBERTO BARBOSA** — Aprovado
(Instituto Federal de Educação, Ciência e Tecnologia de São Paulo)

Prof. Associado **JONAS DE CARVALHO**
Coordenador do Programa de Pós-Graduação em
Engenharia Mecânica

Prof. Titular **GERALDO ROBERTO MARTINS DA COSTA**
Presidente da Comissão da Pós-Graduação da EESC

DEDICATÓRIA

"A minha amada mãe Márcia Guimarães, com muito carinho, admiração e gratidão e a minha querida irmã Carolina pelo eterno amor fraternal incentivo e admiração"

AGRADECIMENTOS

Agradeço primeiramente a Deus, por suas bênçãos e por me dar força e confiança para superar as dificuldades encontradas.

À minha admirável Mãe, pelo esforço árduo para prover a excelência em estudo para mim, além do imenso amor e carinho incondicional em todos os momentos da minha vida.

A minha irmã Carolina, pelo incentivo e por ser uma fonte de inspiração e incentivo para superar dificuldades, sempre me tratando com muito amor e carinho e também ao meu cunhado Guilherme.

Ao meu professor orientador Paulo Seleghim Júnior, pela orientação durante este trabalho e pelos ensinamentos de vida durante os 6 anos de convivência.

Ao meu querido avô Messias e minha querida avó Jovenilia (*in memoriam*) pelo amor e carinho em toda minha vida.

Aos meus tios e tias Antônio, Célia, Marden, Janete, Bakkar, Silvia e a todos os outros que mesmo distante me incentivaram e apoiaram em todos os momentos.

Aos meus amigos e amigas Ennes, Camila, Celi, Amauri, Gustavo Rodrigo, Thais, Elma Ize, Marcus, Carlos Eduardo, Fabrício, Ulisses, Tang, Leonardo, Diorginer, José Robeto, Alisson Gallo, Frederico Ribeiro e à todos, que mesmo longe sempre estiveram presentes em minha vida, me apoiando, ajudando e incentivando com muitos momentos de alegria e companheirismo.

Ao engenheiro Jorge Nicolau, aos técnicos Roberto Prata e Luchesi e à todos os funcionários do NETeF, pelos ensinamentos, colaboração e incentivo neste trabalho.

À Escola de Engenharia de São Carlos – Universidade de São Paulo, pela oportunidade de continuar e desenvolver meus estudos.

À todos os professores e colegas de departamento, que ajudaram na execução e conclusão deste trabalho.

Enfim, a todos que tiveram envolvido direta ou indiretamente para o desenvolvimento dessa dissertação, os meus sinceros agradecimentos.

“É muito melhor arriscar coisas grandiosas, alcançar triunfos e glórias, mesmo expondo-se a derrota, do que formar fila com os pobres de espírito que nem gozam muito nem sofrem muito, porque vivem nessa penumbra cinzenta que não conhece vitória nem derrota.”

Theodore Roosevelt

RESUMO

AGUIAR, F. G. (2010). Utilização de redes neurais artificiais para detecção de padrões de vazamentos em oleodutos. *Dissertação de Mestrado em Engenharia Mecânica, Escola de Engenharia de São Carlos – Universidade de São Paulo*.

O presente trabalho tem como objetivo principal o desenvolvimento de um sistema de identificação do surgimento de vazamentos (rupturas) em dutos, através da análise do sinal de sensores de pressão de resposta rápida (frequência de corte superior a 1 kHz). O reconhecimento do sinal de vazamento se realiza através de uma rede neural artificial *feed-foward* do tipo *Perceptron* Multi Camadas, previamente treinada. Neste trabalho, a implementação para tal operação foi feita *off-line*, mas devido ao baixo custo computacional pode ser facilmente implementada em eletrônica embarcada, em tempo real (*on-line*). Os resultados experimentais foram obtidos no oleoduto piloto do NETeF – Núcleo de Engenharia Térmica e Fluidos da USP – Universidade de São Paulo, com uma seção de testes com 1500 metros e diâmetro de 51,2 mm. Especificamente, os resultados foram obtidos com escoamento monofásico de água. Os resultados mostram-se promissores, visto que o sistema de redes neurais artificiais foi capaz de discriminar 2 universos linearmente separáveis, para sinais de vazamento e de não vazamento, para diversas vazões e localizações de vazamentos simulados.

Palavras-chave: Detecção de vazamento. Processamento de sinais. Redes neurais artificiais. Instrumentação.

ABSTRACT

AGUIAR, F. G. (2010). The use of artificial neural networks for pattern detection of leaks in pipelines. *MSc. Dissertation in Mechanical Engineering, Escola de Engenharia de São Carlos – Universidade de São Paulo*.

The present dissertation deals with the development of a system to recognize abrupt leaks (ruptures) in pipelines, by analyzing the signal of fast response pressure sensors (cutoff frequency over then 1kHz). The recognition of the leak signal is established by an artificial neural network feed-forward Perceptron Multi Layer, previously trained. In the present work the implementation was performed off-line, but due to low computational costs, the neural network can be easily implemented in real time embedded electronics (online). The experimental results were obtained in a 1500 meter-long and 51.2 millimeter-diameter pilot pipeline at the Center of Thermal Engineering and Fluids. Specifically, the results were obtained with single-phase flow of water. The results have proven to be promising, as the trained neural network was capable of classifying the 2 types of signals into 2 linearly separable regions, for leakage signals and no leakage signals, for various flow rates and locations of simulated leaks.

Keywords: Leak detection. Signal processing. Artificial neural networks. Instrumentation.

LISTA DE FIGURAS

Figura 1 - Modelo do neurônio artificial. 33
Figura 2 – Modelo do *Perceptron* e sua correlação com o neurônio de McCulloch e Pitts. ... 35
Figura 3 - *Perceptron Multicamadas.* (Figura Adaptada de SILVA (2008)). 38
Figura 4 - Foto do Oleoduto Piloto Trifásico do NETeF/USP. 47
Figura 5 - Representação Esquemática do Oleoduto Piloto Trifásico do NETeF/USP. 48
Figura 6 - Arquitetura da Aplicação do CompactRIO. 49
Figura 7 - Topologia de Conexão do Sistema CompactRIO. 50
Figura 8 - Tela do *software* em LabVIEW® que é executado em um computador do tipo PC. 51
Figura 9 - Tela do *software* em LabVIEW® que é executado no controlador de tempo real (NI cRIO 9014). 52
Figura 10 - Tela do *software* em LabVIEW® que é executado em FPGA (NI cRIO 9114). .. 52
Figura 11 - Temporizações programáveis do *software* para execução automática dos experimentos. 53
Figura 12 - Processo para obtenção de resultados. 56
Figura 13 - Sinal Experimental de Simulação de Vazamento. 58
Figura 14 - Componente AC dos Sinais Experimentais de Simulação de Vazamento da Figura 13. 59
Figura 15 - Detalhe nos Sinais de Abertura de Válvula das Simulações de Vazamento da Figura 14. 60
Figura 16 - Transformada de Fourier para o Sinal Vazamento (Abertura de Válvula) Exemplificado na Figura 15. 61
Figura 17 - Exemplo de Visualização Gráfica das Saídas da RNA. 64
Figura 18 - Tangente Hiperbólica Sigmóide. 65
Figura 19 - Topologia de RNA *Perceptron* Implementada. 67
Figura 20 - Curvas de Aprendizagem para Neurônios na Camada Escondida Iguais a 3, 5, 10 e 20. 68
Figura 21 - Classificação dos Dados Utilizados para Treinamento da RNA com N1 = 10. 69
Figura 22 - Histograma de Erro Quadrático Médio Absoluto dos Dados Utilizados para Treinamento da RNA com N1 = 10. 70

Figura 23 - Classificação dos Dados Utilizados para Validação Cruzada (Teste) da RNA com N1 = 10. 71
Figura 24 - Histograma de Erro Quadrático Médio Absoluto dos Dados Utilizados para Validação Cruzada (Teste) da RNA com N1 = 10. 71
Figura 25 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 5%. 73
Figura 26 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 5% de ruído (Freq. Inversor de 40Hz; P2; S2). 73
Figura 27 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 10%. 74
Figura 28 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 10% de ruído (Freq. Inversor de 40Hz; P2; S2). 74
Figura 29 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 20%. 75
Figura 30 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 20% de ruído (Freq. Inversor de 40Hz; P2; S2). 75
Figura 31 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 30%. 76
Figura 32 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 30% de ruído (Freq. Inversor de 40Hz; P2; S2). 76
Figura 33 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 40%. 77
Figura 34 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 40% de ruído (Freq. Inversor de 40Hz; P2; S2). 77
Figura 35 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 50%. 78
Figura 36 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 50% de ruído (Freq. Inversor de 40Hz; P2; S2). 78
Figura 37 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 60%. 79
Figura 38 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 60% de ruído (Freq. Inversor de 40Hz; P2; S2). 79
Figura 39 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 70%. 80

Figura 40 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 70% de ruído (Freq. Inversor de 40Hz; P2; S2). 80
Figura 41 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 80%. 81
Figura 42 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 80% de ruído (Freq. Inversor de 40Hz; P2; S2). 81
Figura 43 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 90%. 82
Figura 44 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 90% de ruído (Freq. Inversor de 40Hz; P2; S2). 82
Figura 45 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 100%. 83
Figura 46 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 100% de ruído (Freq. Inversor de 40Hz; P2; S2). 83
Figura 47 - Diagrama de Blocos do *software* em LabVIEW® que é executado em um computador do tipo PC..... 93
Figura 48 - Diagrama de Blocos do *software* em LabVIEW® que é executado no controlador de tempo real (NI cRIO 9014)..... 94
Figura 49 - Diagrama de Blocos do *software* em LabVIEW® que é executado em FPGA (NI cRIO 9114)..... 95

LISTA DE TABELAS

Tabela 1 - Posições Relativas dos Transdutores à Bomba de Água. 54
Tabela 2 - Posições Relativas das Válvulas Solenóides (Vazamentos). 55
Tabela 3 - Relação entre Simulação de Vazamento e Aquisição de Sinal. 56

LISTA DE ABREVIATURAS E SIGLAS

ASCII	American Standard Code for Information Interchange
ANP	Agência Nacional de Petróleo
CAN	Controller Area Network
cRIO	Compact RIO ®
EESC	Escola de Engenharia de São Carlos
FPGA	Field Programmable Gate Array
Hz	Hertz
IA	Inteligência Artificial
I/O	Input and Output
NETeF	Núcleo de Engenharia Térmica e Fluidos
NI	National Instruments ®
PAC	Programmable Automation Controller
PC	Personal Computer
PMC	Perceptron Multi Camada
RBF	Radial Basis Function
RNA	Rede Neural Artificial
RTOS	Real Time Operational System
RTTM	Real Time Transient Modeling
SCADA	Supervisory Control and Data Acquisition
USP	Universidade de São Paulo

LISTA DE SÍMBOLOS

d_j	Valor desejado para j-ésimo neurônio de saída da RNA
$E(t)$	Erro da saída da RNA
$E(k)$	Erro quadrático para k-ésimo vetor de entrada da RNA
$E_M(k)$	Erro quadrático médio para k-ésimo vetor de entrada da RNA
f_{MAX}	Máxima freqüência contida em um sinal
f_{SMIN}	Freqüência de Nyquist
f_S	Freqüência de amostragem
g( )	Função de ativação da RNA
Il_j	Valor da entrada ponderada do *j-ésimo* neurônio da camada l
MEDIA_Pl( )	Media do vetor Pl( )
$\dot{m}_e$	Vazão mássica a montante
m_p	Inventário do duto (massa contida no duto)
$\dot{m}_s$	Vazão mássica a jusante
Nl	Número de neurônios da l-ésima camada da RNA
Pl( )	Vetor Discreto do sinal de pressão adquirido no experimento
Pl_AC( )	Componente AC do vetor Pl( )
Pl_DEC( )	Vetor Pl_AC( ) decimado
Wl_{ji}	Valor do peso sináptico conectado ao j-ésimo neurônio da camada l ao i-ésimo neurônio da camada (l-1);
X	Vetor de entradas da RNA
x_i	i-ésima entrada da RNA
y^d	Vetor de saída desejada da RNA
$y(x)$	Vetor de saída calculada da RNA
Yl	Vetor de saída da l-ésima camada da RNA
ε	Limiar
δl_j	Gradiente local para l-ésima camada neural, referente ao j-ésimo neurônio
η	Fator de Aprendizagem

SUMÁRIO

RESUMO 11
ABSTRACT 13
1. INTRODUÇÃO 27
1.1. Objetivos 28
2. REVISÃO BIBLIOGRÁFICA 29
2.1. Métodos de Detecção de Vazamentos em Dutos 29
2.2. Redes Neurais Artificiais 32
2.2.1. Breve Histórico das Redes Neurais Artificiais 34
2.2.2. Rede Perceptron Multicamadas e Algoritmo de Treinamento Backpropagation 37
3. METODOLOGIA 47
3.1. Circuito Experimental 47
3.1.1. Oleoduto Piloto e Instrumentação 47
3.1.2. Sistema de Controle e Aquisição de Dados 49
3.2. Aquisição de Dados Experimentais 50
3.3. Aplicação de Redes Neurais Artificiais para Detecção de Vazamentos em Dutos ... 56
3.3.1. Sistema de Controle e Aquisição de Dados 57
3.3.2. Pré-processamento do Sinal Adquirido 57
3.3.3. Treinamento da RNA com Sinais Experimentais 62
3.3.3.1. Classificação dos Sinais para Treinamento da RNA 62
3.3.3.2. Topologia da RNA Utilizada 64
3.3.4. Validação Cruzada do Treinamento da RNA 65
3.3.5. Toolbox de Rede Neural Artificial – MATLAB® 66
4. TESTES E RESULTADOS EXPERIMENTAIS 67
4.1. Interferência de Ruído no Sinal de Entrada 72
5. CONCLUSÕES E PERSPECTIVAS 85
REFERÊNCIAS BIBLIOGRÁFICAS 87
APÊNDICE A – Diagrama de Blocos dos programas em LabVIEW® para Controle da Planta e Aquisição de dados nos experimentos 93

1. INTRODUÇÃO

O transporte de petróleo e seus derivados em dutos (oleodutos, gasodutos e polidutos) é uma maneira eficiente e econômica, quando se compara os custos de transporte de petróleo pela malha rodoviária, ferroviária ou marítima, especialmente em longas distâncias. A utilização de dutos para transporte de produtos petroquímicos não é recente. Em 1872 foi inaugurado o primeiro duto para transporte de gás nos Estados Unidos da América, no estado da Pensilvânia, com 8 km de extensão e 2” de diâmetro.

No Brasil, a construção de oleoduto teve início na década de 40, sendo que a década de 80 se caracterizou pelo grande número de projetos e construção de gasodutos no Brasil, devido ao aumento da utilização de gás natural na indústria.

Todavia, deve-se ressaltar que os riscos associados ao transporte de petróleo em dutos são muito altos. Um vazamento ou rompimento da tubulação pode acarretar danos irreparáveis ao meio ambiente, em especial se o duto é construído em regiões alagadas, submersas ou em reservas ambientais. Quanto ao aspecto financeiro, um levantamento da Agência Nacional de Petróleo (ANP) estima-se que o prejuízo oriundo do vazamento de 1 metro cúbico de petróleo supera R$ 100.000,00. Ressalta-se também que a lei brasileira de crimes ambientais, que vigora sob o decreto de número 3.179 de 21 de setembro de 1999, é severa com multas que podem chegar a até R$ 50.000.000,00.

Segundo Papadakis, Porter e Wetting (1999), as principais causas de acidentes em oleodutos e gasodutos estão ligadas a falhas operacionais, corrosão, movimentação do solo, fenômenos naturais e ações externas não intencionais ou não autorizadas (ligações clandestinas, por exemplo).

Neste contexto, diversas técnicas para detecção de vazamentos em dutos vêm sendo pesquisadas, a fim de evitar e/ou diminuir danos ao meio ambiente e perdas econômicas. Entretanto, destaca-se a citação de Stouffs e Michel (1993): “Nenhum método de detecção de vazamento é universalmente aplicável e os requisitos operacionais ditam qual é o método mais eficaz para o processo. Em geral, o ideal é utilizar mais de um sistema independente de detecção de vazamento em oleodutos importantes”, que mesmo escrita há 17 anos continua válida e atual.

1.1.Objetivos

Neste trabalho uma técnica de detecção de vazamentos abruptos através da análise do sinal transiente de pressão (propagação acústica do sinal de vazamento), que utiliza uma rede neural artificial para identificar padrões de vazamento no sinal transiente de pressão é aplicada a um duto com escoamento monofásico líquido.

Em específico, pretende-se identificar uma arquitetura de rede neural artificial, que seja treinada para classificar e diferenciar padrões de vazamentos e de não-vazamentos, que são obtidos experimentalmente, em regiões linearmente separáveis.

2. REVISÃO BIBLIOGRÁFICA

Neste capítulo é apresentada uma revisão bibliográfica sobre os tópicos envolvidos neste trabalho, destacando-se o histórico e metodologias de detecção de vazamentos em dutos e o histórico e topologias de redes neurais artificiais.

2.1.Métodos de Detecção de Vazamentos em Dutos

Problemas de corrosão, fadiga, falhas de soldas, mudanças repentinas na pressão e ações de terceiros podem afetar a integridade de um duto e provocar vazamentos de diversas proporções, e de acordo com o produto transportado, isso pode representar graves prejuízos ambientais, além da perda econômica. Diante disso, várias técnicas de detecção de vazamentos em dutos têm sido propostas e podendo estas ser classificadas em três categorias, segundo Khomairi (2008): observacionais, baseados em *hardwares* e baseados em *softwares*.

Os sistemas de detecção de vazamentos baseados em métodos observacionais são os mais simples para realizar a detecção de vazamento, consistindo basicamente da inspeção visual (podendo utilizar câmeras de segurança, inspeções aéreas, utilização de câmeras infra-vermelhos). Estes métodos são muito dependentes do fator humano e são geralmente aplicáveis em dutos de pequeno comprimento que estão expostos em regiões de fácil acesso.

Os métodos de detecção baseados em *softwares* são sistemas com um custo maior e requerem uma grande capacidade de processamento, e isso torna a utilização proibitiva em oleodutos curtos. Comumente, um sistema de controle e aquisição de dados (do inglês *Supervisory Control and Data Acquisition* – SCADA) é usado para capturar dados do processo, como pressão, vazão, temperatura, densidade, dentre outros e então, os dados são analisados para detectar possíveis vazamentos em oleodutos. Destacam-se os métodos de balanço de massa, análise do transiente fluido dinâmico, análise inversa de transientes, análise da transformada *wavelet* e métodos de modelagem matemática em tempo real.

Quanto ao método de balanço de massa, segundo Stouffs e Michel (1993) um vazamento pode ocorrer quando o erro da computação do balanço de massa for superior ao limiar $\boldsymbol{\varepsilon}$**,** sendo a computação do erro do balanço de massa dada pela Equação 1.

$$\left|\dot{m}_e - \dot{m}_s - \frac{dm_p}{dt}\right| \geq \varepsilon \qquad (1)$$

Onde $\dot{m}_e$ e $\dot{m}_s$ são os fluxos de massa na entrada e saída do duto e o termo $\frac{dm_p}{dt}$ descreve a variação do inventário do duto (do inglês, *line pack*). Matematicamente é simples a teoria do balanço de massa, todavia, o desafio é calcular o inventário do duto, devido a difícil modelagem da densidade do líquido de acordo com as variações de pressão e temperatura, que ocorrem tanto na direção longitudinal quanto na direção radial do duto, e também, tem-se a incerteza dos instrumentos de medição de massa nas extremidades do duto. Dentre as características do método de balanço de massa, destaque para o limite de detecção proporcional a vazão do duto (tipicamente 2%) e o grande tempo de resposta para detecção de vazamentos pequenos, podendo ser superior a 8 horas.

Segundo Wang, et al. (2002), o método de análise do transiente fluidodinâmico baseia-se no fato de que o evento de vazamento gera um sinal transiente amortecido. Esse transiente fluidodinâmico pode ser modelado em termos de uma série de Fourier. A magnitude de cada termo da série de Fourier se reflete na dimensão do vazamento e, através da análise da taxa de amortecimento dos termos das componentes da série de Fourier, pode-se estimar a posição do vazamento.

A análise inversa de transientes é uma metodologia aplicável a tubulações onde possa reproduzir um escoamento em regime permanente. É realizada a modelagem da tubulação e o vazamento na tubulação pode ser tratado como um problema inverso, através da modelagem de vazão ou pressão. A área equivalente de possíveis orifícios de vazamentos é utilizada como variável desconhecida na formulação do problema inverso. A área é calculada através da minimização entre a variável de processo media e o valor ideal calculado. Para minimização pode ser utilizado algoritmos de cálculo numérico convencionais, como no estudo de Liggett e Chen (1994), onde foi aplicado o algoritmo de Levenberg-Marquardt em uma rede de distribuição de água, ou podem ser utilizados algoritmos genéticos como exemplificado no trabalho de Wu e Sage (2006).

A aplicação de transientes em dutos pode também ser utilizada para detecção de vazamento. O método de resposta ao impulso é usado para resolver diretamente as equações governantes de transiente de fluxo em dutos pressurizados, Analisando o domínio da freqüência. Para tal, é calculado o espectro de freqüências de sensores de pressão piezométricos, comumente localizados em uma das extremidades de um duto. O espectro é constituído de dois termos principais, sendo o primeiro relacionado as características do sistema e outra relacionado as características do impulso (manobra utilizada para gerar o transiente). Em 2003, Ferrante e Brunone (2003) demonstraram que o vazamento pode ser detectado analisando a ocorrência de descontinuidades no tempo, que podem ser atribuídas ao sinal de vazamento refletido pelas ondas de pressão.

Métodos de detecção de vazamentos baseados em modelagem de transientes em tempo real (equação de conservação da massa, quantidade de movimento e energia associada a equação de estado do escoamento), do inglês, *Real Time Transient Modeling* (RTTM), são compostos por um sistema eletrônico para aquisição de dados de pressão e vazão em ambas extremidades de um segmento de duto. Um modelo de tempo real simula os transientes de pressão e vazão da tubulação utilizando equações de regime transiente. Então, utiliza-se uma das grandezas medidas nas extremidades (pressão ou vazão) como condição de contorno para calcular a outra grandeza modelada. O método analisa a variação de pressão e vazão entre os valores medidos e os valores modelados matematicamente e um desvio nesse cálculo pode ser atribuído a um vazamento. Esse desvio obtido é utilizado para estimar vazão do vazamento. Destaque para o trabalho de Hemande et al. (1995), que desenvolveu um sistema RTTM para um duto de etileno.

Quanto aos métodos de detecção baseados em *hardware*, são utilizados diferentes dispositivos eletrônicos para detecção e localização de um vazamento, podendo ser classificados de acordo com o princípio de detecção. Destacam-se os métodos de detecção de ondas de pressão negativa e sistemas acústicos de detecção de vazamento.

A detecção de vazamento através de onda de pressão negativa é baseada no fato de que no instante da ocorrência do vazamento há uma queda de pressão abrupta no local do vazamento, até que se atinja um novo perfil de pressão no duto, ou um novo regime de pressão estacionário. O recente trabalho de Li e Sun (2009), formaliza a metodologia para detecção de vazamento através de onda de pressão negativa e apesar de não relacionar os falsos alarmes, demonstra bons resultados quanto à detecção e localização de vazamentos, detectando vazamentos de 2% da vazão do duto e precisão de localização de 98%.

Os métodos acústicos de detecção de vazamento utilizam o fato de que na ocorrência do vazamento é gerado um transiente acústico, o qual é propagado através de estruturas e fluidos ao longo da tubulação, podendo esse sinal ser captado por sensores acústicos, ou sensores de pressões de resposta rápida (comumente sensores de pressão piezoelétricos ou piezoresistivos com freqüência de corte superior a 1 kHz). Todavia o transiente acústico é atenuado ao propagar-se ao longo da tubulação e para uma boa sensibilidade na detecção dos vazamentos, os sensores acústicos devem ser estrategicamente posicionados tão próximos quanto possível. São requeridas técnicas de processamento de sinal para extrair informações características do sinal de vazamento para então, classificar o sinal como vazamento ou sinal de operação normal da tubulação. Este método propicia a localização do vazamento, caso seja possível obter o tempo exato da detecção do sinal nos diferentes sensores acústicos ao longo da tubulação.

Neste trabalho é abordado o método acústico de detecção de vazamento, sendo que é proposto uma rede neural artificial, previamente treinada que seja capaz de extrair as características de um sinal de vazamento e distingui-lo de sinais operacionais do escoamento.

2.2. Redes Neurais Artificiais

Sistemas baseados em Inteligência Artificial (IA) tem sido desenvolvidos e demonstrado resultados promissores e flexíveis, tal como nos trabalhos de Simões (2000), para a classificação robusta à variação de grandezas como iluminação ou brilho da cor para aplicação em futebol de robôs; Goedtel (2007), desenvolvendo um estimador neural de velocidade de motores de indução trifásico a partir de variáveis primárias de tensão e corrente; Selli (2007), para identificação de regimes de escoamentos bifásicos com um classificador neural analisando a transformada de Gabor do sinal de pressão; Gaspar (2006) desenvolvendo um identificador de faces humanas utilizando redes neurais artificiais; dentre inúmeros outros trabalhos, sendo aplicáveis a diversas áreas de engenharia, representando um domínio de pesquisa multidisciplinar, envolvendo além de engenharia, física, matemática, biologia, neurofisiologia, etc.

