



**Universidade do Estado do Rio de Janeiro**

Centro de Tecnologia e Ciências

Faculdade de Engenharia

Marcos Antônio Andrade de Oliveira