Dentre as ferramentas que constituem a IA destacam-se os Algoritmos Genéticos, Lógica Difusa e Redes Neurais Artificiais (FILIPATTI F., *et al.*, 2000), sendo que este trabalho tem a utilização focada em Redes Neurais Artificiais (RNA).

Conforme descrito por Selli e Seleghim (2007), em uma análise matemática, as RNA podem ser definidas como um mapeamento não linear de um vetor de espaço de entrada para um vetor de espaço de saída, que pode ser feito através de camadas de funções de ativação ou neurônios, nos quais coordenadas de entrada são somadas de acordo com o valor de seus respectivos pesos e “bias” para produzir uma saída simples, ativada ou não, de acordo com o respectivo nível de disparo.

É importante salientar que essa análise matemática tem sua inspiração biológica, pois o cérebro é constituído por unidades funcionais, denominadas neurônios, que emitem impulsos elétricos em resposta a estímulos, tal como salientado por Timoszczuk (2004). Essas unidades são densamente interconectadas, resultando em uma arquitetura altamente complexa. Inspirados nessa arquitetura complexa, vários modelos matemáticos de neurônios artificiais foram desenvolvidos, refletindo o conhecimento biológico sobre o funcionamento do cérebro humano (TAGLIARINI G. A., *et al.*, 1991).

Segundo Guyon (1991), o neurônio artificial é uma estrutura lógico-matemática que procura simular a forma, comportamento e funções de um neurônio biológico. Assim, os dendritos são substituídos por entradas, cujas ligações com o corpo celular artificial são realizadas através de elementos chamados de peso (simulando as sinapses neuronais). Os estímulos são captados pelas entradas e processados pela função de soma e o bias. O limiar de disparo do neurônio biológico tem como analogia a função de transferência no neurônio artificial (CHUA L.O.; YANG L., 1988). A Figura 1 exibe uma representação do neurônio artificial.

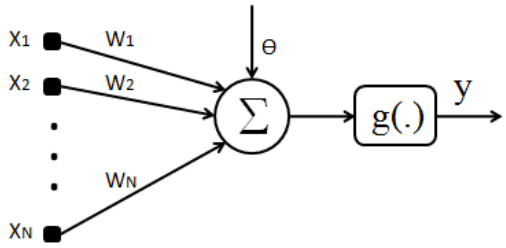

Figura 1 - Modelo do neurônio artificial.

2.2.1. Breve Histórico das Redes Neurais Artificiais

As pesquisas sobre Redes Neurais datam de 1943 (PICCININI G., 2004) por McCulloch (fisiologista) e Pitts (matemático) em um trabalho pioneiro, consistindo num estudo sobre o comportamento do neurônio biológico objetivando a criação do modelo matemático correspondente, com a interpretação do funcionamento do neurônio como sendo um circuito binário (MCCULLOCH W. S.; PITTS W. H., 1943). O modelo matemático do neurônio de McCulloch e Pittts é capaz de separar duas entradas *booleanas*, todavia não é possível treinar os neurônios, pois não possuem parâmetros livres. McCulloch e Pitts não desenvolveram nenhum método para adaptar os pesos do neurônio em um processo de treinamento ou aprendizagem.

Uma contribuição importante ocorreu em 1949 de autoria do neuro-psicologista Donnald Hebb (TEES R. C., 2002). Hebb propôs uma lei de aprendizagem específica para a sinapse dos neurônios, demonstrando que a capacidade de aprendizagem das redes neurais vem da alteração da eficiência sináptica, isto é, a conexão é reforçada somente se tanto as células pré-sinápticas quanto as pós-sinápticas estiverem excitadas, tal como citado no livro de Russell e Norvig em 1995 (RUSSELL S. J., NORVIG P., 1995). A Equação 2 expressa matematicamente o enunciado da lei de aprendizagem de Hebb.

$$\nabla W_i = \eta \cdot x_i \cdot y(x) \qquad (2)$$

Onde η é o fator de aprendizagem, x_i a i-ésima entrada do neurônio (valor do neurônio pré-simpático) e $y(x)$ é o valor do neurônio pós-simpático.

Outra contribuição de grande importância nas pesquisas com redes neurais foi a concepção do modelo denominado *Perceptron*, por Rosenblatt (1958), que consistia em um modelo cognitivo de unidades sensoriais (entradas) conectadas a uma única camada de neurônios tal como o modelo de McCulloch e Pitts, acrescidos de sinapses ajustáveis. Utilizando a lei de aprendizagem de Hebb, Rosenblatt demonstrou que essas redes poderiam ser treinadas para classificar padrões de classes linearmente separáveis – o que é uma grande limitação para utilização prática (GUYON I., 1991). A Figura 2 apresenta o modelo do neurônio *Perceptron* e sua correlação com o neurônio proposto por McCulloch e Pitts.

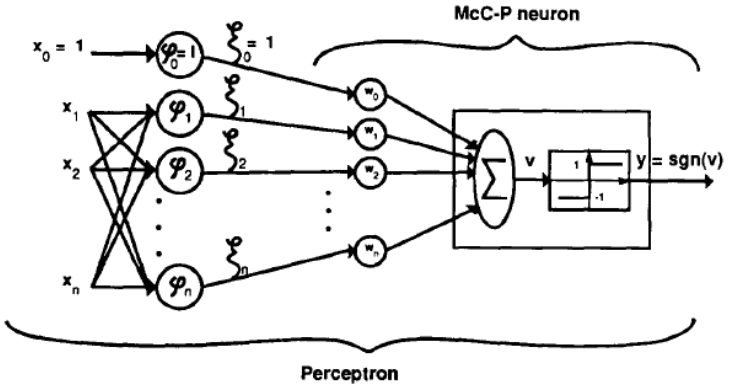

Figura 2 – Modelo do *Perceptron* e sua correlação com o neurônio de McCulloch e Pitts. (Figura adaptada de GUYON I., 1991).

Ainda em 1960, uma grande contribuição de Widrow e Hoff foi uma variação do algoritmo de aprendizagem do *Perceptron* (WIDROW B.; LEHR M. A., 1990), aplicando o conceito do erro médio quadrático, formulando o modelo Adaline, acrônimo do inglês (*Adaptative Linear Element*, podendo ser traduzido por Elemento Linear Adaptativo). Neste modelo proposto por Widrow, o ajuste dos pesos da rede é realizado através de uma aproximação linear do cálculo do gradiente de uma função de erro quadrática, atualmente conhecida como "Regra Delta" ou "Regra de Widrow-Hoff". A Equação 3 expressa matematicamente o enunciado da Regra de Widrow-Hoff.

$$E(t) = \left(y^{d} - y(x)\right) \tag{3}$$

$$W(t+1) = W(t) - \eta \frac{\partial E(t)}{\partial t} \tag{4}$$

Onde t é a iteração do treinamento, η é o fator de aprendizagem, y^{d} é a saída desejada, $y(x)$ é a saída do neurônio, $W(t)$ são os pesos na iteração t e $\frac{\partial E(t)}{\partial t}$ é o gradiente do erro na iteração t.

Apesar do otimismo a respeito da capacidade de aprendizagem e reconhecimento de padrões das redes neurais propostas por Rosenblatt, Widrow, dentre outros, em 1969 Marvin Minsky, juntamente com Seymour Papert publicaram sua monografia que refletiam o

ceticismo dos autores quanto aos conceitos das redes *Perceptron* e Adaline (KELEMEN J., 2007). Na monografia, Minsky e Papert provaram alguns teoremas matemáticos a respeito dos limites do treinamento proposto por Rosenblatt e Widrow. Uma ilustração simples é que os modelos *Perceptron* e *Adaline* não são capazes de resolver dois operadores lógicos cruciais "OU EXCLUSIVO" e "NÃO OU EXCLUSIVO" (BORCHARDT F. L., 1988). Segundo Timoszczuk (2004), a publicação de Minsky e Papert colocou que não havia motivo aparente que redes formadas por múltiplas camadas de *Perceptron* ou *Adaline* pudessem superar as limitações e ainda herdar as boas características das redes simples. Tais argumentos desmotivaram substancialmente os pesquisadores e reduziram drasticamente as pesquisas sobre RNA nas décadas de 70 e 80.

Apesar da considerável redução nas pesquisas sobre RNA nas décadas de 70 e 80, ocorreram notáveis contribuições, podendo ser destacado o surgimento das redes auto-organizáveis utilizando algoritmos competitivos não supervisionados. Em 1973 Von del Marlsburg apresentou um trabalho pioneiro, demonstrando o princípio da auto-organização (MALSBURG V. D., 1973) e juntamente com Willshaw, publicaram em 1976 um artigo sobre a formação das redes auto-organizáveis (WILLSHAW D. J.; MALSBURG V. D., 1976).

Ainda na década de 70, outra importante contribuição foram os estudos pioneiros de Kohonen (KOHONEN T., 1972), Reid e Frame (REID R. J.; FRAME J. S., 1975) no desenvolvimento de modelos e métodos de convergência mapas auto-organizados também conhecidos como "Mapa de Kohonen", sendo uma nova topologia de RNA que utiliza aprendizado não-supervisionado. Os mapas de Kohonen produzem uma representação discretizada "clusterizada" do universo de entrada, chamado mapas, muito conveniente para representar dados de várias dimensões em um universo de poucas dimensões. Assim, os mapas de Kohonen são capazes de descobrir padrões ou características específicas nos dados de entrada sem a interferência do usuário.

Na década de 80, juntamente com o advento de computadores com maior capacidade de cálculo, ocorreu um novo impulso nas pesquisas de redes neurais. Destaca-se as pesquisas de Carpenter e Grossberg (1980), com a introdução dos conceitos da rede neural *Adaptative Resonance Theory* (ART) (CARPENTER G. A.; GROSSBERG S., 1988), sendo uma rede auto-organizável cujo princípio é a auto-definição dos seus parâmetros, sendo mais uma rede de aprendizado não supervisionado. A primeira versão da rede ART proposta foi a rede ART1 que trabalhava apenas com valores binário. Posteriormente foi desenvolvida a rede ART2, cujos valores de entradas são contínuos. Têm sido desenvolvidas diversas sofisticações e

variações do modelo ART, como ART3, *Fuzzy-ART*, *Fuzzy-MAP*, dentre outros (CASTRO A. P. A.; SILVA J. D. S., 2002).

Em 1982, outro trabalho de grande relevância com enfoque pioneiro em redes recorrentes (HOPFIELD J. J., 1982), utilizando a idéia da minimização da função de energia, apresentando uma rede, normalmente com camada única, com conexões retro-alimentadas entre os neurônios. Deve-se ressaltar que a função de energia deve ser associada a função objetivo e também as restrições físicas e matemáticas do problema a ser resolvido.

Deve-se enfatizar que a década de 80 teve o ápice das pesquisas de Redes Neurais Artificiais com o desenvolvimento do algoritmo *backpropagation* (ou retro-propagação – em português), formalizado por Rumelhart, Hinton e Williams (RUMELHART D. E., *et al.*, 1986) propiciando o treinamento de redes *Perceptron* Multi-camadas resultando em uma rede com grande poder de generalização, possibilitando a implementação de diversas aplicações, idealizadas até então. Destaque para o trabalho de Broomhead com a implementação de redes neurais com funções de base radial (do inglês *radial basis functions* (RBF)), com excelente capacidade de aproximação (HUNT K. J., *et al*., 1996).

2.2.2. Rede Perceptron Multicamadas e Algoritmo de Treinamento Backpropagation

As redes *Perceptron* Multicamadas (PMC), são caracterizadas pela presença de múltiplas camadas de unidades básicas de processamento do tipo *Perceptron* (GUYON I., 1991). O incremento de mais camadas neurais implica em um aumento na capacidade de processamento não linear e generalização da rede neural. Assim, foram superadas as limitações para o modelo do *Perceptron* e Adaline por Minsky e Papert em 1969.

A rede PMC é composta minimamente por 1 camada de entrada e 1 camada de neurônios de saída, sendo que entre essas camadas podem conter inúmeras camadas intermediárias, também denominadas de camadas escondidas. Cada camada pode conter inúmeros neurônios *Perceptrons*, sendo que as saídas dos neurônios de cada camada são as entradas dos neurônios da cama sub-sequente, desde a camada de entrada, até a camada de saída. Neste tipo de rede não há retro-alimentações, pois a propagação do processamento neural é unidirecional.

As redes PMC possuem treinamento supervisionado, sendo que o algoritmo de treinamento visa ajustar os pesos da rede para, a partir de um conjunto conhecido de vetores de entrada para obter da rede um conjunto de saídas desejadas. A Figura 3 exemplifica uma rede *Perceptron* Multicamadas.

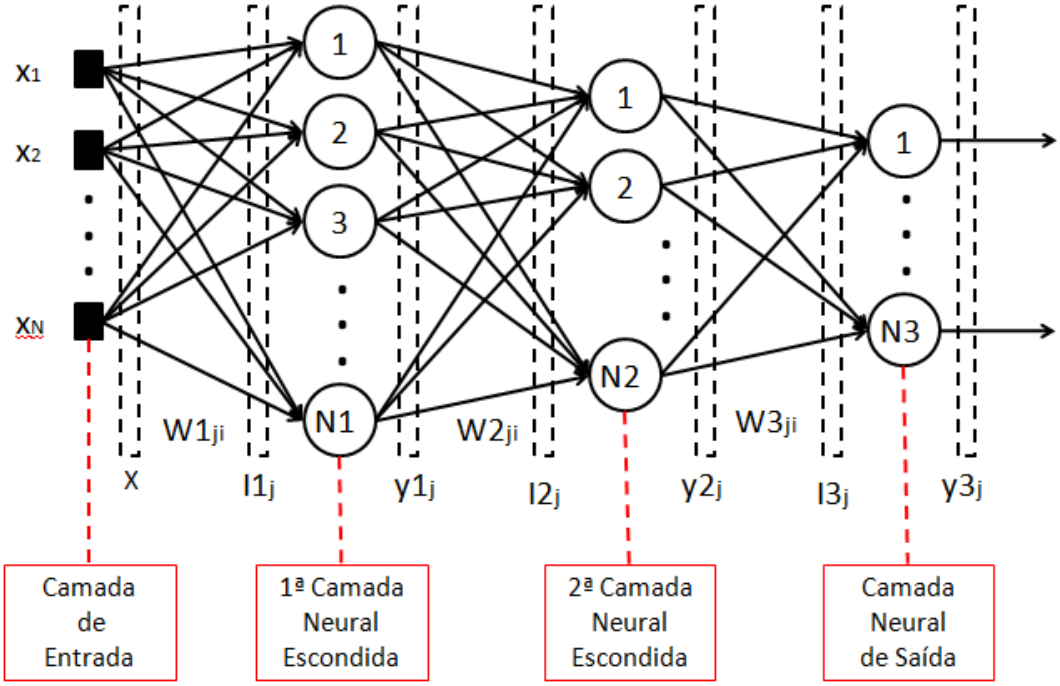

Figura 3 - *Perceptron Multicamadas.* (Figura Adaptada de SILVA (2008))[1].

Na Figura 3 tem-se a seguinte simbologia:

- **N**: Número de pontos do vetor de entrada **X**;
- **X**: Vetor de entrada da rede: $X = [-1, x_1, x, \dots, x_N]^T$;
- **W_{ji}^{l}**: Valor do peso sináptico conectado ao ***j**-ésimo* neurônio da camada **l** ao ***i**-ésimo* neurônio da camada (**l-1**); Ressalta-se que nesta convenção o valor do peso **W_{j0}^{l}**, para todos valores de **l** e ***j***, teremos o valor do *bias* (ou limiar) de cada neurônio;
- **I_j^{l}**: Valor da entrada ponderada do ***j**-ésimo* neurônio da camada **l**. Assim:

$$I1_j = \sum_{i=0}^{N} W1_{ji} \cdot X_i; \qquad \text{para } j = 1..N1 \qquad (5)$$

$$I2_j = \sum_{i=0}^{N1} W2_{ji} \cdot y1_i; \qquad \text{para } j = 1..N2 \qquad (6)$$

[1] Figura Adaptada das notas de aula da disciplina SEL5712 – Redes Neurais Artificiais, ministrada pelo professor Tit. Dr. Ivan Nunes da Silva em 2008.

$$I3_j = \sum_{i=0}^{N2} W3_{ji} \cdot y2_i; \qquad \text{para } j = 1..N3 \qquad (7)$$

Generalizando para ***l*** camadas, teremos:

$$Il_j = \sum_{i=0}^{N[l-1]} Wl_{ji} \cdot y[l-1]_i; \qquad \text{para } j = 1..Nl \qquad (8)$$

- **yl_j**: Valor da saída do ***j-ésimo*** neurônio da camada **l**. Assim:

$$y1_j = g(I1_j); \qquad \text{para } j = 1..N1 \qquad (9)$$

$$y2_j = g(I2_j); \qquad \text{para } j = 1..N2 \qquad (10)$$

$$y3_j = g(I3_j); \qquad \text{para } j = 1..N3 \qquad (11)$$

Generalizando para ***l*** camadas, teremos:

$$yl_j = g(Il_j); \qquad \text{para } j = 1..Nl \qquad (12)$$

- **g( ):** Função de ativação do neurônio.

Para treinamento das redes PMC é utilizado o treinamento supervisionado através do algoritmo *backpropagation*, onde é apresentado à rede um conjunto de treinamento da rede neural, com pares de entrada e saída conhecidos. O vetor de entrada é propagado camada a camada, até a camada de saída. O vetor de saída da rede é então comparado ao vetor de saída desejado, sendo a diferença entre ambas saídas (calculada e desejada) o erro de saída da rede.

Esse erro é então retropropagado na rede, a fim de ajustar os pesos sinápticos para que a próxima iteração o erro de saída seja reduzido. Esse processo é repetido para todos os pares do conjunto de treinamento da rede, até que o erro de saída aceitável seja atingindo, e assim, a condição de parada do treinamento.

As funções de erro empregadas como critério de parada do processo de treinamento são: Erro Quadrático – que fornece o valor instantâneo da soma dos erros quadráticos do

padrão de treinamento de todos os neurônios da camada de saída –, e Erro Quadrático Médio – obtido a partir da soma dos erros quadráticos relativos a todos os padrões de entrada utilizados no conjunto de treinamento. A Equação (13) expressa matematicamente o Erro Quadrático para uma RNA com *m* camadas, enquanto a Equação (14) expressa matematicamente o Erro Quadrático Médio para um conjunto de treinamento com *p* pares de vetores de entrada e saída desejadas.

$$E(k) = \frac{1}{2}\sum_{j=1}^{Nm}(d_j(k) - ym_j(k))^2 \tag{13}$$

$$E_M = \frac{1}{p}\sum_{k=1}^{p} E(k) \tag{14}$$

Logo, o objetivo do processo de treinamento *backpropagation* é ajustar a matriz de pesos sinápticos da rede (matriz Wl_{ji}), visando minimizar o Erro Quadrático Médio. Esse ajuste é divido em 2 casos: Ajuste dos pesos dos neurônios da camada de saída; Ajustes dos pesos dos neurônios das camadas escondidas.

Desenvolvendo o método *backpropagation* para a rede PMC da Figura 3, teremos:

- **Ajuste dos pesos dos neurônios da camada de saída:**

Ajustam-se os pesos da camada de saída (3ª camada neural) a partir da minimização da função de erro quadrático médio em relação aos pesos $W3_{ji}$. Utilizando a regra de diferenciação em cadeia, tem-se:

$$\nabla E(W3_{ji}) = \frac{\partial E}{\partial W3_{ji}} = \frac{\partial E}{\partial y3_j} \cdot \frac{\partial y3_j}{\partial I3_j} \cdot \frac{\partial I3_j}{\partial W3_{ji}} \tag{15}$$

$$\frac{\partial I3_j}{\partial W3_{ji}} = y2_i \tag{16}$$

$$\frac{\partial y3_j}{\partial I3_j} = g'(I3_j) \tag{17}$$

$$\frac{\partial \mathrm{E}}{\partial \mathrm{y3_j}} = -(\mathrm{d_j} - \mathrm{y3_j}) \tag{18}$$

Tendo ∀ *g( )* uma função monótona, a derivada de 1ª ordem não alterna de sinal em todo o domínio. Assim, substituindo as Equações (16), (17) e (18) em (15), tem-se:

$$\frac{\partial \mathrm{E}}{\partial \mathrm{W3_{ji}}} = -(\mathrm{d_j} - \mathrm{y3_j}) \cdot g'(I3_j) \cdot y2_i \tag{19}$$

Para minimização, o ajuste deve ser realizado oposto ao gradiente do erro $\nabla \mathrm{E}(\mathrm{W3_{ji}})$.

$$\Delta \mathrm{W3_{ji}} = -\eta \cdot \frac{\partial \mathrm{E}}{\partial \mathrm{W3_{ji}}} = \eta \cdot \delta 3_\mathrm{j} \cdot y2_i \tag{20}$$

Onde:

$$\delta 3_\mathrm{j} = (\mathrm{d_j} - \mathrm{y3_j}) \cdot g'(I3_j) \tag{21}$$

Sendo η a taxa de aprendizagem do algoritmo *backpropagation* e $\delta 3_\mathrm{j}$ é definido como gradiente local.

Assim, em uma análise temporal, teremos:

$$\mathrm{W3_{ji}}(\mathrm{t}+1) = \mathrm{W3_{ji}}(\mathrm{t}) + \Delta \mathrm{W3_{ji}}(\mathrm{t}) = \mathrm{W3_{ji}}(\mathrm{t}) + \eta \cdot \delta 3_\mathrm{j} \cdot y2_i \tag{22}$$

- **Ajuste dos pesos dos neurônios das camadas escondidas:**

  - **Ajuste para 2ª Camada Neural**

Ajustam-se os pesos da 2ª camada neural a partir da minimização da função de erro quadrático médio em relação aos pesos $W2_{ji}$. Utilizando a regra de diferenciação em cadeia, tem-se:

$$\nabla E(W2_{ji}) = \frac{\partial E}{\partial W2_{ji}} = \frac{\partial E}{\partial y2_j} \cdot \frac{\partial y2_j}{\partial I2_j} \cdot \frac{\partial I2_j}{\partial W2_{ji}} \tag{23}$$

$$\frac{\partial I2_j}{\partial W2_{ji}} = y1_i \tag{24}$$

$$\frac{\partial y2_j}{\partial I2_j} = g'(I2_j) \tag{25}$$

$$\frac{\partial E}{\partial y2_j} = \sum_{k=1}^{N3} \frac{\partial E}{\partial I3_k} \cdot \frac{\partial I3_k}{\partial y2_j} \tag{26}$$

Substituindo a Equação (7) em (26), teremos:

$$\frac{\partial E}{\partial y2_j} = \sum_{k=1}^{N3} \frac{\partial E}{\partial I3_k} \cdot \frac{\partial\left(\sum_{i=0}^{N2} W3_{kj} \cdot y2_j\right)}{\partial y2_j} = \sum_{k=1}^{N3} \frac{\partial E}{\partial I3_k} \cdot W3_{kj} \tag{27}$$

Substituindo as Equações (17) e (18) em (27), teremos:

$$\frac{\partial E}{\partial y2_j} = \sum_{k=1}^{N3} \frac{\partial E}{\partial I3_k} \cdot W3_{kj} = \sum_{k=1}^{N3} \left(\frac{\partial E}{\partial y3_k} \cdot \frac{\partial y3_k}{\partial I3_k}\right) \cdot W3_{kj}$$
$$= -\sum_{k=1}^{N3} \delta 3_k \cdot W3_{kj} \tag{28}$$

Substituindo as Equações (24), (25) e (28) em (23), tem-se:

$$\nabla E(W2_{ji}) = \left(-\sum_{k=1}^{N3} \delta 3_k \cdot W3_{kj}\right) \cdot g'(I2_j) \cdot y1_i \quad (29)$$

Para minimização, o ajuste deve ser realizado oposto ao gradiente do erro $\nabla E(W2_{ji})$.

$$\Delta W2_{ji} = -\eta \cdot \frac{\partial E}{\partial W2_{ji}} = \eta \cdot \delta 2_j \cdot y1_i \quad (30)$$

Onde:

$$\delta 2_j = \left(\sum_{k=1}^{N3} \delta 3_k \cdot W3_{kj}\right) \cdot g'(I2_j) \quad (31)$$

Sendo η a taxa de aprendizagem do algoritmo *backpropagation* e $\delta 2_j$ é definido como gradiente local.

Assim, em uma análise temporal, teremos:

$$W2_{ji}(t+1) = W2_{ji}(t) + \Delta W2_{ji}(t) = W2_{ji}(t) + \eta \cdot \delta 2_j \cdot y1_i \quad (32)$$

- **Ajuste para 1ª Camada Neural**

Ajustam-se os pesos da 1ª camada neural a partir da minimização da função de erro quadrático médio em relação aos pesos $W1_{ji}$. Utilizando a regra de diferenciação em cadeia, tem-se:

$$\nabla E(W1_{ji}) = \frac{\partial E}{\partial W1_{ji}} = \frac{\partial E}{\partial y1_j} \cdot \frac{\partial y1_j}{\partial 1} \cdot \frac{\partial I1_j}{\partial W1_{ji}} \quad (33)$$

$$\frac{\partial \mathrm{I1_j}}{\partial \mathrm{W1_{ji}}} = x_i \tag{34}$$

$$\frac{\partial \mathrm{y1_j}}{\partial \mathrm{I1_j}} = g^{'}(I1_j) \tag{35}$$

$$\frac{\partial \mathrm{E}}{\partial \mathrm{y1_j}} = \sum_{\mathrm{k=1}}^{\mathrm{N2}} \frac{\partial \mathrm{E}}{2} \cdot \frac{\partial \mathrm{I2_k}}{\partial \mathrm{y1_j}} \tag{36}$$

Substituindo a Equação (6) em (36), teremos:

$$\frac{\partial \mathrm{E}}{\partial \mathrm{y1_j}} = \sum_{\mathrm{k=1}}^{\mathrm{N2}} \frac{\partial \mathrm{E}}{\partial \mathrm{I2_k}} \cdot \frac{\partial \left(\sum_{\mathrm{i=0}}^{\mathrm{N2}} \mathrm{W2_{kj}} \cdot y1_j\right)}{\partial \mathrm{y1_j}} = \sum_{\mathrm{k=1}}^{\mathrm{N2}} \frac{\partial \mathrm{E}}{\partial \mathrm{I2_k}} \cdot \mathrm{W2_{kj}} \tag{37}$$

Substituindo as Equações (26) e (28) em (37), teremos:

$$\begin{aligned} \frac{\partial \mathrm{E}}{\partial \mathrm{y1_j}} &= \sum_{\mathrm{k=1}}^{\mathrm{N2}} \frac{\partial \mathrm{E}}{\partial \mathrm{I2_k}} \cdot \mathrm{W2_{kj}} = \sum_{\mathrm{k=1}}^{\mathrm{N2}} \left(\frac{\partial \mathrm{E}}{\partial \mathrm{y2_k}} \cdot \frac{\partial \mathrm{y2_k}}{\partial \mathrm{I2_k}}\right) \cdot \mathrm{W2_{kj}} \\ &= -\sum_{\mathrm{k=1}}^{\mathrm{N3}} \delta 2_{\mathrm{k}} \cdot \mathrm{W2_{kj}} \end{aligned} \tag{38}$$

Substituindo as Equações (34), (35) e (38) em (33), tem-se:

$$\nabla \mathrm{E}(\mathrm{W1_{ji}}) = \left(-\sum_{\mathrm{k=1}}^{\mathrm{N2}} \delta 2_{\mathrm{k}} \cdot \mathrm{W2_{kj}}\right) \cdot \mathrm{g}^{'}(\mathrm{I1_j}) \cdot \mathrm{x_i} \tag{39}$$

Para minimização, o ajuste deve ser realizado oposto ao gradiente do erro $\nabla \mathrm{E}(\mathrm{W1_{ji}})$.

$$\Delta \mathrm{W1_{ji}} = -\eta \cdot \frac{\partial \mathrm{E}}{\partial \mathrm{W1_{ji}}} = \eta \cdot \delta 1_{\mathrm{j}} \cdot x_i \tag{40}$$

Onde:

$$\delta 1_j = \left(\sum_{k=1}^{N2} \delta 2_k \cdot W2_{kj}\right) \cdot g'(I1_j) \quad (41)$$

Sendo η a taxa de aprendizagem do algoritmo *backpropagation* e $\delta 1_j$ é definido como gradiente local.

Assim, em uma análise temporal, teremos:

$$W1_{ji}(t+1) = W1_{ji}(t) + \Delta W1_{ji}(t) = W1_{ji}(t) + \eta \cdot \delta 1_j \cdot x_i \quad (42)$$

Assim, aplica-se o ajustes dos pesos da camada neural de saída e o ajustes dos pesos das camadas neurais escondidas (2ª e 1ª camada neural) seqüencialmente, até que o Erro Quadrático Médio atinja um valor desejável para a aplicação.

O algoritmo *backpropagation* pode ser sintetizado pelos seguintes passos:

- Definir conjunto de vetores de entradas ($x(k) = [-1, x_1, x_2, x_3, \dots, x_N]^T$) – com N elementos – e saídas desejadas ($d(k) = [\, d_1, d_2, d_3, \dots, d_M]^T$) – com M elementos;
- Definir os parâmetros da rede (número de camadas neurais, de neurônios, funções de ativação, parâmetros de aprendizagem, funções de erro;
- Iniciar os as matrizes de pesos $Wl_{ji;}$
- REPITA:
  - PARA CADA PAR: X(k), d(k) FAÇA:
    - Passo *forward*
      - $y1 = g(I1) = g(W1_{ji} * x_i)$ (43)
      - $y2 = g(I2) = g(W2_{ji} * y_1)$ (44)
      - ...
      - $yl = g(Il) = g(Wl_{ji} * y_{(l-1)})$ (45)
    - Passo *backward*
      - Determinar δl e ajustar Wl_{ji}

        - Determinar $\delta(l-1)$ e ajustar $W(l-1)_{ji}$
        - ...
        - Determinar $\delta 1$ e ajustar $W1_{ji}$
    - FIM PARA
    - Calcular $E_M(t)$
- ATÉ QUE $|E_M(t) - E_M(t-1)| < \varepsilon$

A cada repetição do laço REPITA do algoritmo de treinamento tem-se 1 época de aprendizagem da RNA.

3. METODOLOGIA

3.1.Circuito Experimental

Neste trabalho, todos os testes experimentais foram realizados no oleoduto piloto do laboratório do Núcleo de Engenharia Térmica e Fluidos (NETeF) – da Universidade de São Paulo (USP) em São Carlos, Brasil. Serão descritos nesta seção o oleoduto piloto e o sistema de instrumentação e aquisição de dados.

3.1.1. Oleoduto Piloto e Instrumentação

O oleoduto piloto trifásico (Figura 4) opera com misturas gás-líquido-líquido com seção de teste construída em aço galvanizado com 50,8 mm de diâmetro e comprimento útil de 1512 metros. Um sistema de tanques instalados à jusante das seções de testes é responsável pela separação primária ar-líquido e, subseqüentemente, pela separação líquido-líquido.

Figura 4 - Foto do Oleoduto Piloto Trifásico do NETeF/USP.

Bombas centrífugas controladas por inversores de freqüência de 15kW (YASKAWA CIMR-P5U2011) recirculam as fases líquidas (Figura 5). Um compressor de parafuso de 50kW assegura o suprimento de ar, cujo controle é feito através de 3 posicionadores pneumáticos de válvulas (SMAR FY301) acoplados a válvulas de controle (VALTEK P-15) instaladas em paralelo. Esta arquitetura foi adotada para permitir maiores variações de escala nas estratégias de controle de vazão.

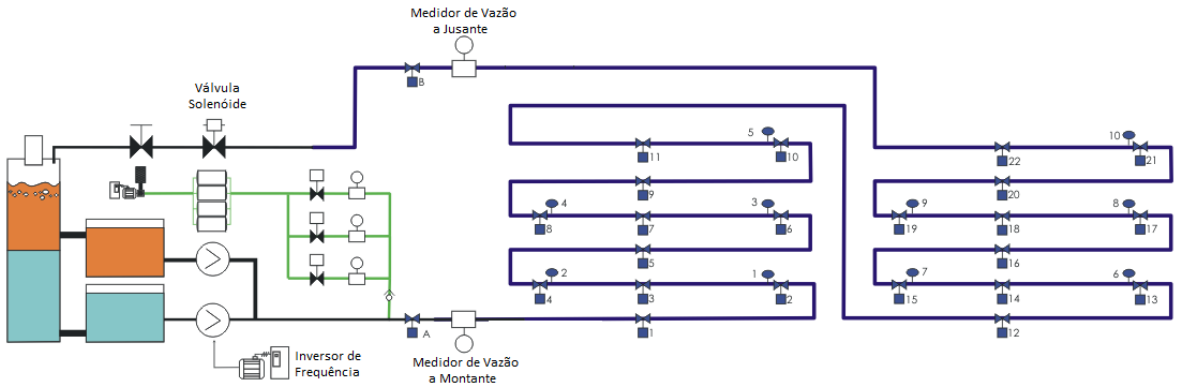

Figura 5 - Representação Esquemática do Oleoduto Piloto Trifásico do NETeF/USP.

Quanto à instrumentação do oleoduto piloto, tanto a montante quanto a jusante, estão instalados sensores e transmissores de vazão do tipo eletromagnético (ROSEMOUNT EMERSON 570TM) com fundo de escala de 23,76 m³/h (396 l/min). A instrumentação também inclui transdutores de pressão de resposta rápida (WIKA A10 com freqüência de corte superior à de 5 kHz) para medida da perda de carga e aquisição do sinal acústico do escoamento, com fundo de escala de 16 bar.

Os elementos primários de atuação (inversores de freqüência e posicionadores pneumáticos de válvulas) são acionados a partir de estações de transferência automático/manual (SMAR AM01P), que permitem o acionamento em modo manual através de seu painel frontal ou em modo automático. O equipamento retransmite proporcionalmente em escala de 4 a 20 mA o sinal de entrada, podendo ser em escala de 0 a 5V ou de 4 a 20 mA, proveniente do módulo Transdutor Atuador *Controller Area Network* (CAN) (ESEL TCAN002) com saída de 4-20 mA.

3.1.2. Sistema de Controle e Aquisição de Dados

O conjunto de sinais a serem lidos pelo sistema de aquisição de dados é composto por 10 transmissores de pressão, 2 transmissores de vazão e 22 válvulas solenóides distribuídas ao longo do duto para simulação de vazamento em posições determinadas. O sistema de controle é composto por 5 transdutores CAN/4-20mA que acionam os 2 inversores de freqüência e os 3 posicionadores pneumáticos de válvula, através da estação de transferência automático manual.

O sistema de controle e aquisição de dados é gerenciado por um Controlador de Automação Programável (do inglês *Programmable Automation Controller (PAC)*), que é um *hardware* eletrônico da *National Instruments*® (NI), denominado *CompactRIO*, sendo este um sistema de alta performance e confiabilidade. Aplicações para *CompactRIO* utilizam três processadores separados: um computador do tipo PC com sistema operacional Windows, um controlador com sistema operacional em tempo real (do inglês *Real Time Operacional System* (RTOS)) e um arranjo de portas programável em campo (do inglês *Field Programmable Gate Array* (FPGA)), tal como exemplificado na Figura 6.

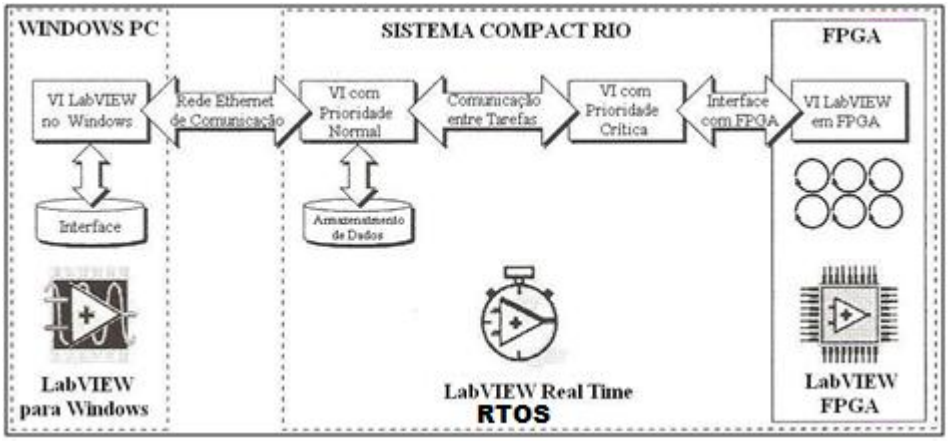

Figura 6 - Arquitetura da Aplicação do CompactRIO.
(Figura adaptada de NATIONAL INSTRUMENTS INC., 2008)

O *CompactRIO* é constituído por módulos de entradas e saídas (do inglês *Input and Output Module*(I/O)), um chassi de FPGA e um controlador de tempo real. Os módulos de entrada e saída realizam a comunicação com equipamentos externos – tais como sensores e atuadores – e comunicam diretamente com o chassi de FPGA (Figura 7), podendo ser

integrados diversos módulos de entradas analógicas e digitais. O chassi de FPGA permite a implementação de lógicas de controle específicas, em *hardware*, sendo que no chassi há um barramento de transferência de dados. Através do duto de transferência de dados é possível transmitir dados dos módulos I/O para o controlador de tempo real, para análises, pós-processamento, armazenamento do sinal ou comunicação com o computador através da rede Ethernet.

O controlador de tempo real possui processador de ponto flutuante, comunicação Ethernet (com a aplicação em computador do tipo PC), porta serial e relógio em tempo real, para base de tempo em análises e pós-processamento do sinal. Ainda, o controlador de tempo real possui interface para dispositivos de armazenamento de dados de alta capacidade do tipo *PenDrive*.

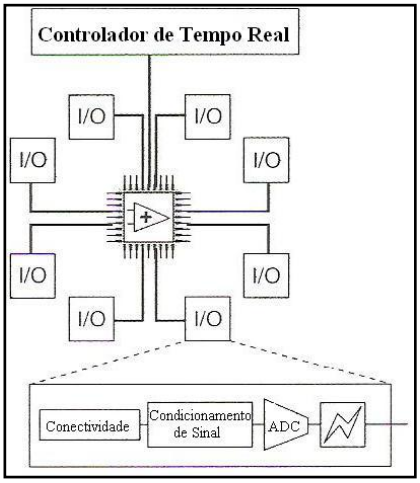

Figura 7 - Topologia de Conexão do Sistema CompactRIO.
(Figura adaptada de NATIONAL INSTRUMENTS INC., 2008)

3.2.Aquisição de Dados Experimentais

Para aquisição e armazenamento dos dados experimentais foram implementados 3 programas em *software* LabVIEW®. O primeiro executa em um computador do tipo PC (Figura 8), para interface com o usuário, onde são configurados os parâmetros dos ensaios. O segundo (Figura 9) executa no controlador de tempo real (NI cRIO 9014), realizando o filtro dos dados do tipo *Butterworth* passa baixa e armazenamento dos dados em dispositivos de

alta capacidade do tipo *PenDrive*. Por fim, o terceiro (Figura 10) executa no FPGA (NI 9114), realizando a aquisição e controle dos dados a uma taxa de 100 Hz.

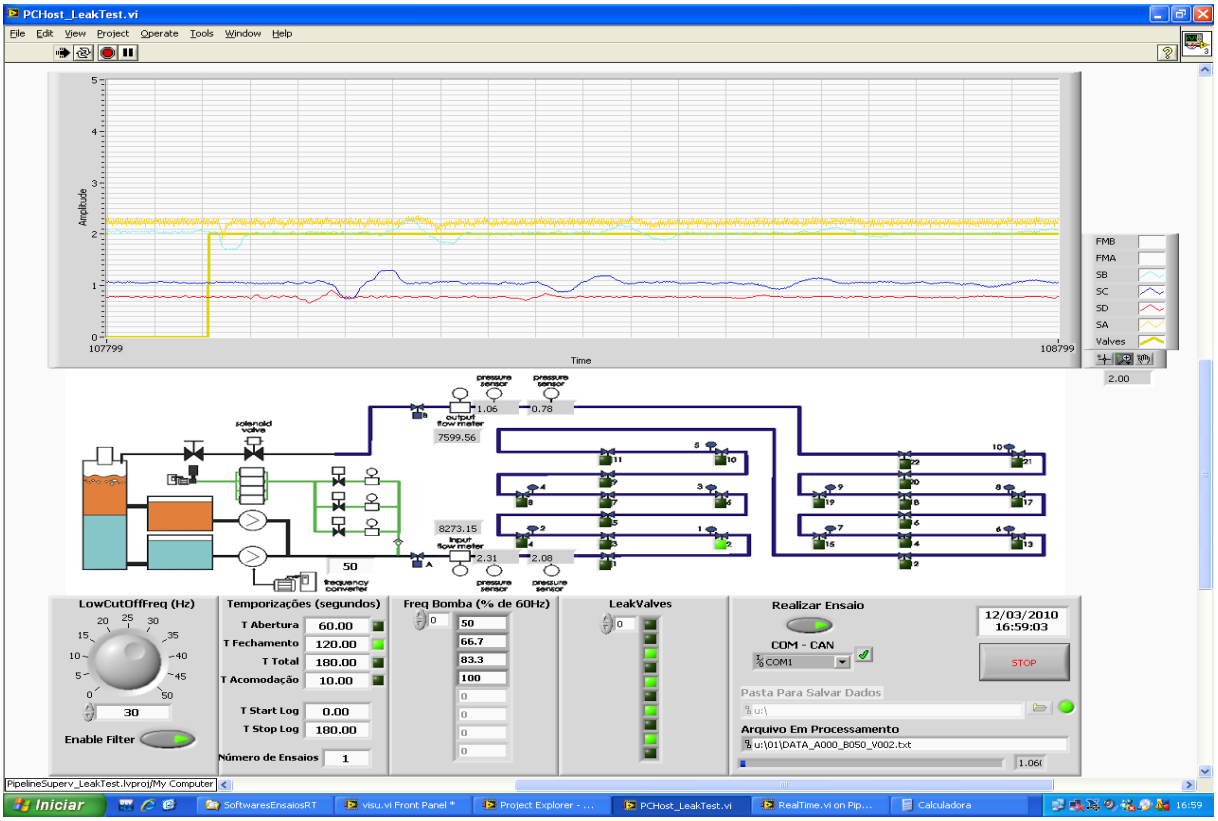

Figura 8 - Tela do *software* em LabVIEW® que é executado em um computador do tipo PC.

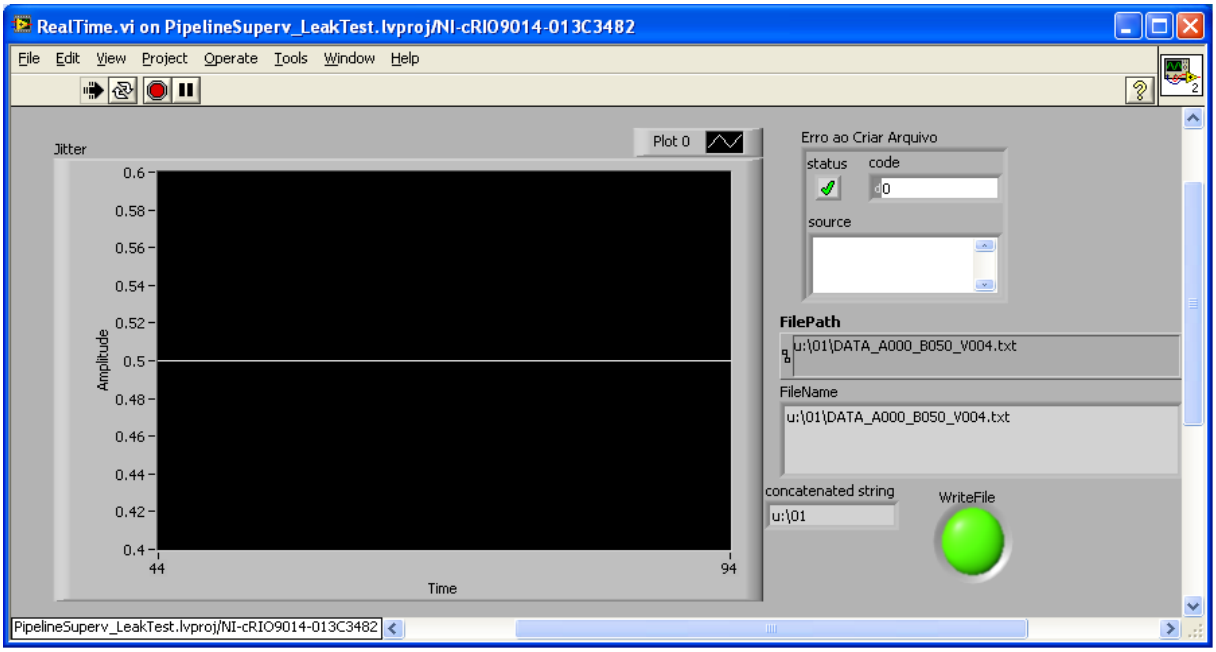

Figura 9 - Tela do *software* em LabVIEW® que é executado no controlador de tempo real (NI cRIO 9014).

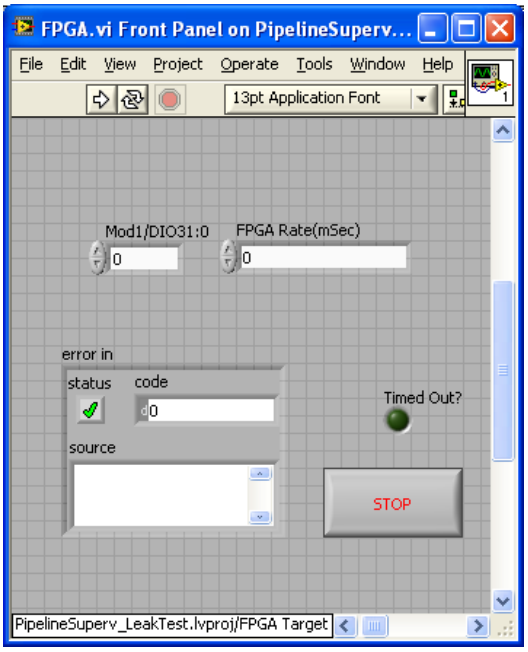

Figura 10 - Tela do *software* em LabVIEW® que é executado em FPGA (NI cRIO 9114).

Para execução dos testes foi utilizado um escoamento monofásico de água, sendo que o *software* para execução automática dos testes realiza ciclicamente as seguintes operações:

i. define a freqüência da bomba de água;
ii. define a válvula solenóide que simula um vazamento;
iii. aguarda o tempo de estabilização do sistema (10 segundos);
iv. inicia o armazenamento de dados (9 transdutores de pressão (ver Tabela 1)) no *PenDrive* em arquivos ASCII separados por tabulação;
v. aguarda tempo para abertura da válvula solenóide (60 segundos);
vi. abre a válvula solenóide pré-definida;
vii. aguarda tempo para fechamento da válvula solenóide (60 segundos);
viii. fecha a válvula solenóide;
ix. finaliza ensaio e aquisição de sinais.

Mais detalhes das temporizações programáveis do *software* para execução automática dos testes são ilustrados na Figura 11. A disposição dos transdutores de pressão, vazão e as válvulas solenóides podem ser visualizadas na Figura 5.

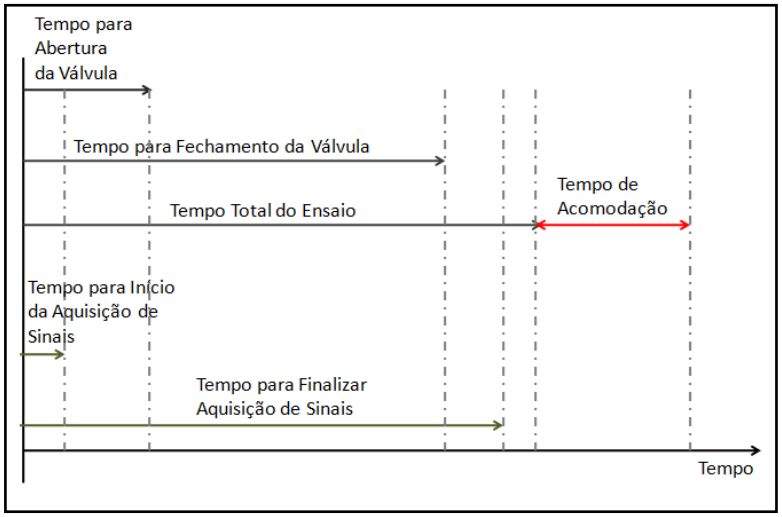

Figura 11 - Temporizações programáveis do *software* para execução automática dos experimentos.

Tabela 1 - Posições Relativas dos Transdutores à Bomba de Água.

Sensores	Posição Relativa (metros)
FMI – Medidor de Vazão da Entrada	15
P1 – Transdutor de Pressão 1	143
P2 – Transdutor de Pressão 2	263
P3 – Transdutor de Pressão 3	387
P4 – Transdutor de Pressão 4	508
P5 – Transdutor de Pressão 5	632
P6 – Transdutor de Pressão 6	878
P7 – Transdutor de Pressão 7	1000
P8 – Transdutor de Pressão 8	1123
P9 – Transdutor de Pressão 9	1243
P10 – Transdutor de Pressão 10	1367
FMO – Medidor de Vazão da Saída	1492

Foram arbitradas 4 frequências (30, 40, 50 e 60 Hz) de bomba. Devido a manutenções no oleoduto piloto, apenas 10 das 22 válvulas de simulação de vazamento estão operantes (V2, V4, V6, V8, V10, V13, V15, V17, V19 e V21). Ainda, o sensor de pressão P1 também está inoperante. Assim, constituiu um total de 40 ciclos de testes experimentais, sendo cada ciclo com duração de 180 segundos, totalizando a aquisição de 360 sinais de simulação de vazamento. A vazão média de cada experimento para as frequências de bomba de 30, 40, 50 e 60 Hz são respectivamente, 73.7, 100.4, 125.4 e 146.6 l/min. A abertura das válvulas utilizadas para simulação de vazamento foram calibradas para fornecer uma vazão aproximada de 7 litros por minuto com o inversor de freqüência da bomba à 30Hz.

Tabela 2 - Posições Relativas das Válvulas Solenóides (Vazamentos).

Válvulas	Posição Relativa (metros)
V1 – Válvula Solenóide 1	100
V2 – Válvula Solenóide 2	142
V3 – Válvula Solenóide 3	185
V4 – Válvula Solenóide 4	266
V5 – Válvula Solenóide 5	344
V6 – Válvula Solenóide 6	387
V7 – Válvula Solenóide 7	430
V8 – Válvula Solenóide 8	511
V9 – Válvula Solenóide 9	589
V10 – Válvula Solenóide 10	631
V11 – Válvula Solenóide 11	674
V12 – Válvula Solenóide 12	835
V13 – Válvula Solenóide 13	878
V14 – Válvula Solenóide 14	921
V15 – Válvula Solenóide 15	1002
V16 – Válvula Solenóide 16	1080
V17 – Válvula Solenóide 17	1122
V18 – Válvula Solenóide 18	1165
V19 – Válvula Solenóide 19	1246
V20 – Válvula Solenóide 20	1324
V21 – Válvula Solenóide 21	1366
V22 – Válvula Solenóide 22	1410

Como o ponto de aquisição de pressão e simulação de vazamento é o mesmo para os sensores P2, P3, P4, P5, P6, P7, P8, P9 e P10, e respectivamente para as válvulas V4, V6, V8, V10, V13, V15, V17, V19 e V21, esses sinais de pressão nos testes coincidentes foram desconsiderados na análise. A Tabela 3 explicita a matriz de sinais adquiridos para cada freqüência da bomba (30, 40, 50 e 60Hz), sendo que as colunas em destaque exibem os sensores que capturam dados para cada simulação de vazamento.

Tabela 3 - Relação entre Simulação de Vazamento e Aquisição de Sinal.

Válvula / Sensor	V2	V4	V6	V8	V10	V13	V15	V17	V19	V21
P2										
P3										
P4										
P5										
P6										
P7										
P8										
P9										
P10										

3.3. Aplicação de Redes Neurais Artificiais para Detecção de Vazamentos em Dutos

Neste trabalho, utiliza-se redes neurais artificiais do tipo *Perceptron*, sendo o treinamento realizado através do método *backpropagation* (detalhado no item 2.2.2). O processo de aquisição dos dados, pré-processamento do sinal, treinamento e validação da rede neural aplicada são detalhados no fluxograma da Figura 12.

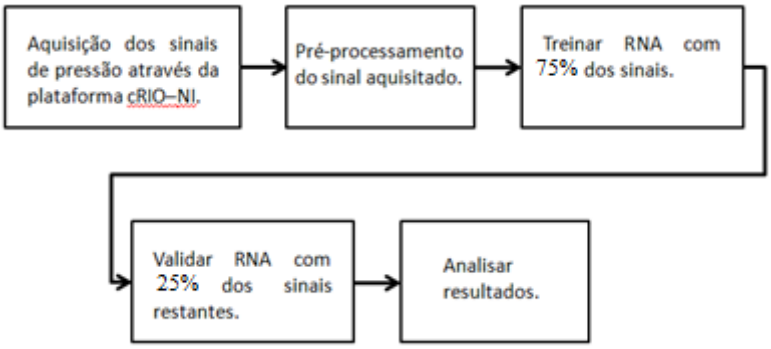

Figura 12 - Processo para obtenção de resultados.

3.3.1. Sistema de Controle e Aquisição de Dados

O Sistema de controle e aquisição de dados está detalhado nos itens 3.2 e 3.3. Sucintamente, utiliza-se um PAC da *National Instruments*® composto por um controlador de tempo real, um FPGA e módulos de I/Os. A lógica do programa do PAC controla a freqüência do inversor controlador da bomba de água e também aciona a válvula solenóide que simula o vazamento em posições pré-determinadas – detalhadas na Figura 5. O PAC realiza a aquisição de sinais de 10 transdutores de pressão a taxa de 100 Hz, armazenando os dados em um dispositivo do tipo *PenDrive*. Na lógica do programa, é possível executar experimentos com diferentes freqüências de aquisição, freqüências do inversor de freqüência, posições de vazamentos.

3.3.2. Pré-processamento do Sinal Adquirido

Um exemplo de sinal adquirido experimentalmente de uma simulação de vazamento está disposto na Figura 13. Os sinais experimentais são compostos por 2 componentes: 1) Componente DC, que expressa o valor em regime permanente; 2) Componente AC, que expressa o sinal transiente.

A diferença de cotas altimétricas nos sensores de pressão e a perda de carga do escoamento acarretam em uma diferença na pressão estática em cada sensor instalado no oleoduto piloto (ver Figura 5). Assim, é extraído a componente DC do sinal através da subtração da média do sinal, para centralizar todos os sinais e então realizar uma análise na componente AC do sinal. A Figura 14 exemplifica a componente AC extraída do sinal, experimental, exemplificado na Figura 13. As Equações (46) e (47) expressam matematicamente o algoritmo para obtenção do sinal AC do sinal experimental adquirido.

$$\mathrm{MEDIA_Pl(i)} = \frac{1}{\mathrm{N}} \sum_{\mathrm{i}=1}^{\mathrm{N}} \mathrm{Pl(i)} \tag{46}$$

$$\mathrm{Pl_AC(i)} = \mathrm{Pl(i)} - \mathrm{MEDIA_Pl} \tag{47}$$

Onde: Pl é o vetor discreto do sinal de pressão adquirido no ensaio; N número de amostras do experimento; Pl_AC é a componente AC do vetor de sinal de pressão.

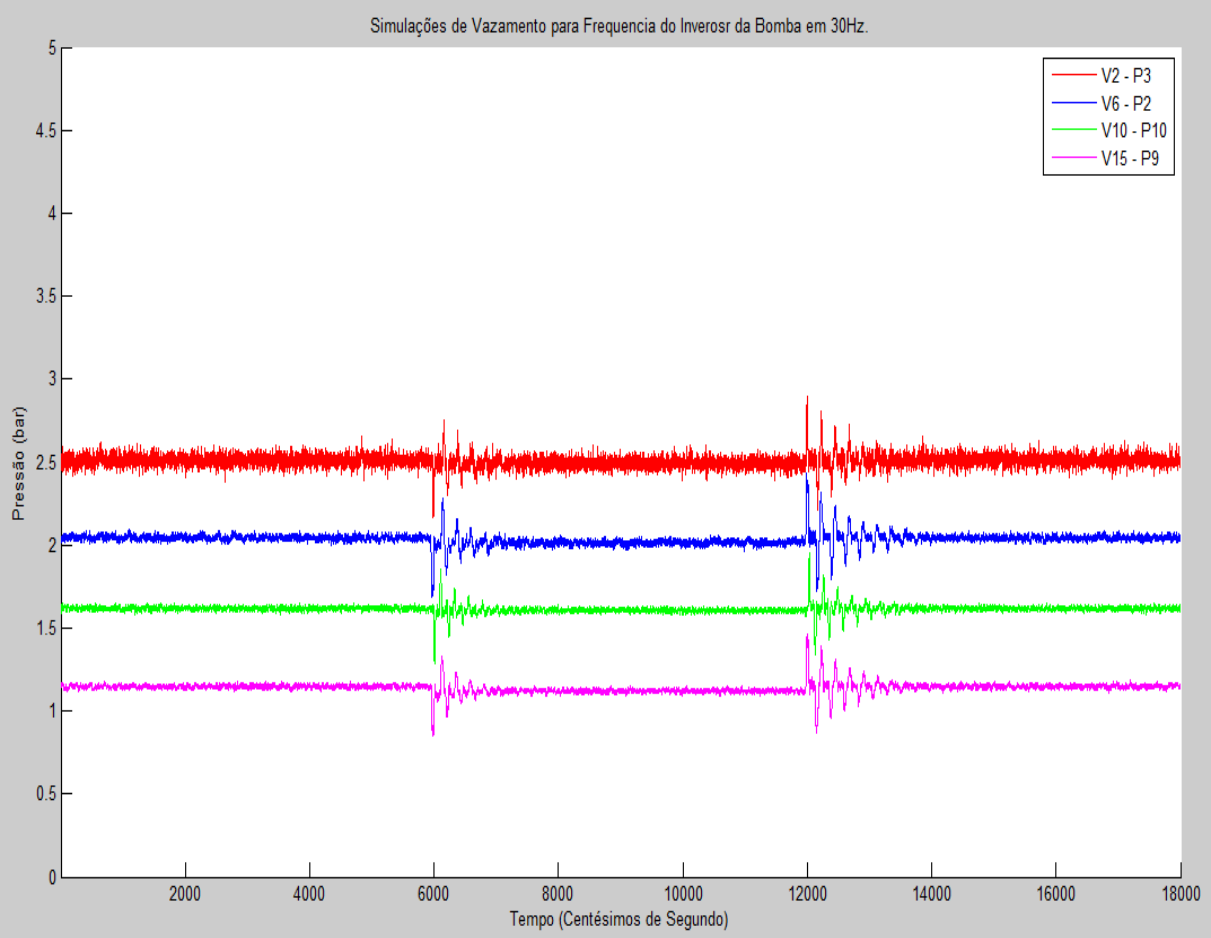

Figura 13 - Sinal Experimental de Simulação de Vazamento.

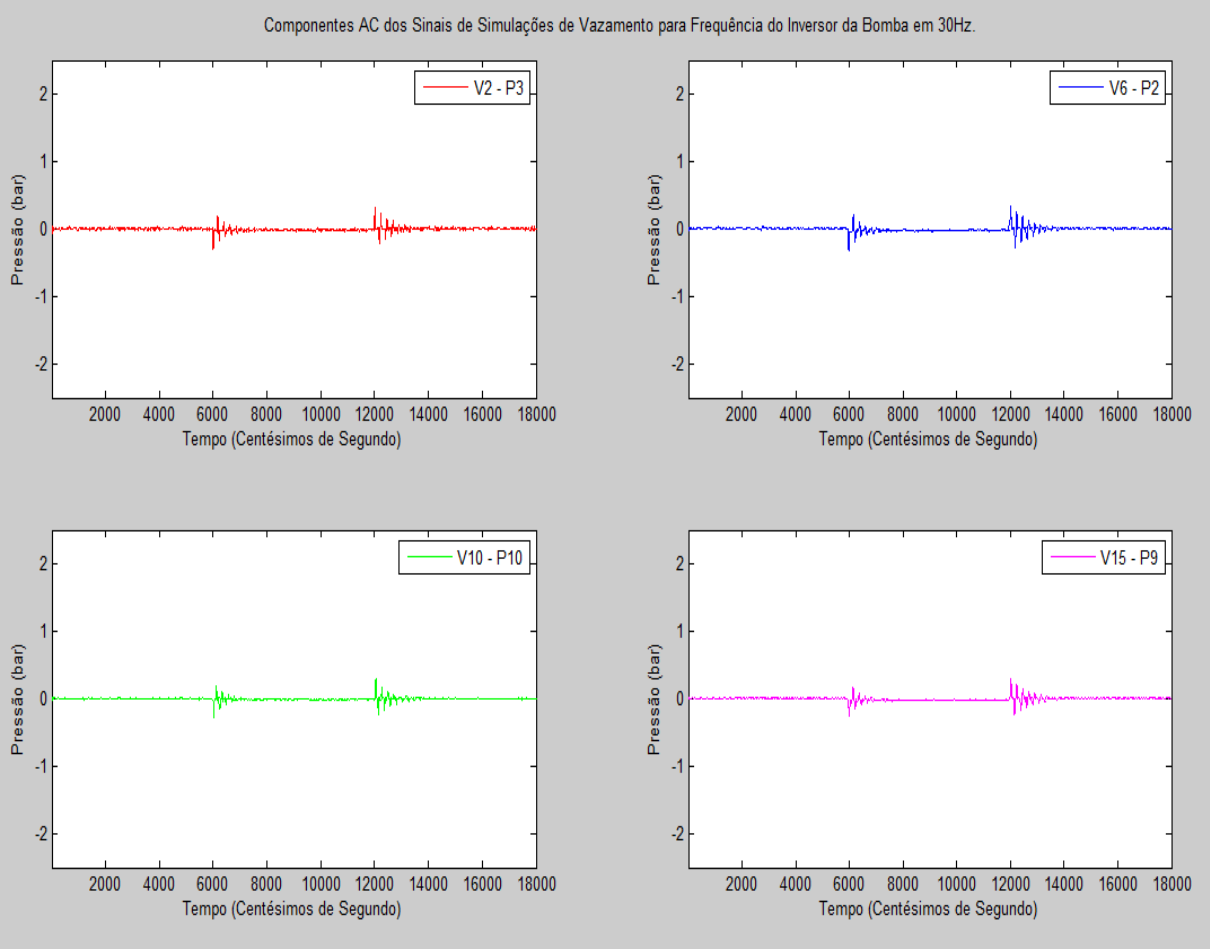

Figura 14 - Componente AC dos Sinais Experimentais de Simulação de Vazamento da Figura 13.

Analisando o gráfico da Figura 13, pode-se destacar 5 etapas no experimento de simulação de vazamento.

i. Entre os instantes 0 à 6000 centésimos de segundo: Aguarda abertura de válvula que simula vazamento;
ii. Instante 6000 centésimos de segundo: Instante da abertura da válvula que simula vazamento;
iii. Entre os instantes 6000 à 12000 centésimos de segundo: Acomodação do sinal de vazamento;
iv. Instante 12000 centésimos de segundo: Instante do fechamento da válvula que simula vazamento;

v. Entre os instantes 12000 à 18000 centésimos de segundo: Acomodação do sinal de fechamento de vazamento.

Para realizar uma análise específica para extrair características dos sinais de vazamentos, focaremos a análise nos 1500 centésimos de segundos a partir do instante de abertura da válvula que simula o vazamento. Assim, a Figura 15 exibe os sinais de vazamento dos experimentos exemplificados na Figura 14.

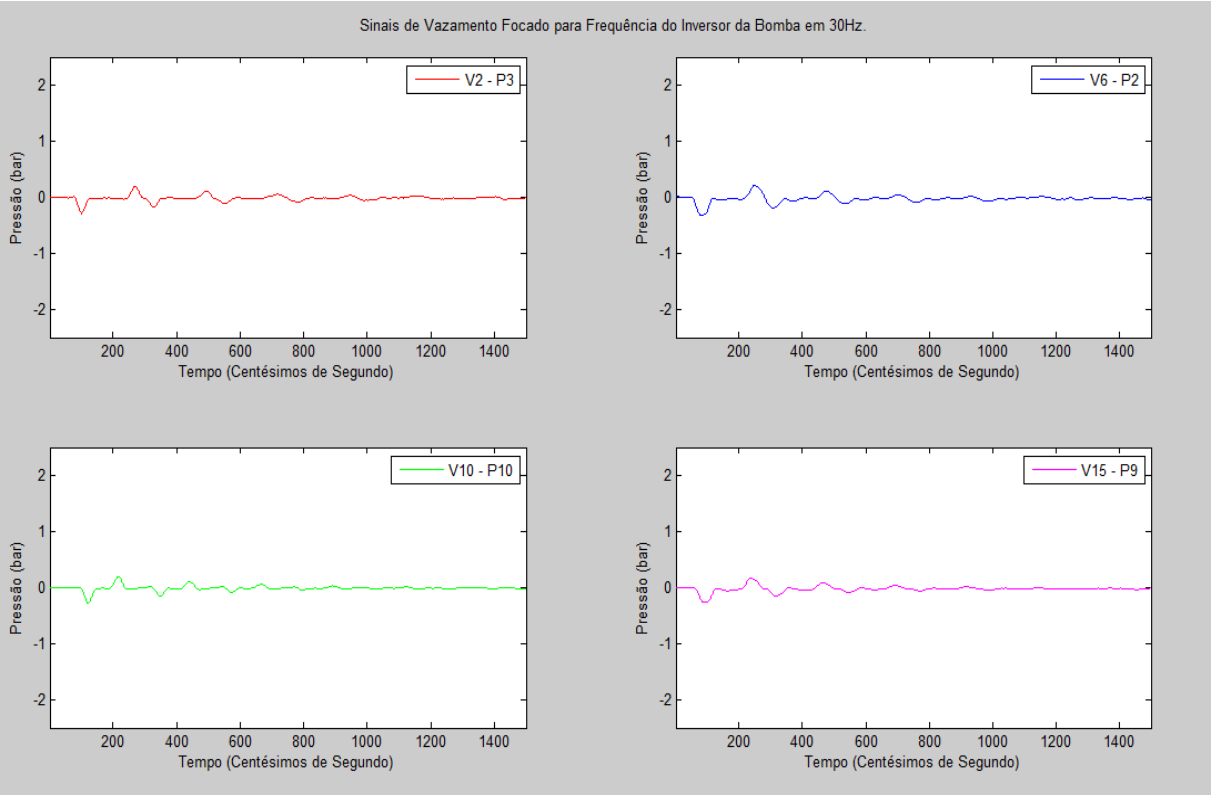

Figura 15 - Detalhe nos Sinais de Abertura de Válvula das Simulações de Vazamento da Figura 14.

Para realizar uma análise espectral de um sinal, uma ferramenta muito utilizada é a Transformada de Fourier, que consiste na decomposição do sinal em termos de senos e cossenos de diferentes freqüências características (COHEN L., 1995). Para um sinal discreto, utiliza-se a Transformada de Fourier Discreta, que está expressa na Equação (48).

$$X(k) = \sum_{n=1}^{N} x(n) \cdot e^{-j \cdot 2 \cdot \pi \cdot (k-1) \cdot (n-1)/N} \; ; 1 \leq k \leq N \qquad (48)$$

A Figura 16 apresenta uma análise do espectro de freqüências, através do módulo da transformada de Fourier para o sinal vazamento (abertura de válvula) exemplificado na Figura 15. Descrições abrangentes sobre análise no espaço tempo-freqüência podem ser encontradas em COHEN L., 1995.

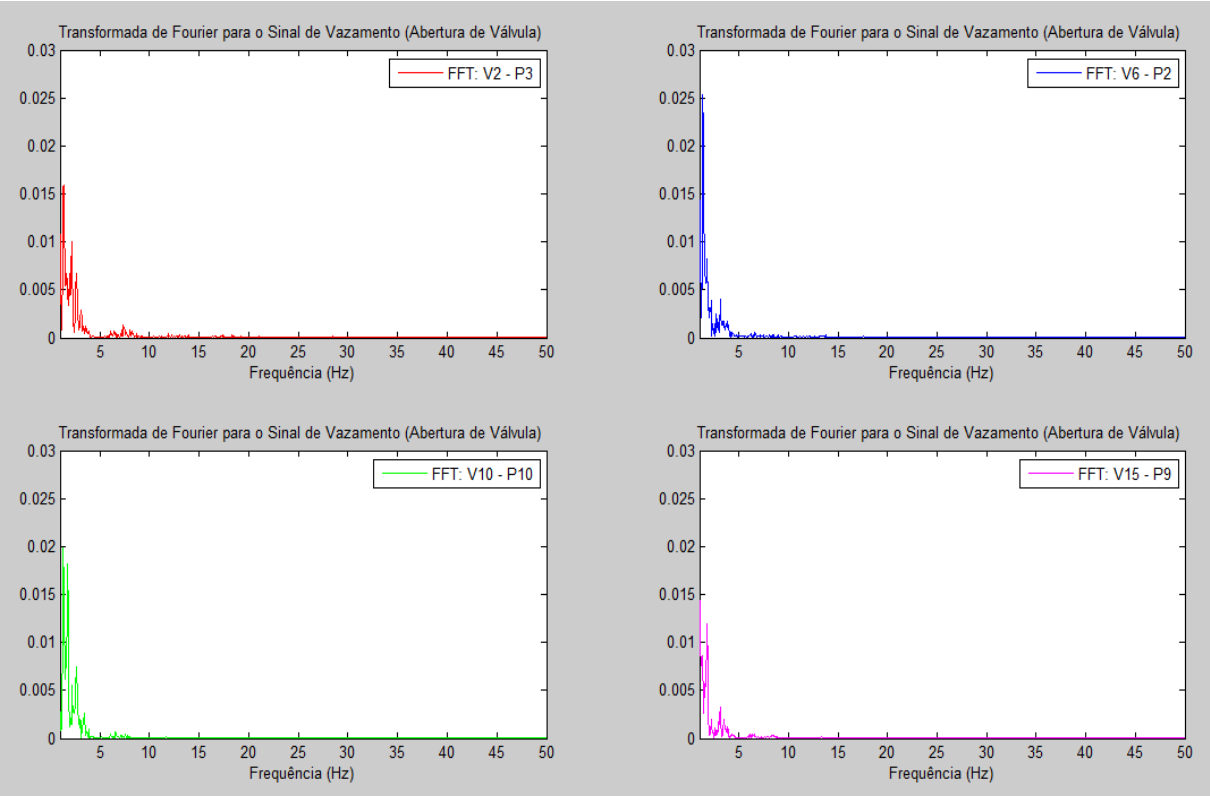

Figura 16 - Transformada de Fourier para o Sinal Vazamento (Abertura de Válvula) Exemplificado na Figura 15.

Analisando a transformada de Fourier para os sinais de vazamento analisados, conclui-se que as freqüências características de vazamento, tipicamente são inferiores a 10 Hz para os sinais adquiridos neste trabalho. De acordo com o critério da amostragem de Nyquist (LÜKE H., 1999) a taxa mínima de amostragem de um sinal (f_{sMIN}) – freqüência de Nyquist – é tal que a relação entre a máxima freqüência do sinal (f_{MAX}) e (f_{sMIN}) seja superior a 2. Em termos matemáticos temos:

$$f_{sMIN} \geq 2 \cdot f_{MAX} \tag{49}$$

Logo, para $f_{MAX} = 10Hz$, temos uma freqüência de Nyquist $f_{sMIN} = 20$Hz. Os experimentos foram realizados a freqüência de amostragem $f_s = 100Hz$, assim tem uma freqüência de amostragem 5 vezes à freqüência máxima, satisfazendo o critério de Nyquist.

Para uma diminuição no esforço computacional, os sinais experimentais foram decimados, sendo o fator de decimação igual a 4. Portanto, os sinais experimentais foram reamostrados em uma freqüência de aquisição de 25Hz. A Equação (50) exibe o algoritmo implementado efetivando a decimação e um filtro de média móvel, passa baixa de primeira ordem.

$$\mathrm{Pl_DEC(i)} = \frac{1}{5}\sum_{j=4i-2}^{j=4i+2} \mathrm{Pl_AC(j)} \tag{50}$$

Assim, pode-se resumir o pré-processamento do sinal como através das etapas de remoção da componente DC, decimação e filtragem (passa baixa) do sinal.

3.3.3. Treinamento da RNA com Sinais Experimentais

3.3.3.1.Classificação dos Sinais para Treinamento da RNA

Os testes experimentais de simulação de vazamento foram executados em 10 válvulas distintas (ver Tabela 2) e em 4 rotações distintas da bomba, sendo que cada experimento foi registrado nos sensores de pressão de resposta rápida de acordo com a Tabela 3. Ressalta-se que cada teste experimental é composto inicialmente por um instante de ruído de fundo da linha, prosseguido por um instante de abertura da válvula solenóide e um instante de fechamento da válvula solenóide.

A partir das informações experimentais, os sinais foram classificados em 3 classes:

- Vazamento (abertura da válvula solenóide)
- Fechamento de vazamento (fechamento da válvula solenóide)
- Ruído da linha (sem acionar a válvula solenóide)

O sinais de fechamento de vazamento devem ser classificados como uma manobra operacional no duto. Para simplificar o treinamento da rede, padronizou-se que a classificação em somente 2 classes:

- Vazamento;
- Não Vazamento (fechamento de vazamento e ruído da linha).

Assim, tem-se um total de 324 sinais de vazamento e 648 sinais de não vazamento, sendo que destes, 75% dos sinais de vazamento e também 75% dos sinais de não vazamento foram utilizados para efetuar o treinamento da Rede Neural Artificial. Os demais sinais foram utilizados para efetuar a validação cruzada da RNA.

A saída da RNA será composta por 2 neurônios, que produzirão uma saída do tipo (y_1, y_2), sendo que as saídas ideais para cada classe são:

- (1,-1) – Vazamento;
- (-1,1) – Não Vazamento.

Sintetizando, para uma visualização gráfica teremos dois eixos cartesianos y_1 e y_2, sendo que “1” em y_1 indica vazamento, enquanto “-1” em y_1 indica não vazamento, e conseqüentemente, “1” em y_2 indica não vazamento, enquanto “-1” em y_2 indica vazamento. A Figura 17 exemplifica, em termos gráficos, a saída da RNA para um vazamento e para um não vazamento.

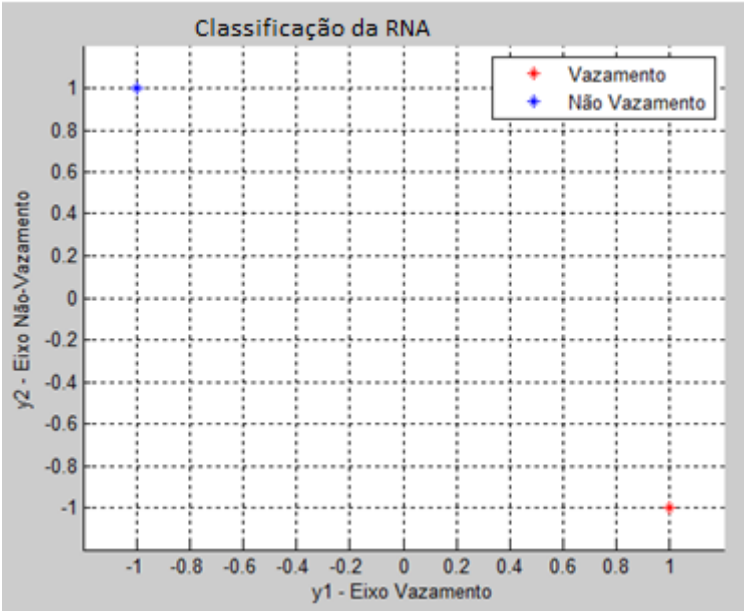

Figura 17 - Exemplo de Visualização Gráfica das Saídas da RNA.

3.3.3.2.Topologia da RNA Utilizada

A definição da topologia de Rede Neural Artificial do tipo *Perceptron* a ser utilizada neste trabalho foi norteada pelo trabalho de Cybenko, que em 1989 demonstrou que regiões de decisões arbitrárias podem ser bem aproximadas por uma rede neural *feedforward*, com uma única camada neural escondida, com função de ativação sigmoidal e camada neural de saída com função de ativação do tipo linear (GYBENKO G. V., 1989).

Como os dados de entrada na rede são normalizados no conjunto $[-1; 1] \in \mathbb{R}$, definiu-se a utilização da função tangente hiperbólica sigmóide para função de ativação da camada neural escondida. A Equação (51) expressa matematicamente à função de ativação tangente sigmóide.

$$y(x) = \left(\frac{2}{1+e^{-2x}}\right) - 1 \qquad (51)$$

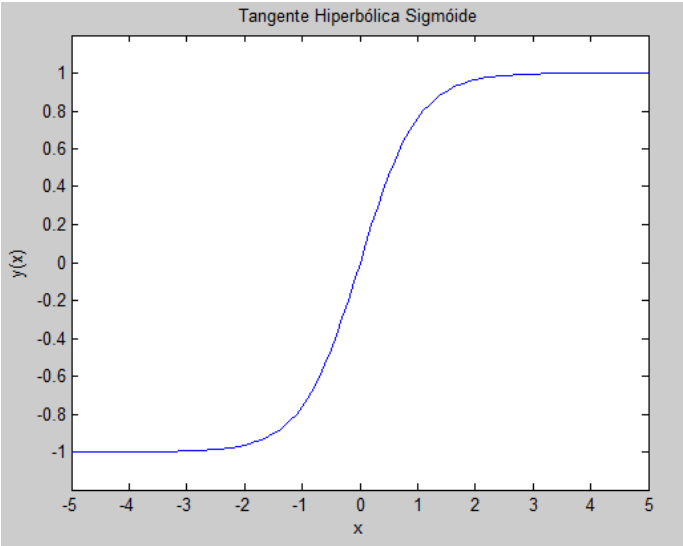

Figura 18 - Tangente Hiperbólica Sigmóide.

Assim, defini-se que serão testadas RNAs do tipo *Perceptron feedforward*, com uma camada escondida com função de ativação tangente hiperbólica sigmóide e função de ativação linear identidade para a camada de saída.

3.3.4. Validação Cruzada do Treinamento da RNA

A validação cruzada (do inglês *Cross-validation*) é uma metodologia comumente utilizada para testar o poder de generalização da uma rede neural artificial. Nesse contexto, deve-se particionar o conjunto de dados em 2 subconjuntos, sendo o primeiro com cerca de 70 à 90% dos dados que é utilizado somente para treinamento; e os demais dados constituem o segundo subconjunto que compõem o conjunto de testes, para verificar se a rede neural está generalizando de forma satisfatória.

Neste trabalho, os dados obtidos com o inversor de freqüência da bomba nas freqüências de 30, 50 e 60 Hertz serão utilizados para treinamento, enquanto os dados de 40Hz serão utilizados para validação da RNA, representando uma classe de dados não apresentados para a RNA durante o treinamento. Assim, 75% dos dados são utilizados para treinamento e 25% para validação cruzada;

3.3.5. Toolbox de Rede Neural Artificial – MATLAB®

O MATLAB® (acrônimo do inglês *MATrix LABoratory*) é um *software* de alta performance voltado para o cálculo numérico, desenvolvido no final da década de 70, contendo constantes atualizações e aperfeiçoamentos. O MATLAB® integra a análise numérica, cálculo com matrizes, processamento de sinais e construção de gráficos em um ambiente de fácil utilização.

O processo de criação, treinamento e simulação das redes neurais artificiais, foi desenvolvido no *software* MATLAB®. Com um sistema iterativo e linguagem de programação para computação técnica e científica em geral, o MATLAB® permite a construção de "bibliotecas" de funções, denominada "*toolboxes*", que o tornam apto a resolver classes particulares de problemas (DEMUTH H.; *et al.*, 2010).

O "*toolbox*" de Redes Neurais do MATLAB® possui ampla versatilidade e flexibilidade, haja visto que o seu uso possibilita a aplicação dos mais variados tipos de redes neurais além de permitir a modificação de redes já existentes, como alterações no número de camadas ou mesmo de algoritmos de treinamento com uma facilidade particular de inserção.

4. TESTES E RESULTADOS EXPERIMENTAIS

Foram analisadas 4 diferentes topologias de RNA para verificar a aplicabilidade das redes neurais treinadas. Em acordo com o item 3.3.3.2, todas as topologias são constituídas de 1 camada neural escondidas com **N1** neurônios e uma camada neural de saída com 2 neurônios (ver Figura 19).

Não há uma fórmula para determinar o número ideal para a quantidade de neurônios nas camadas escondidas. Os valores de **N1** devem ser escolhidos de forma que se tenha baixo custo computacional (rede neural artificial com o mínimo de neurônios) e a minimização do erro entre saída obtida na RNA e a saída desejada. Assim, após a análise dos resultados de um pré-estudo empírico com diferentes valores de **N1**, foram analisadas as topologias para os valores de **N1** iguais a 3, 5, 10 e 20.

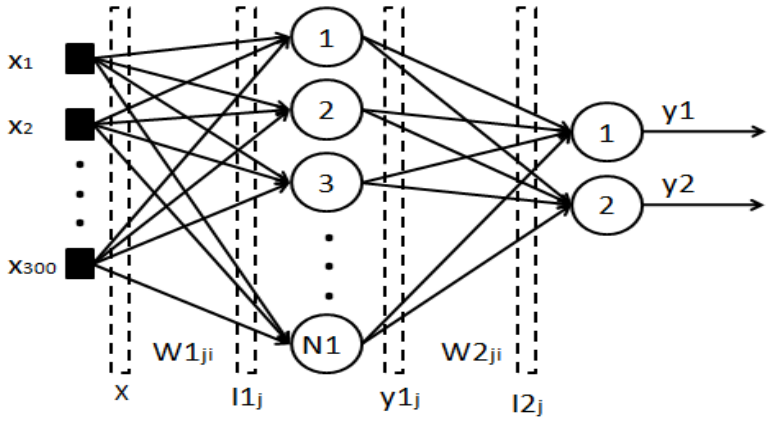

Figura 19 - Topologia de RNA *Perceptron* Implementada.

A Figura 20 apresenta as curvas de aprendizagem para o os diferentes valores de N1 analisados. O critério utilizado para treinamento é um número máximo de 10000 épocas ou erro quadrático médio inferior a 0,0005. O treinamento é finalizado quando um dos critérios é atingido.

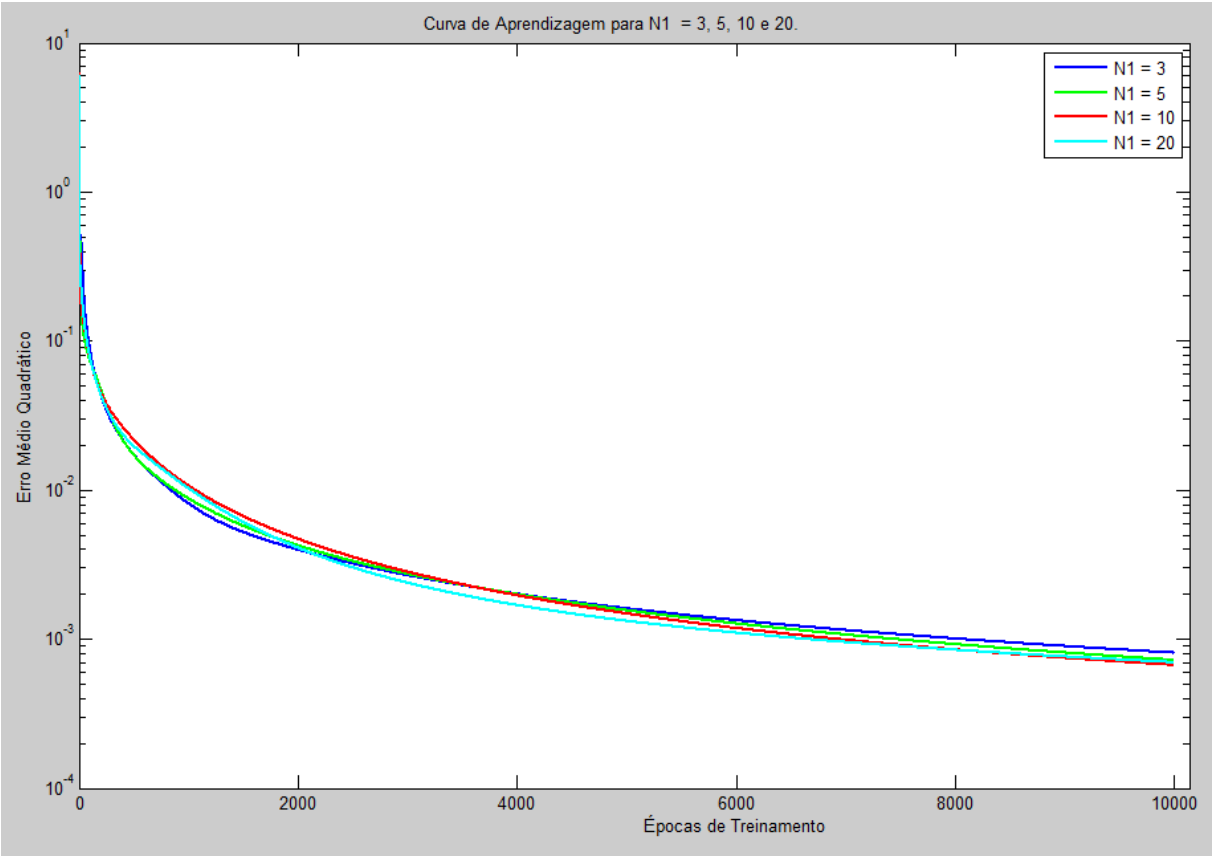

Figura 20 - Curvas de Aprendizagem para Neurônios na Camada Escondida Iguais a 3, 5, 10 e 20.

Com as curvas de aprendizado do treinamento das RNAs com os testes experimentais apresentadas na Figura 20, todas as curvas de aprendizado apresentam resultados satisfatórios, com erro médio quadrático próximo ao desejado, ao final das 10.000 épocas de treinamento. Para uma análise mais detalhada dos resultados, é utilizada a rede com 10 neurônios na camada escondida, vista que esta apresentou o menor erro médio quadrático no treinamento.

Após o treinamento da rede com **N1 = 10**, os dados de treinamento foram classificados. A Figura 21 apresenta a classificação dos dados experimentais utilizados para treinamento e pode-se observar que os dados de vazamento e não vazamento (ruído e fechamento de válvula) são linearmente separáveis, o que permite a utilização de uma função linear para efetuar a separação dos espaços.

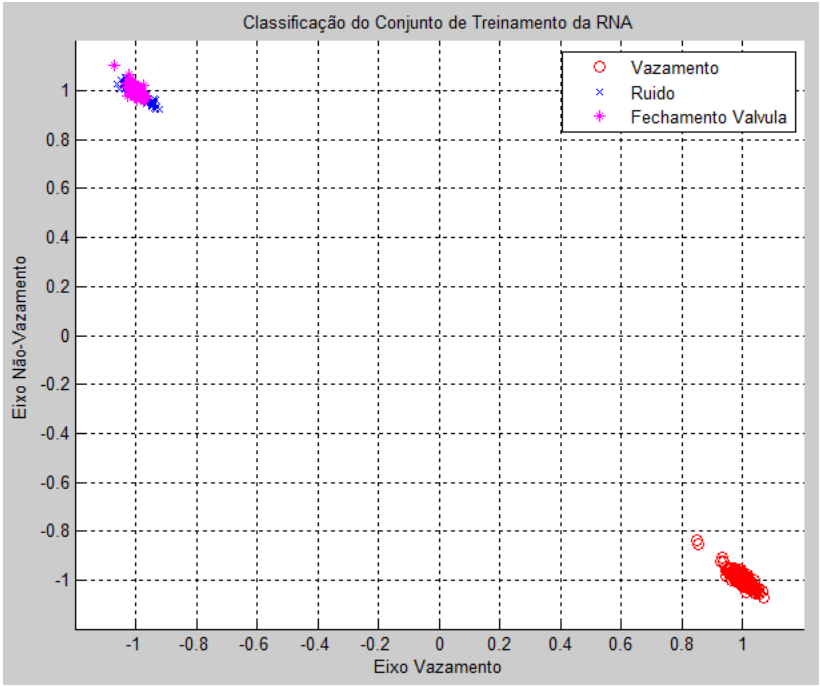

Figura 21 - Classificação dos Dados Utilizados para Treinamento da RNA com N1 = 10.

Para quantificar o erro absoluto de cada ponto classificado pela rede neural é utilizada a distância euclidiana da saída da rede – (y_1, y_2) – ao centróide ideal vazamento (y_{1d}, y_{2d}) – (1, -1) para vazamento; (-1, 1) para não vazamento. A Equação (52) expressa matematicamente o cálculo do erro absoluto.

$$\text{erro} = \sqrt{(y_1 - y_{1d})^2 + (y_2 - y_{2d})^2} \qquad (52)$$

A Figura 22 apresenta um histograma do erro quadrático médio absoluto da saída da RNA, com os valores ideais para vazamento – (1, -1) – e não vazamento – (-1, 1) – onde se tem 99,7% dos dados experimentais classificados com erro absoluto compreendido entre 0 e 0,2.

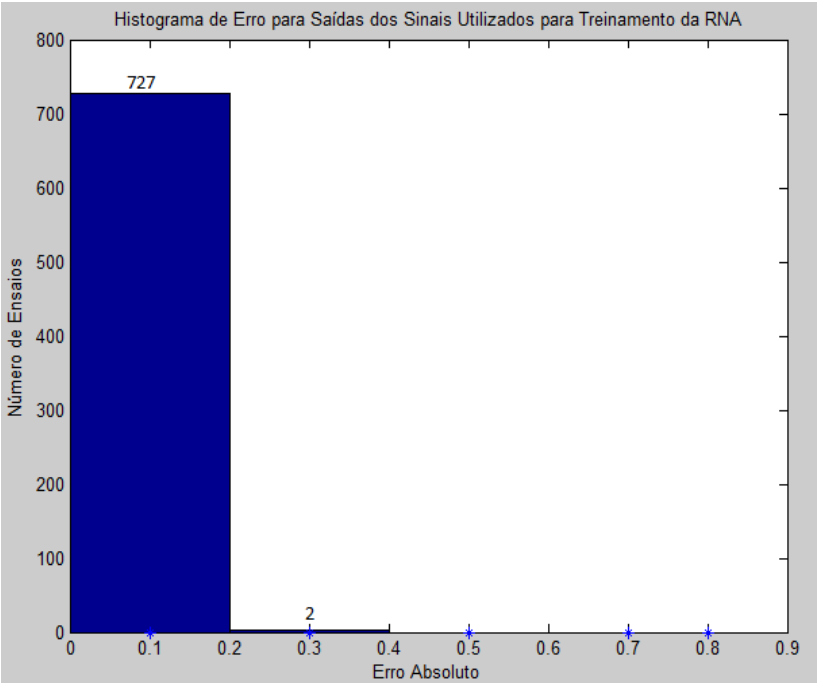

Figura 22 - Histograma de Erro Quadrático Médio Absoluto dos Dados Utilizados para Treinamento da RNA com N1 = 10.

Para verificar a capacidade de generalização da RNA, é realizada a validação cruzada, onde são apresentados dados para serem classificados, que não foram utilizados para treinamento da rede. A Figura 23 apresenta a classificação dos dados de testes utilizados para validação cruzada. Tal como o resultado obtido nos dados utilizados para treinamento da RNA, pode-se observar que os dados de vazamento e não vazamento (ruído e fechamento de válvula) são linearmente separáveis, podendo utilizar uma função linear para efetuar a separação dos espaços.

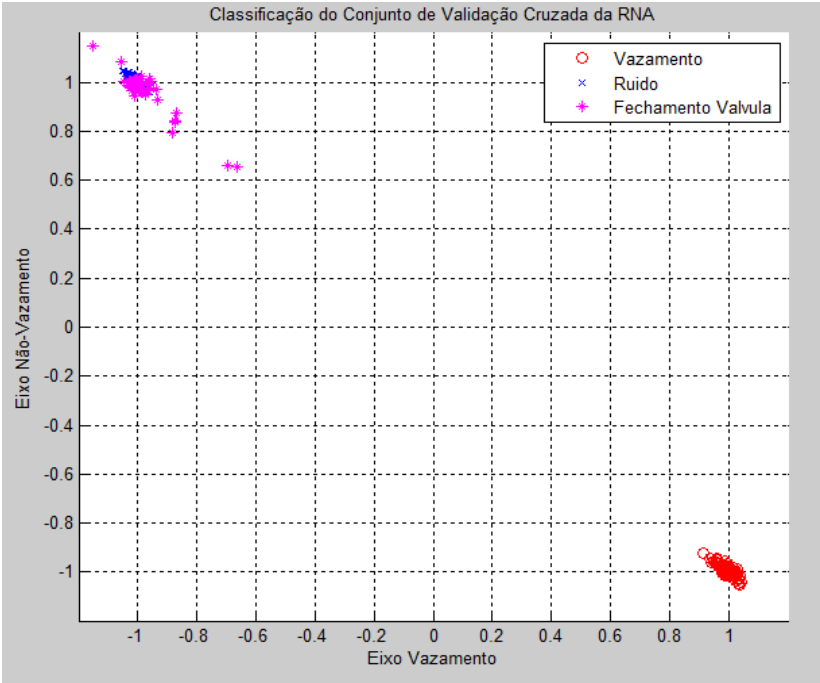

Figura 23 - Classificação dos Dados Utilizados para Validação Cruzada (Teste) da RNA com N1 = 10.

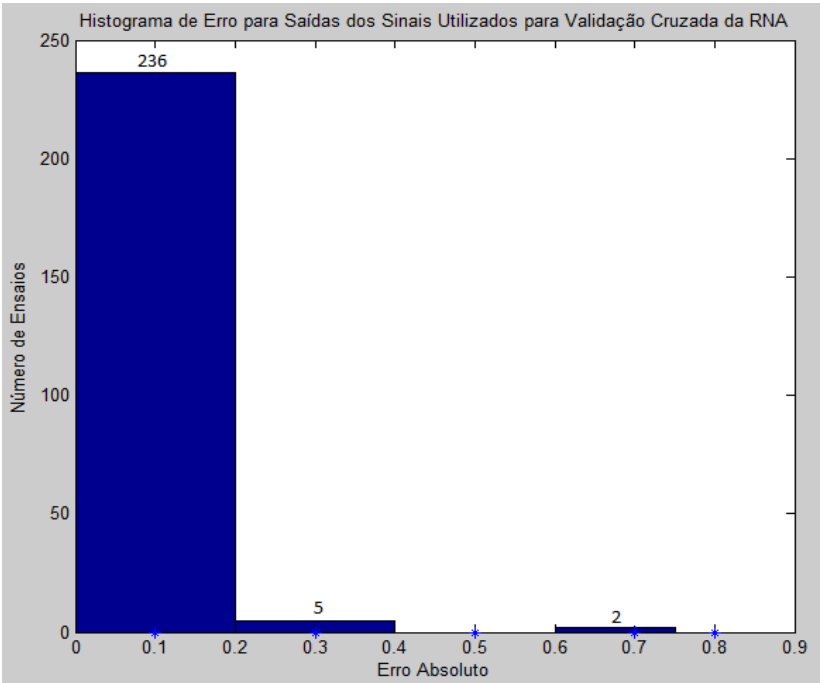

Figura 24 - Histograma de Erro Quadrático Médio Absoluto dos Dados Utilizados para Validação Cruzada (Teste) da RNA com N1 = 10.

4.1. Interferência de Ruído no Sinal de Entrada

Visto que a RNA com 10 neurônios na camada escondida respondeu satisfatoriamente com os resultados obtidos na validação cruzada, realizou-se também uma análise quanto à interferência de ruído no sinal de entrada na RNA. Para isso, foi adicionado aos sinais de validação cruzada da RNA ruídos pseudo-randômicos uniformemente distribuídos, onde foi variada a amplitude do ruído. Para análise, foram avaliados sinais com taxa de relação sinal-ruído de 5, 10, 20, 30, 40, 50, 60, 70, 80, 90 e 100%.

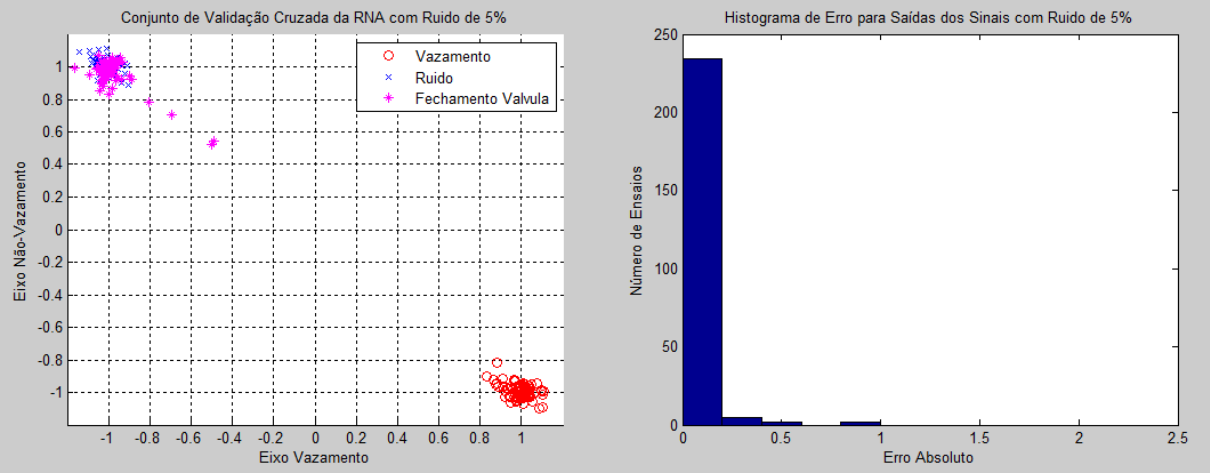

Figura 25 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 5%.

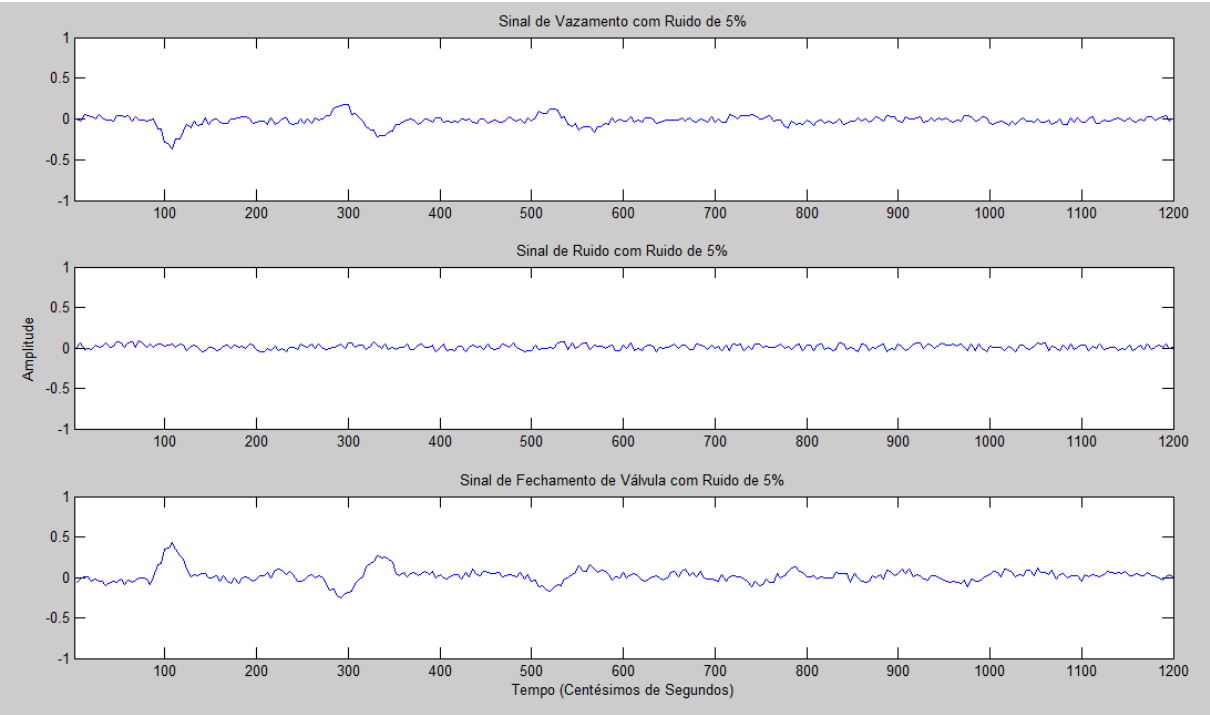

Figura 26 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 5% de ruído (Freq. Inversor de 40Hz; P2; S2).

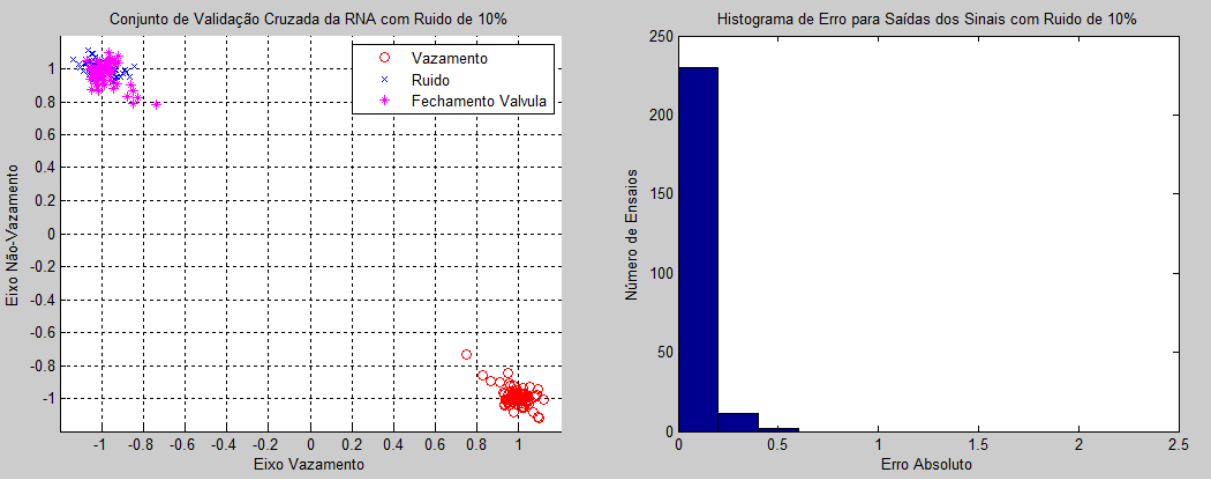

Figura 27 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 10%.

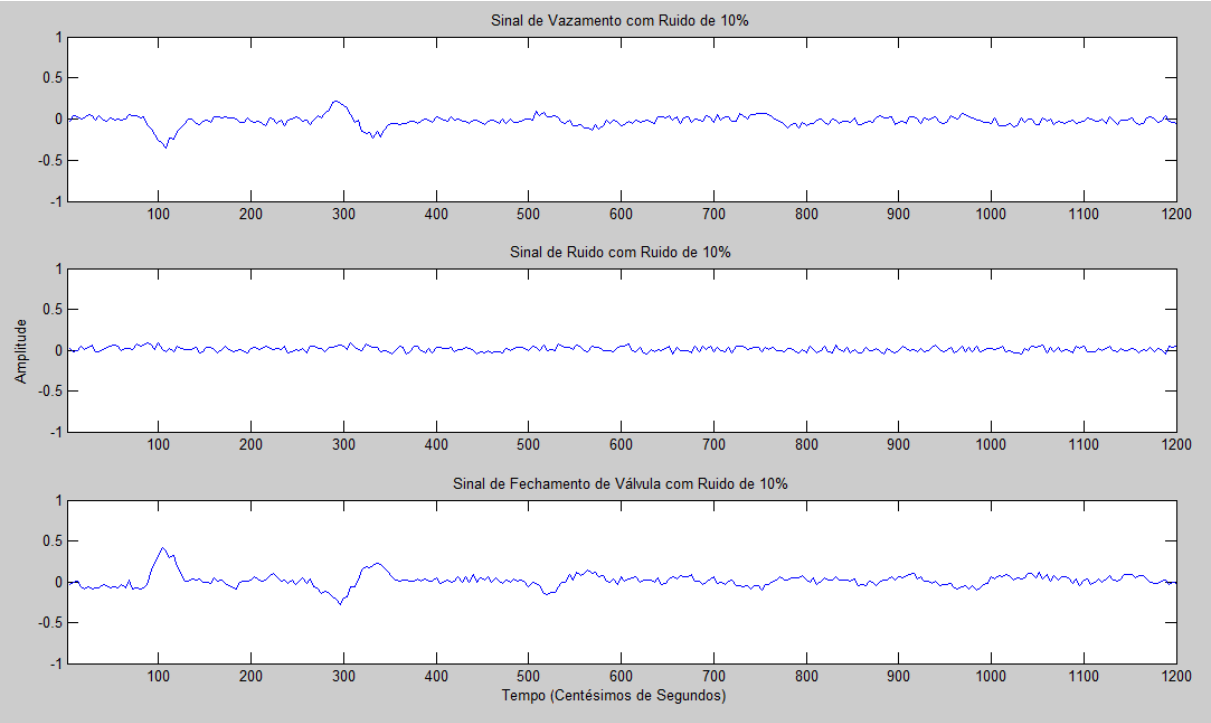

Figura 28 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 10% de ruído (Freq. Inversor de 40Hz; P2; S2).

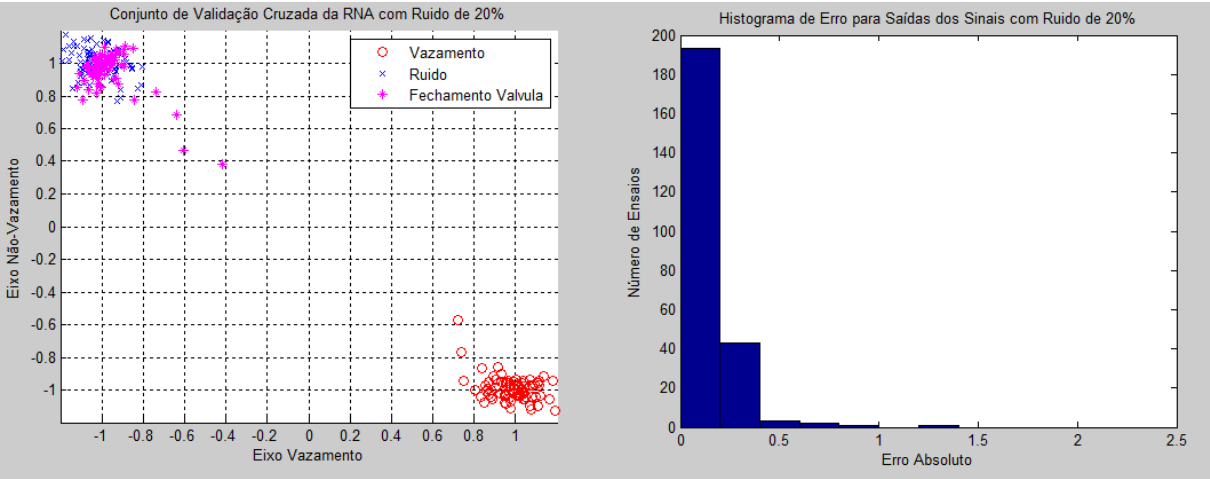

Figura 29 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 20%.

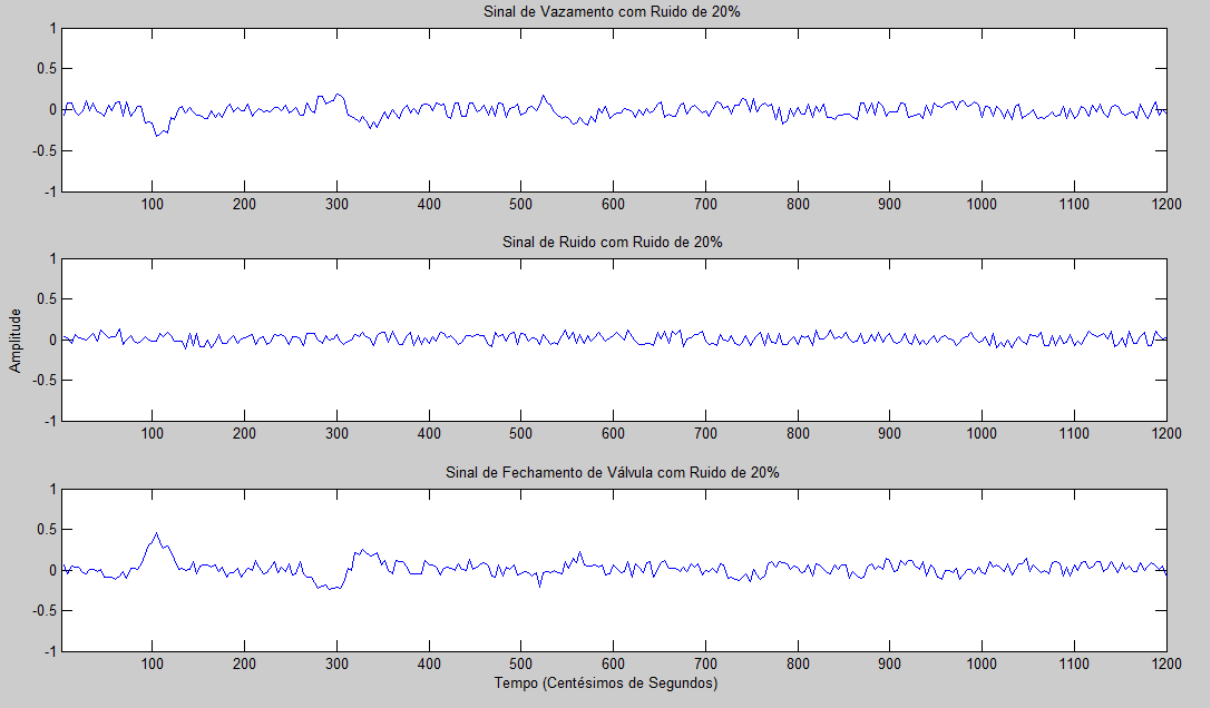

Figura 30 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 20% de ruído (Freq. Inversor de 40Hz; P2; S2).

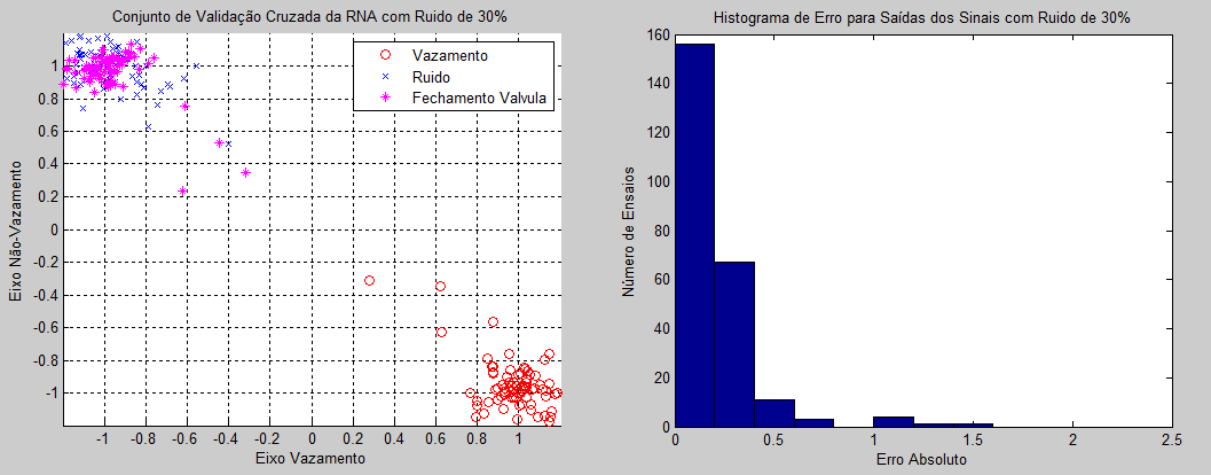

Figura 31 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 30%.

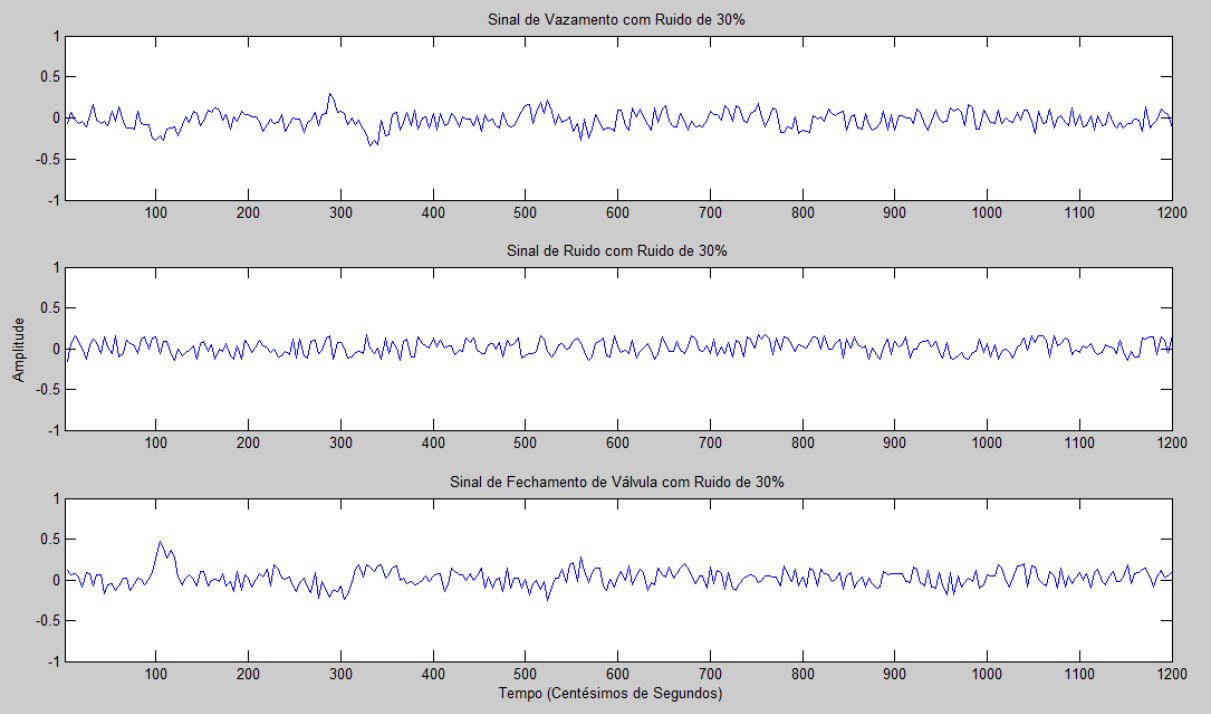

Figura 32 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 30% de ruído (Freq. Inversor de 40Hz; P2; S2).

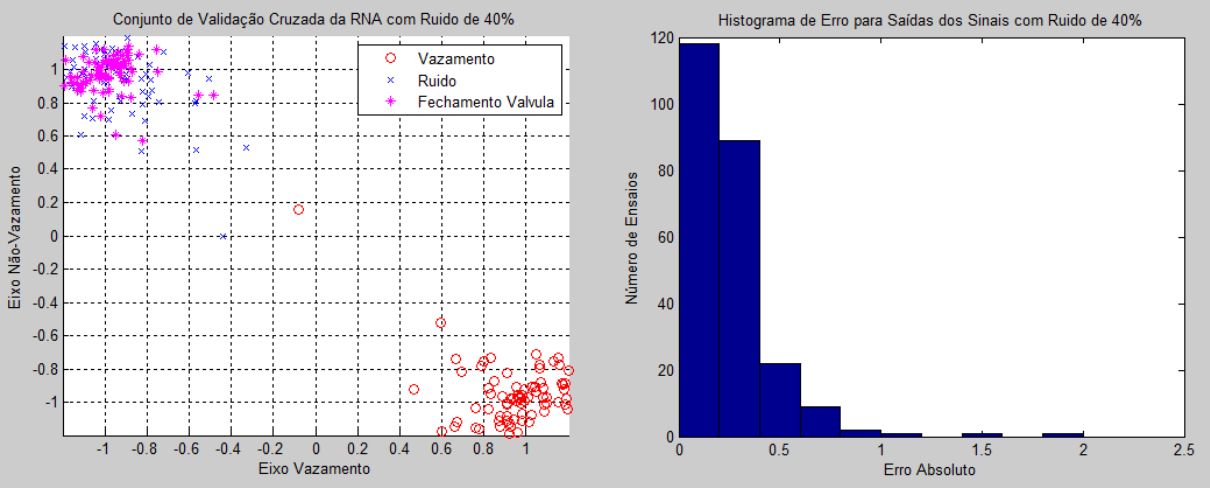

Figura 33 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 40%.

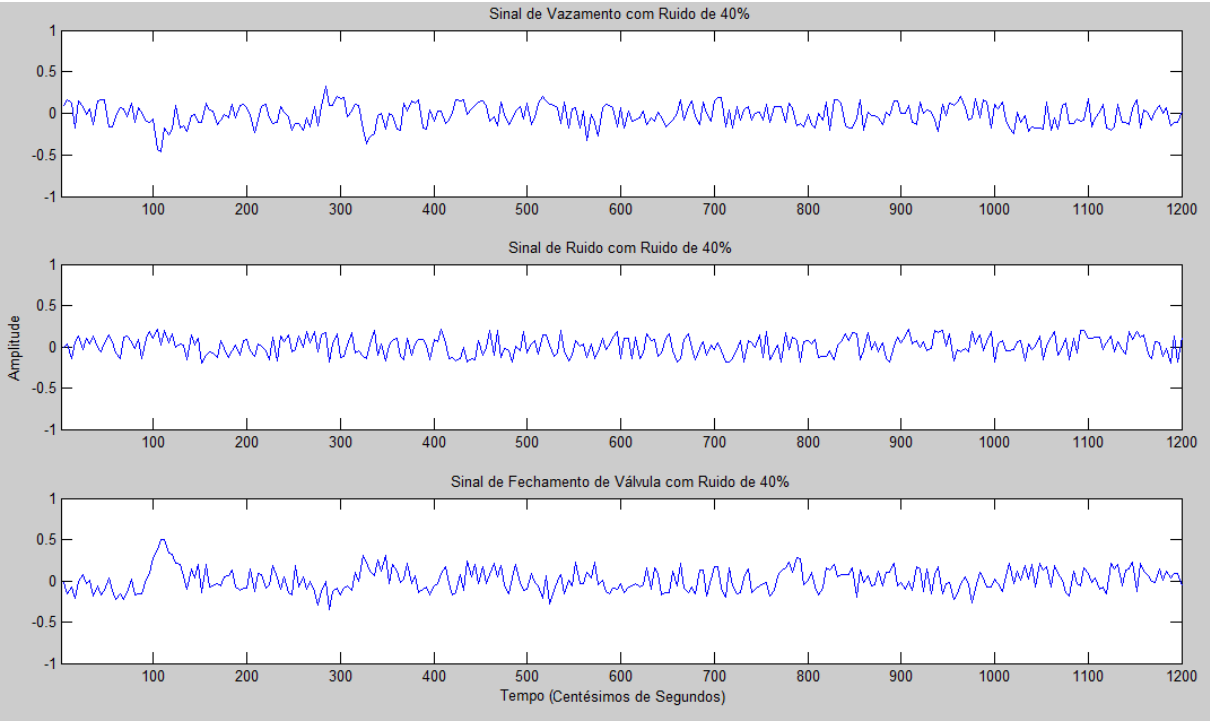

Figura 34 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 40% de ruído (Freq. Inversor de 40Hz; P2; S2).

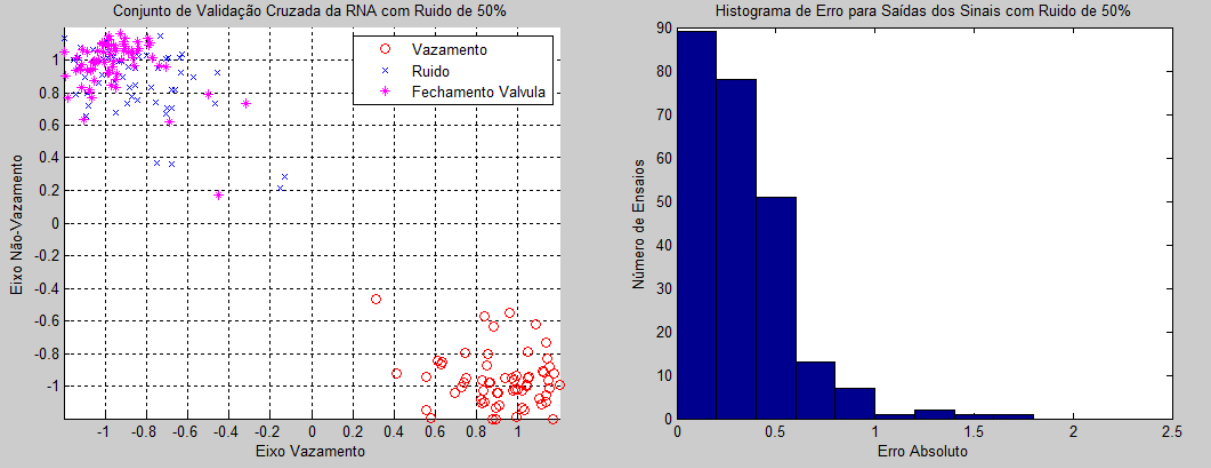

Figura 35 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 50%.

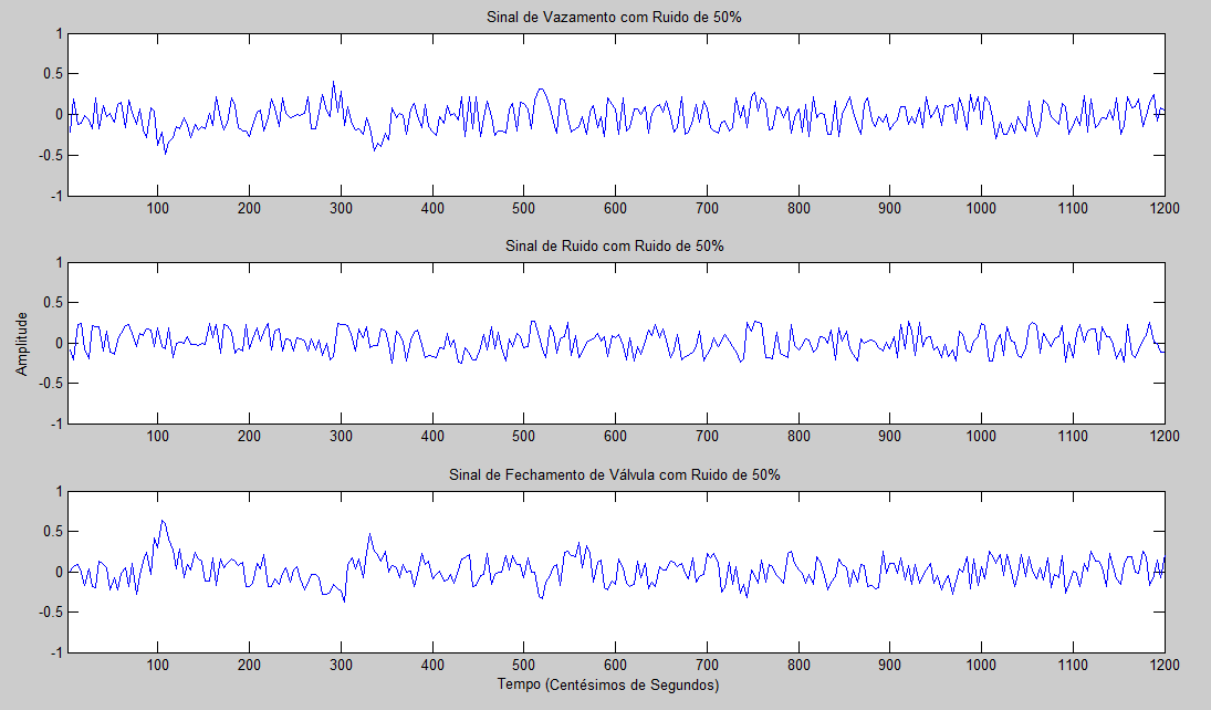

Figura 36 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 50% de ruído (Freq. Inversor de 40Hz; P2; S2).

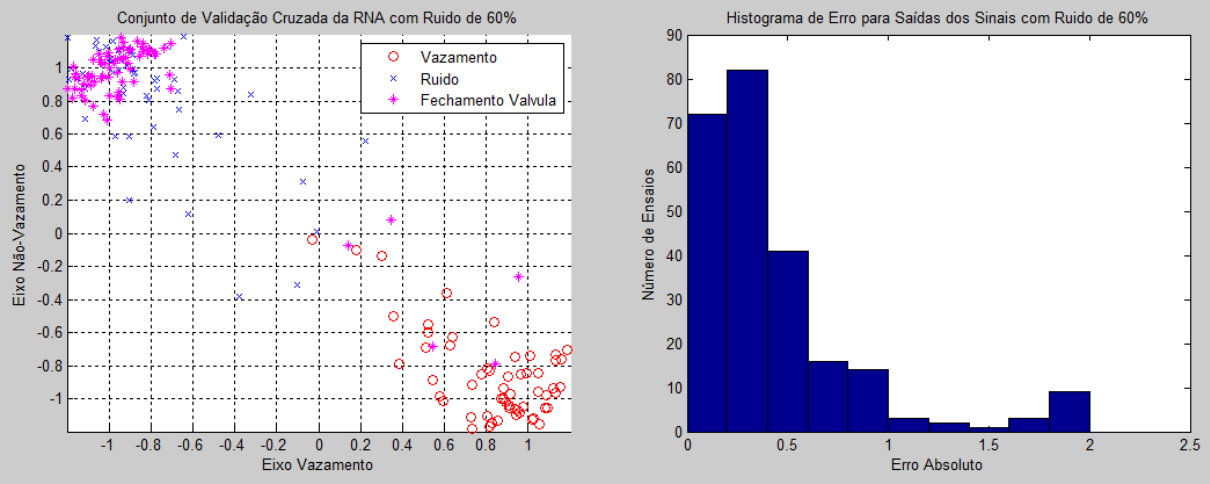

Figura 37 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 60%.

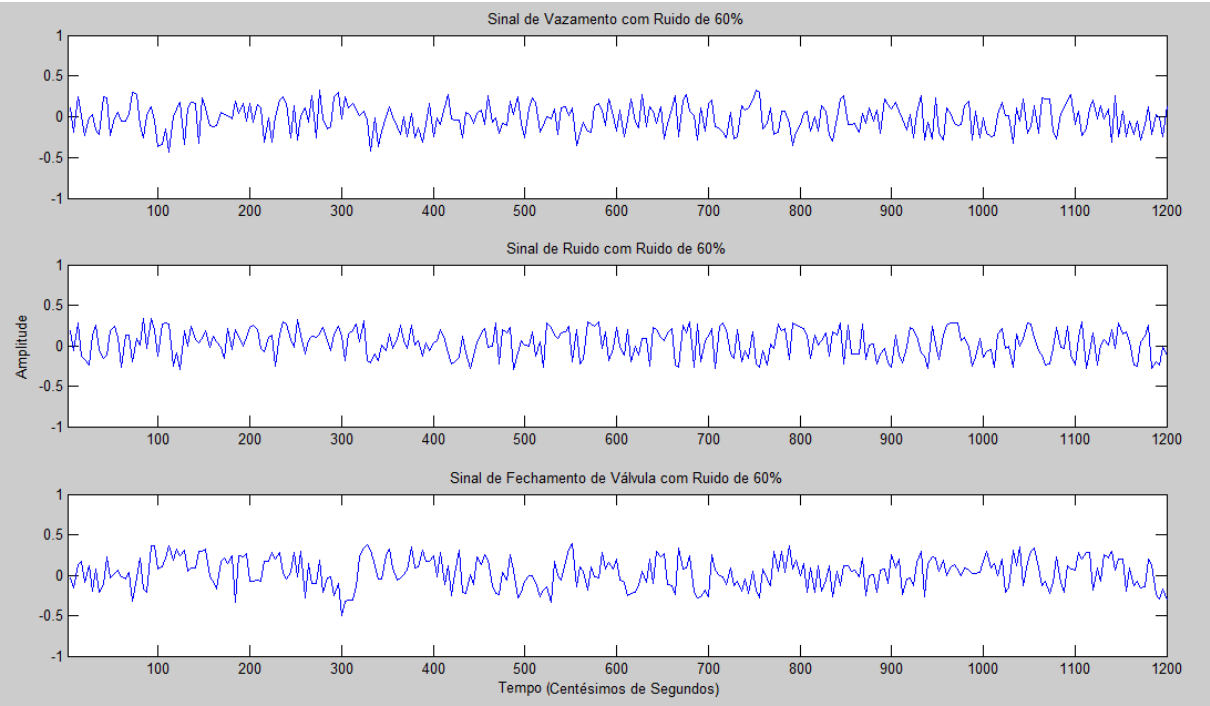

Figura 38 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 60% de ruído (Freq. Inversor de 40Hz; P2; S2).

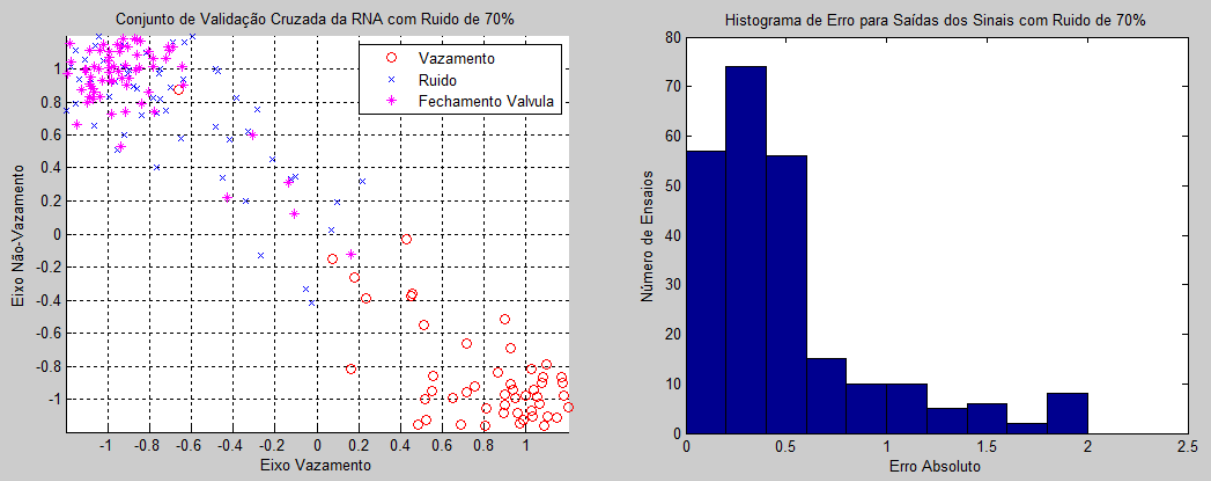

Figura 39 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 70%.

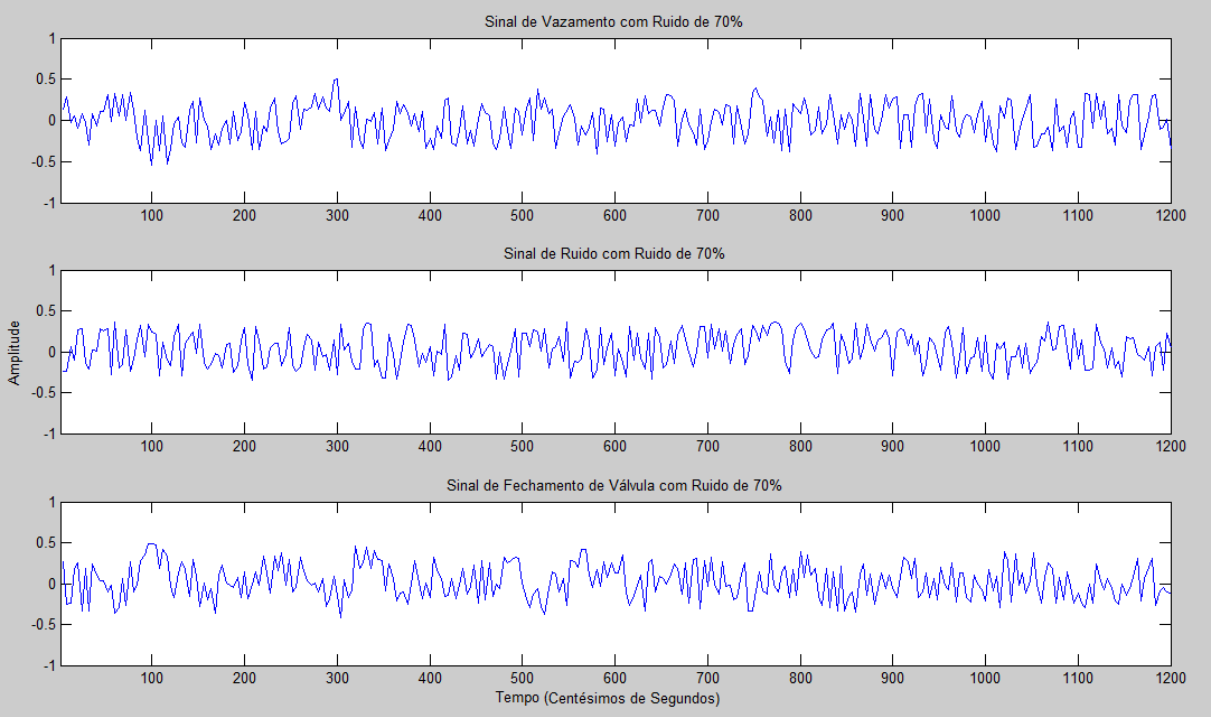

Figura 40 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 70% de ruído (Freq. Inversor de 40Hz; P2; S2).

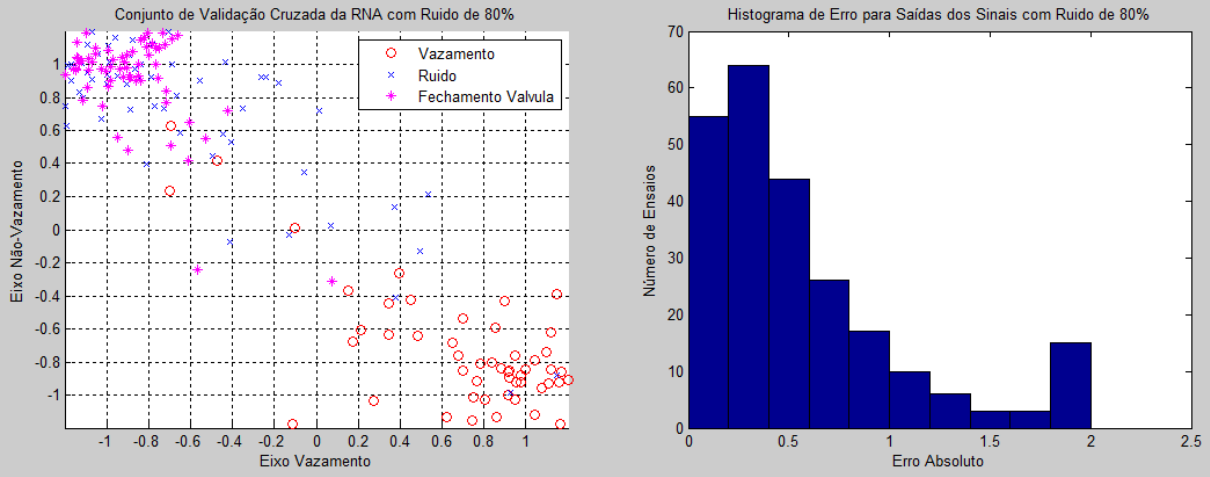

Figura 41 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 80%.

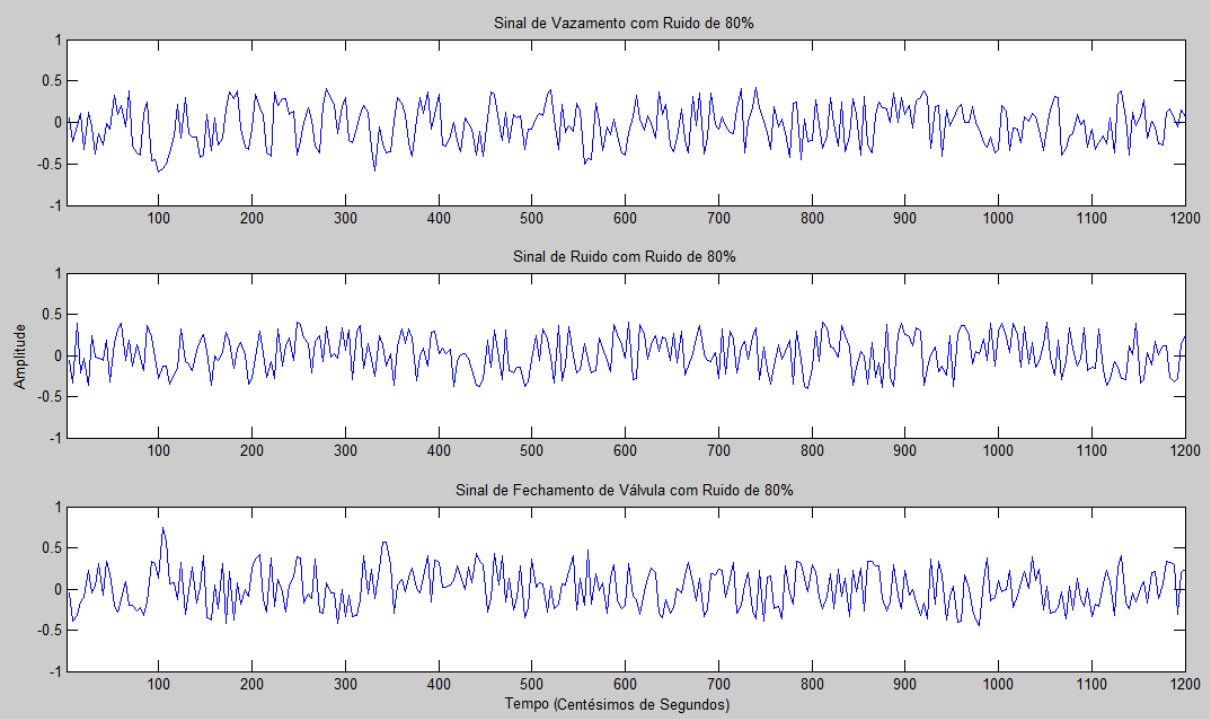

Figura 42 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 80% de ruído (Freq. Inversor de 40Hz; P2; S2).

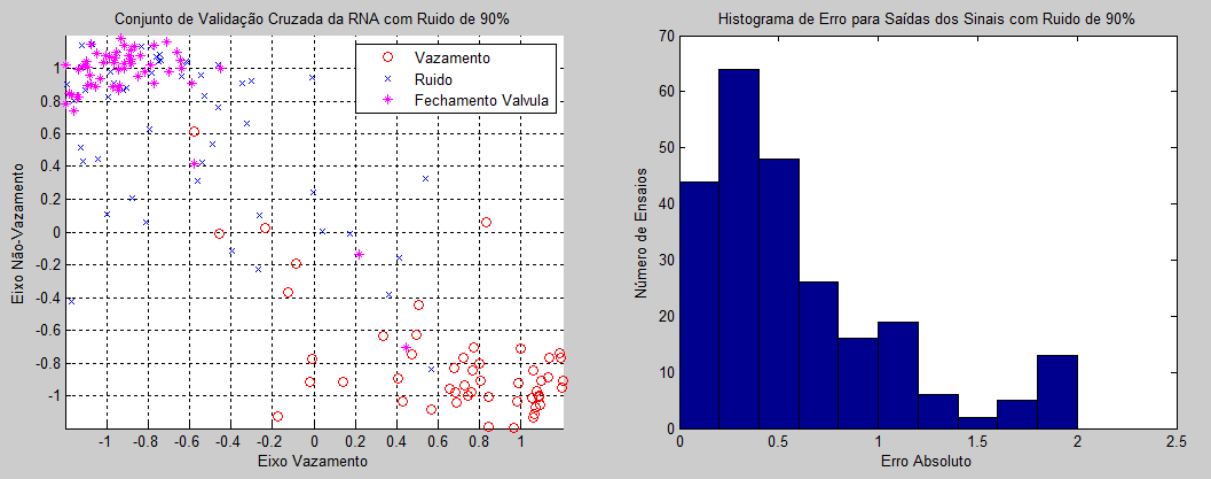

Figura 43 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 90%.

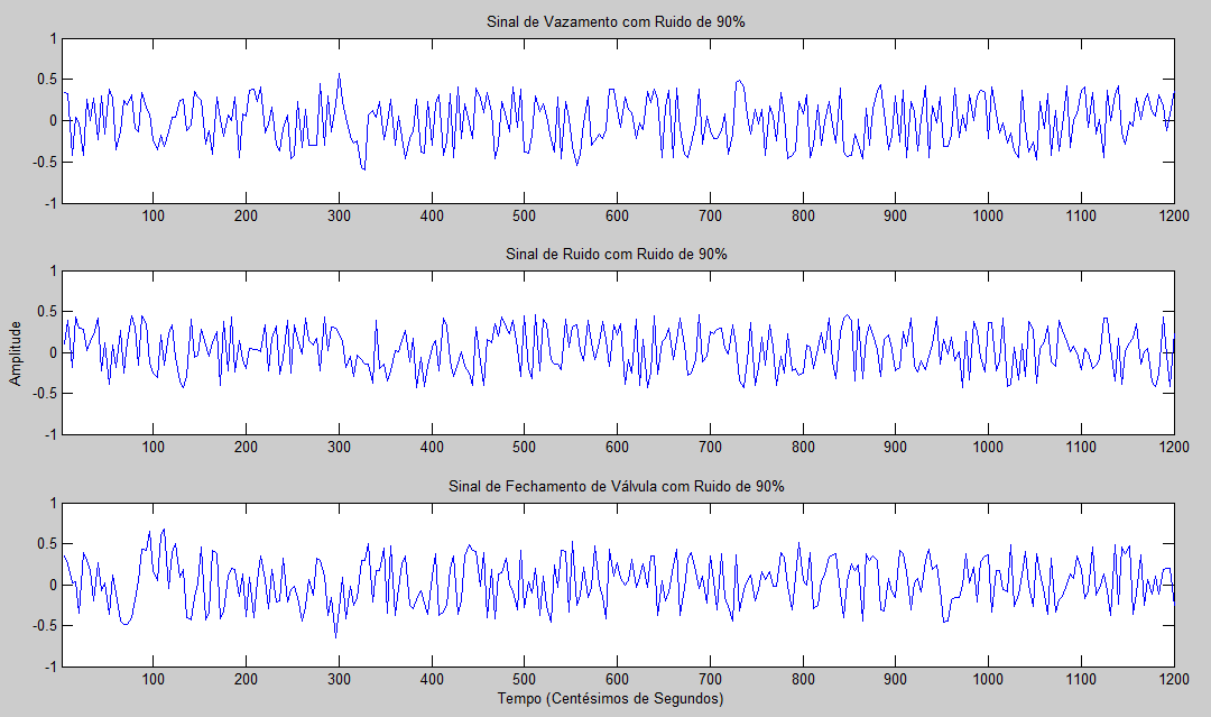

Figura 44 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 90% de ruído (Freq. Inversor de 40Hz; P2; S2).

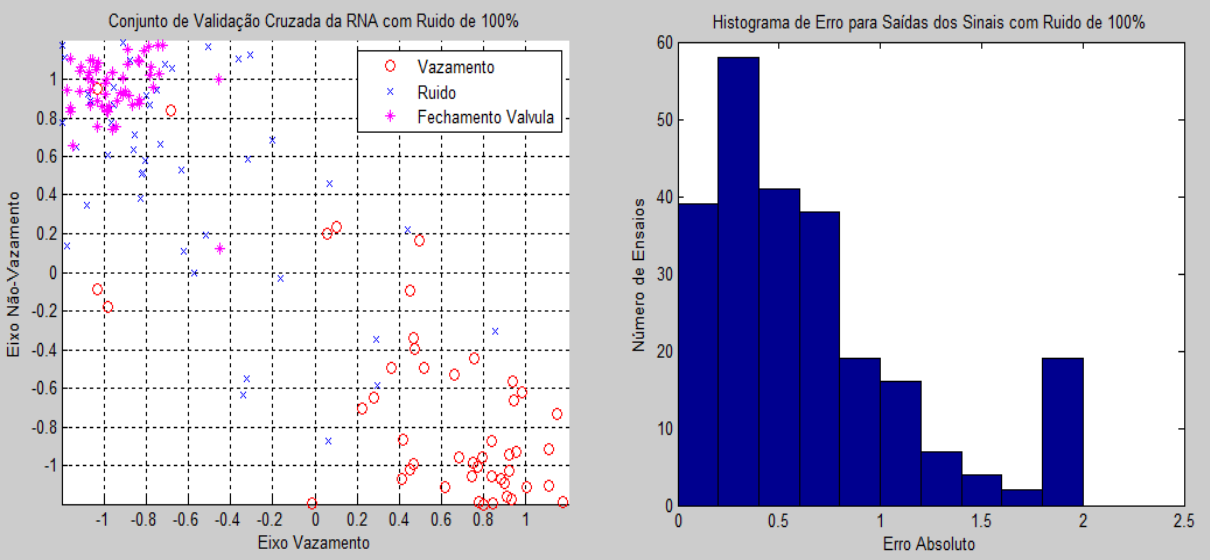

Figura 45 - Classificação e Histograma de Erro Absoluto dos Dados Utilizados para Validação Cruzada com Relação Sinal-ruído de 100%.

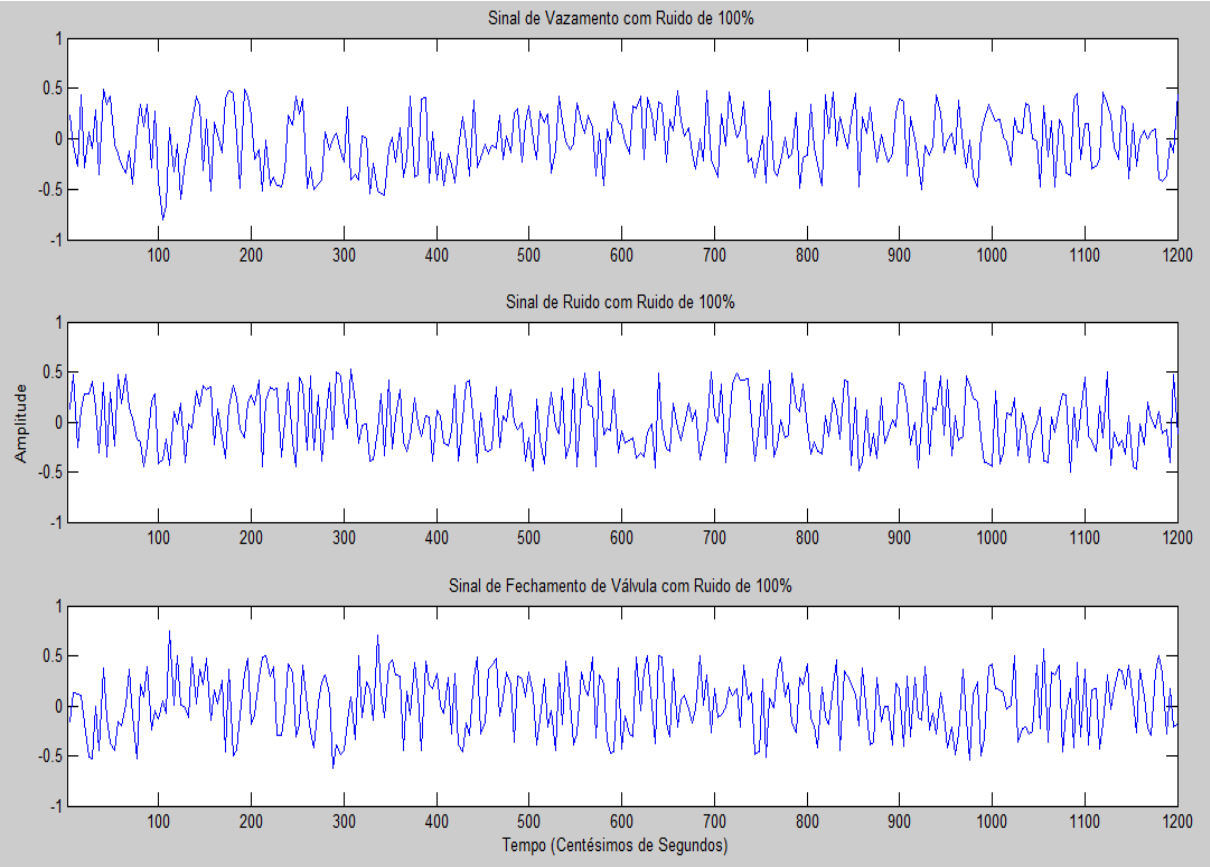

Figura 46 - Exemplo de um Sinal de Vazamento, Ruído e Abertura de Válvula, com incremento de 100% de ruído (Freq. Inversor de 40Hz; P2; S2).

Pela análise das Figuras 25, 27, 29, 31, 33, 35, 37, 39, 41, 43 e 45 comprova-se a robustez da RNA treinada, pois se observa que a RNA produz uma saída satisfatória classificando os vazamentos e não vazamentos em 2 regiões distintas e linearmente separáveis, através de uma função identidade para uma relação sinal-ruído de até 50%.

Para uma relação sinal-ruído igual ou superior a 60% o elevado número de vazamentos classificados na região de não-vazamentos e também o número de não vazamentos classificados como vazamentos, têm-se que a RNA não produziu uma resposta satisfatória.

As Figuras 26, 28, 30, 32, 34, 36, 38, 40, 42, 44, 46 exemplificam o sinal adquirido no sensor P2, para teste de vazamento na válvula V2 e freqüência da bomba de 40Hz, somado a ruídos, cuja relação sinal-ruído é de 5, 10, 20, 30, 40, 50, 60, 70, 80, 90 e 100%, respectivamente.

5. CONCLUSÕES E PERSPECTIVAS

Nesta dissertação foram estudados os fundamentos do funcionamento das redes neurais artificiais e apresentada uma técnica para reconhecimento de um padrões de vazamentos abruptos, utilizando uma rede neural *Perceptron feed-forward* com 2 camadas neurais, treinada como um classificador de sinais de vazamentos e não vazamentos, através do método de aprendizado *backpropagation*.

Foram realizados experimentos no oleoduto piloto do NETeF para capturar padrões de vazamentos e não vazamentos (ruídos de fundo da tubulação e sinais de fechamento de válvula). Os padrões de vazamento foram obtidos realizando o acionamento de uma válvula solenóide de abertura rápida.

De acordo com os dados apresentados no item 4, em especial, nos resultados obtidos com a validação cruzada da rede neural, os resultados obtidos foram extremamente satisfatórios, tendo sido, neste caso, a rede neural artificial capaz de generalizar sinais de vazamento.

Ainda, com os resultados obtidos no item 4.1, pôde-se observar a robustez da rede quando a interferência de ruídos nos sinais de entrada.

Devido ao baixo custo computacional para o processamento da rede neural em estudo, a mesma pode facilmente ser implementada em *hardwares* embarcados com processador de ponto flutuante, como por exemplo, o *Programmable Automation Controller (PAC)* utilizado para realização dos experimentos deste estudo.

Como sugestão para trabalhos futuros pode-se destacar 3 pontos de grande interesse:

- Obter resultados de diferentes padrões, tais como partida e parada de bomba e golpes de aríete no escoamento e analisar a robustez da rede para classificar tais padrões como não vazamento.
- Estudar a eficiência de outras topologias de rede neural *Perceptron feedforward*, com diferentes números de camadas escondidas e neurônios, bem como analisar redes neurais com funções de ativação de base radial, tais como RBF, para efetuar a

classificação de um padrão de vazamento e comparar com os resultados obtidos neste trabalho;

- Analisar características dos sinais de vazamento, tais como, variância, média, média quadrática, transformada de Fourier, transformadas *wavelets* e inserir tais características como entradas da rede neural.
- Reconhecer sinal característico de vazamento em transientes hidráulicos (partida e parada de bomba, dentre outros)

De uma forma geral, o objetivo de estudar a aplicação de redes neurais multicamadas do tipo *Perceptron* para a classificação de um padrão de vazamento foi atingido.

REFERÊNCIAS BIBLIOGRÁFICAS

BORCHARDT F. L. (1988). *Neural Network Computing and Natural Language Processing*. Calico Journal, v. 5, n°. 4, p. 63-75.

CARPENTER G. A.; GROSSBERG S. (1988). *The ART of adaptative pattern recognition by self-organizing neural network*. IEEE Computer Society, v. 21, n°. 3, p. 77-88.

CASTRO A. P. A.; SILVA J. D. S. (2002). *Detecção de bordas com redes neurais BAM e ART*. I Workshop dos Cursos de Computação Aplicada do INPE. 2002.

CHUA L.O.; YANG L. (1988). *Cellular neural networks: theory*. IEEE Transactions on Circuits and Systems, v. 35, n°. 10, p. 1257-1272.

COHEN, L. (1995). *Time-frequency analysis.* New Jersey, Prentice-Hall.

CYBENKO, G.V. (1989). *Approximation by Superpositions of Sigmoidal Function*. Mathematics of Control, Signals and Systems, v. 2, n°. 4, p. 303-314.

DEMUTH H.; BEALE M.; HAGAN M. (2010). *Neural network toolbox – User's guide, version 6.0.4*. The Mathworks Inc., 901p.

FERRANTE M.; BRUNONE B. (2003). *Pipe system diagnosis and leak detection by unstead-state tests 2: Wavelet analysis*. Advances in Water Resources, v.26, nº 1, p. 107-116.

FILIPATTI F.; FRANCESCHINI G.; TASSONI C.; VAS P. (2000). *Recent developments of induction motor drives fault diagnosis using AI techniques*. IEEE Transactions on Industrial Eletronics, v. 47, n°. 5, p. 994-1004.

GASPAR, T. L. (2006). *Reconhecimento de faces humanas usando redes neurais MLP*. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 2006.

GOEDTEL, A. (2007). *Estimador neural de velocidade para motores de indução trifásicos.* Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 2007.

GUYON I. (1991). *Neural networks and applications tutorial*. Physics Reports, v. 17 n°. 3, p. 215-259.

HEMANDE, A.; CONDACSE, V.; MODISETTE J. (1995). *New system pinpoints leak ethylene pipeline*. Pipeline & Gas Journal, v. 222, nº. 4, p. 38-41.

HOPFIELD J. J. (1982). *Neural networks and physical systems with emergent collective computational abilities*. Proceedings of the National Academy of Sciences of the USA, v. 79, p. 2555-2558.

HUNT K. J.; HAAS R.; SMITH R. M. (1996). *Extending the functional equivalence of radial bases function networks and fuzzy inference systems*. IEEE Transactions on Neural Networks, v. 7 n°. 3, p. 776-781.

KELEMEN J. (2007). *From artificial neural networks to emotion machines with Marvin Minsky*. Acta Polytechnica Hungarica, v. 4, n°. 4, p. 5-16.

KOHONEN T. (1972). *Correlation matrix memories*. IEEE Transactions on Computers, v. 21, n°. 4, p. 353-359.

KHOMAIRI, A. A. (2008). *Leak detection in long pipelines using the least square method*. Journal of Hydraulic Research, v. 46, n°. 3, p. 392-401.

LI Y. B.; SUN L. Y. (2009). *Leakage detection and location for long range oil pipeline using negative pressure wave technique*. 4th IEEE Conference of Industrial Electronics and Application, ICIEA'2009, v.1-6.

LIGGETT J. A., CHEN L.C. (1994). *Inverse transient analysis in pipe networks*. Journal of Hydraulic Engineering, v. 120, n°. 8, p. 934-955.

LUKE D. H. (1999). *The origins of the sampling theorem.* IEEE Communications Magazine, v. 37, n°. 4, p. 106-108.

MALSBURG V. D. (1973). *Self-organization of orientation sensitive cells in the striate cortex*. Kybernetik, n°. 14, p. 85-100.

MCCULLOCH W. S.; PITTS W. H. (1943). *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics, v. 5, p. 115-133.

NATIONAL INSTRUMENTS INC. (2008). *CompactRIO and LabVIEW development fundamentals – Course Manual.* 226p.

PAPADAKIS G. A.; PORTER S.; WETTING J. (1999). *EU initiative on the control of major accident hazards arising from pipelines*. Journal of Loss Prevention in The Process Industries, v. 12, n°. 1, p. 85-90.

PICCININI G. (2004). *The first computational theory of mind and brain: a close look at McCulloch and Pitts's "Logical calculus of ideas immanent in nervous activity"* Kluwer Academic Publisher, v. 141, p. 175-215.

REID R. J.; FRAME J. S. (1975). *Convergence in iteratively formed correlation matrix memories.* IEEE Transactions on Computers, v. 24, n°. 8, p. 827-830.

ROSENBLATT F. (1958). *The Perceptron: a probabilistic model for information storage and organization in the brain*. Psychological Review, v. 65, n°. 6, p. 386-408.

RUMELHART D. E.; HINTON G. E.; WILLIANS R. J. (1986). *Learning representations by back propagation errors*. Nature, v. 323, n°. 9, p. 533-536.

RUSSELL S. J.; NORVIG P. (1995). *Artificial Intelligence: a modern approach.* Prentice Hall, 932 p.

SELLI, M. F. (2007). *Identificação de padrões de escoamento horizontal bifásico gás-líquido através de distribuição tempo-freqüência e redes neurais*. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 2007.

SELLI, M. F.; SELEGHIM P. J. (2007). *On-line identification of horizontal two-phase flow regimes through Gabor transform and neural network processing.* Heat Transfer Engineering, v. 28, n°. 6, p. 541-548.

SIMÕES, A. S. (2000). *Segmentação de imagens por classificação de cores: uma abordagem neural.* Dissertação (Mestrado) – Escola Politécnica, Universidade de São Paulo, São Paulo. 2000.

STOUFFS J.; MICHEL G. (1993). *Pipeline leak detection based on mass balance: Importance of the packing term*. Journal of Loss Prevention in the Process Industries. v. 6, n°. 5, p. 307-312.

TAGLIARINI G. A.; CHRIST J. F.; PAGE E. W. (1991). *Optimization using neural network*. IEEE Transactions on Computers, v. 40, n°. 12, p. 1347-1358.

TEES R.C. (2002). *Review of the organization of behavior: a neuropsychological theory by Donald O. Hebb (1949)*. Canadian Psychological Association v. 44. 2002.

TIMOSZCZUK, A. P. (2004). *Reconhecimento automático do locutor com redes neurais pulsadas*. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo, São Paulo. 2004.

WANG, X. J., LAMBERT, M. F., SIMPSON, A. R., LIGGETT, J. A., VITKOVSKY, J. P. (2002). *Leak detection in pipelines using the damping of fluid transients.* Journal of Hydraulic Engineering, v. 128 n°. 7, p. 697-711.

WIDROW B.; LEHR M. A. (1990). *30 years of adaptative neural networks: Perceptron, Madaline, and Backpropagation*. Proceedings of the IEEE, v. 78, n°. 9, p. 1415-1442.

WILLSHAW D. J.; MALSBURG V. D. (1976). *How patterned neural connections can be set up by self-organization*. Proceedings of the Royal Society of London. Series B, Biological Science, v. 194, n°. 1117, p. 431-445.

WU Z. Y., SAGE P. (2006). *Water loss detection via genetic algorithm optimization-based model calibration*. Journal of Water Resources Planning and Management, v. 136, n°. 1, p. 116-128.

APÊNDICE A – Diagrama de Blocos dos programas em LabVIEW® para Controle da Planta e Aquisição de dados nos experimentos.

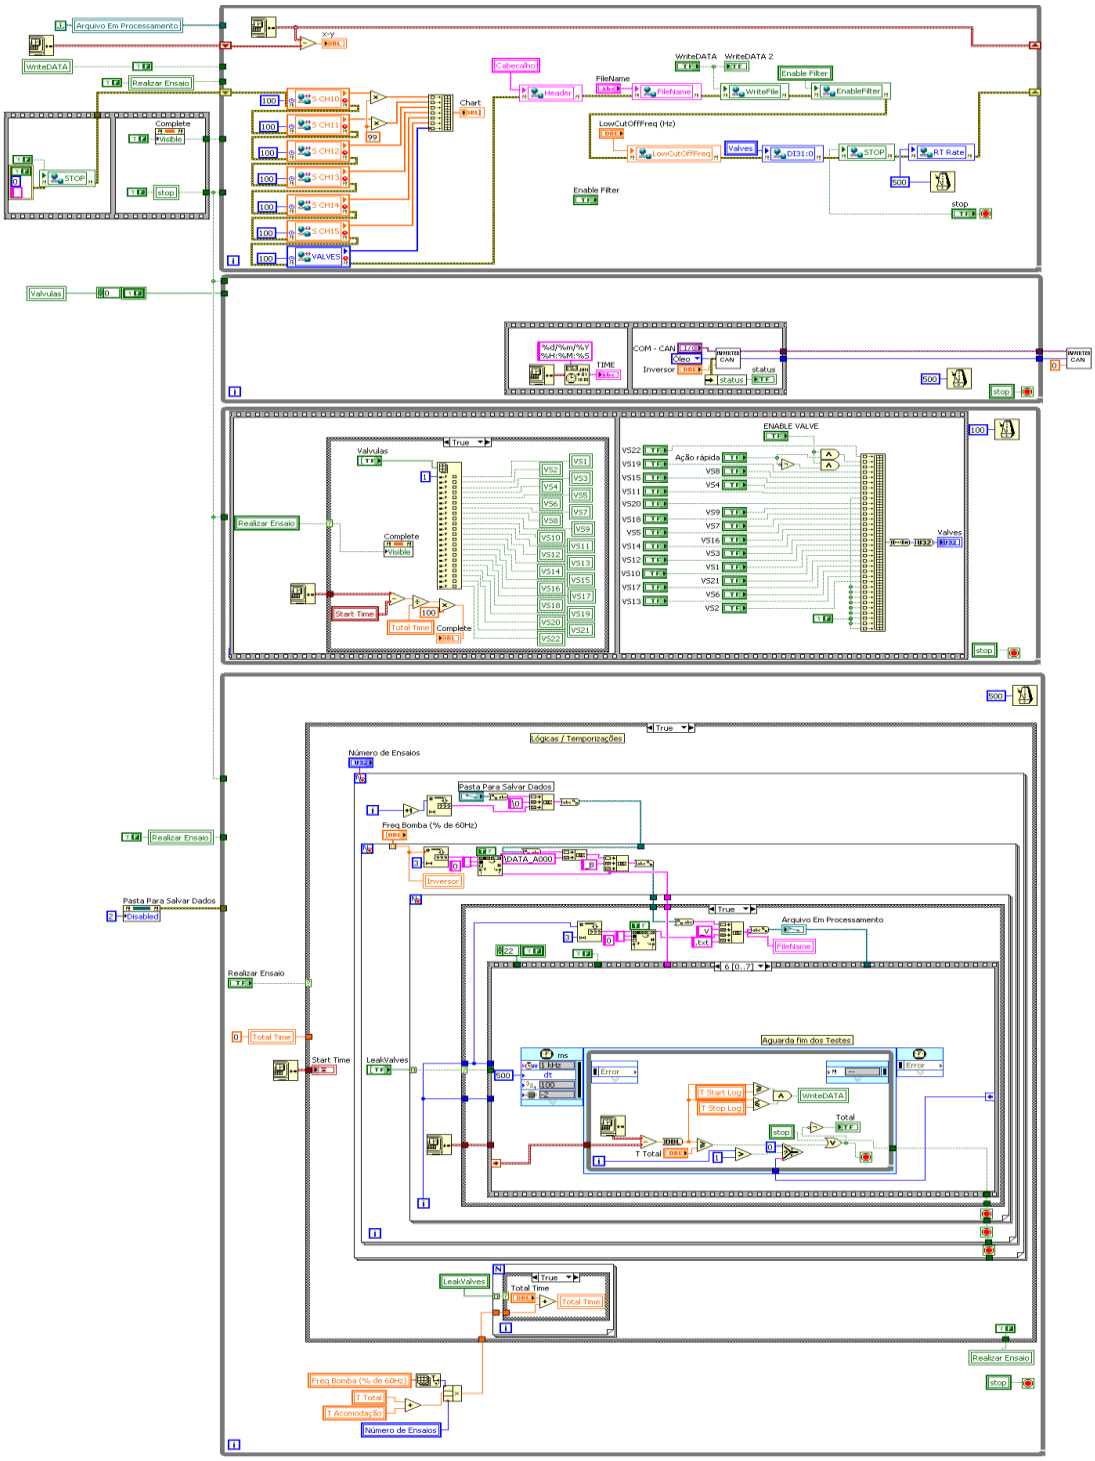

Figura 47 - Diagrama de Blocos do *software* em LabVIEW® que é executado em um computador do tipo PC.

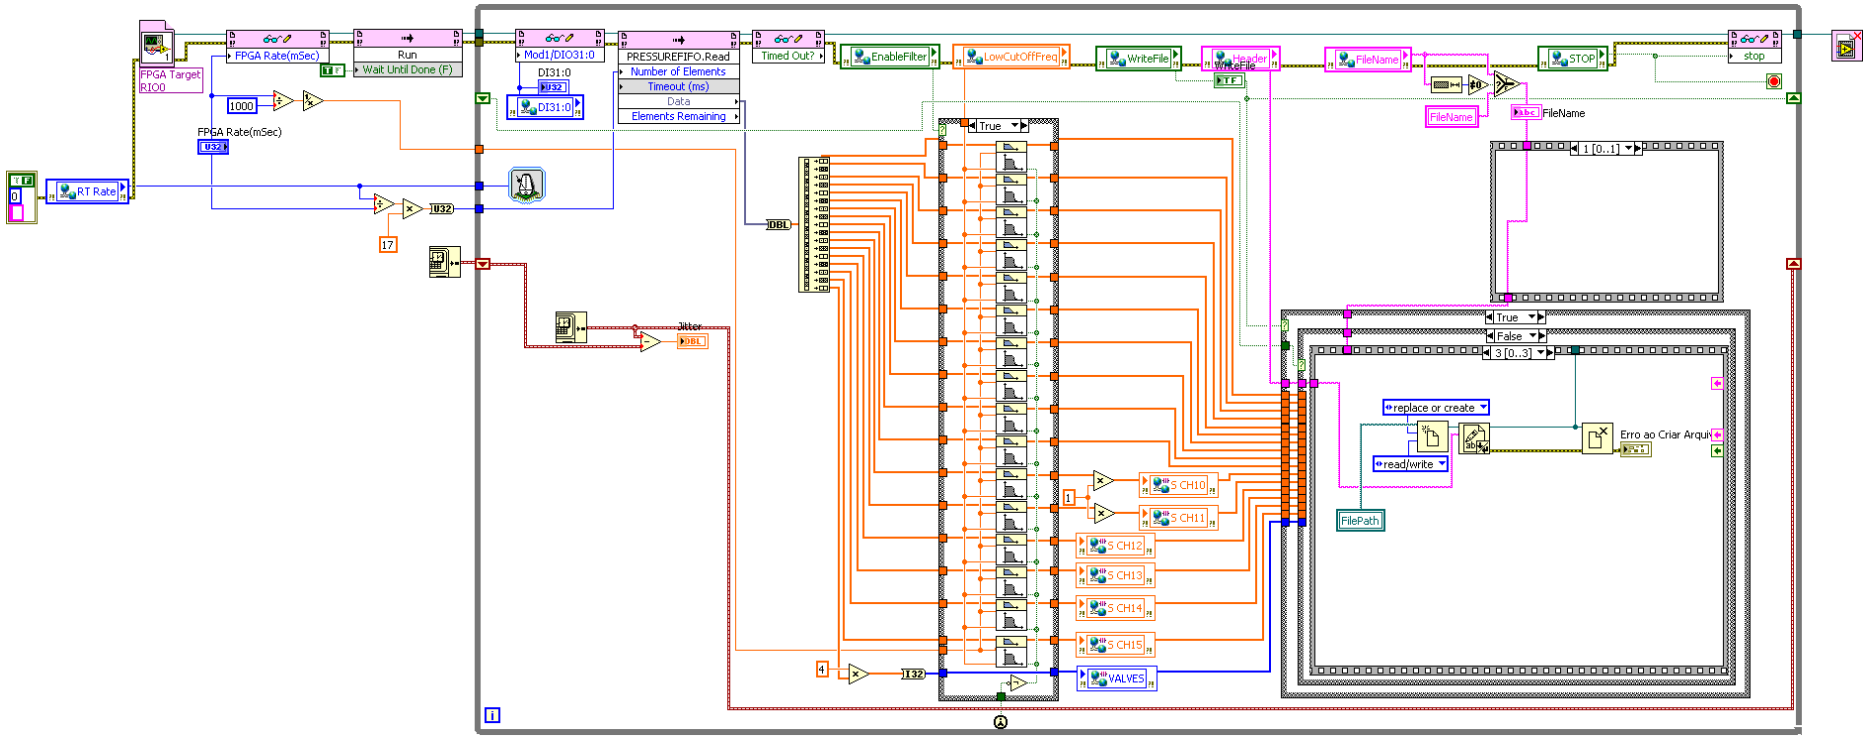

Figura 48 - Diagrama de Blocos do *software* em LabVIEW® que é executado no controlador de tempo real (NI cRIO 9014).

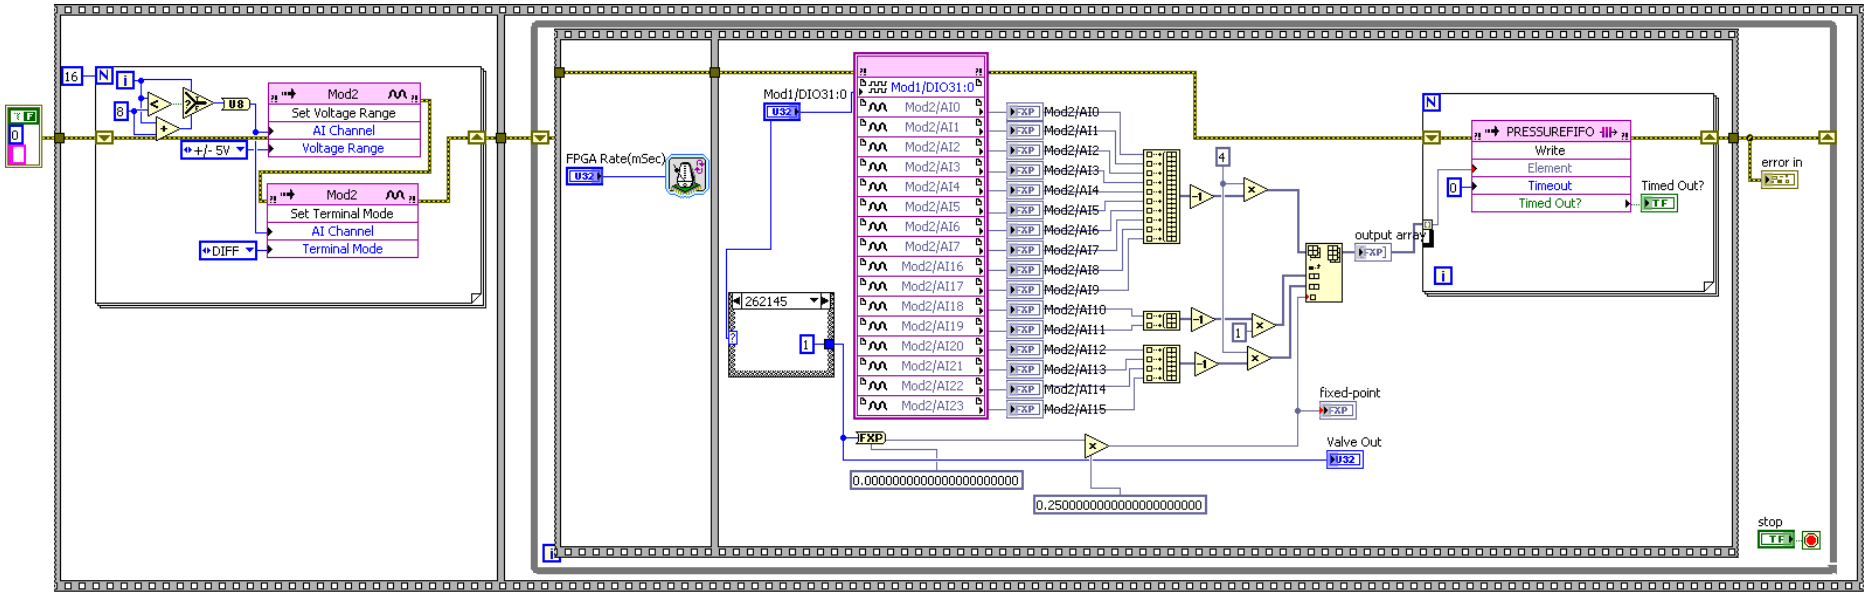

Figura 49 - Diagrama de Blocos do *software* em LabVIEW® que é executado em FPGA (NI cRIO 9114).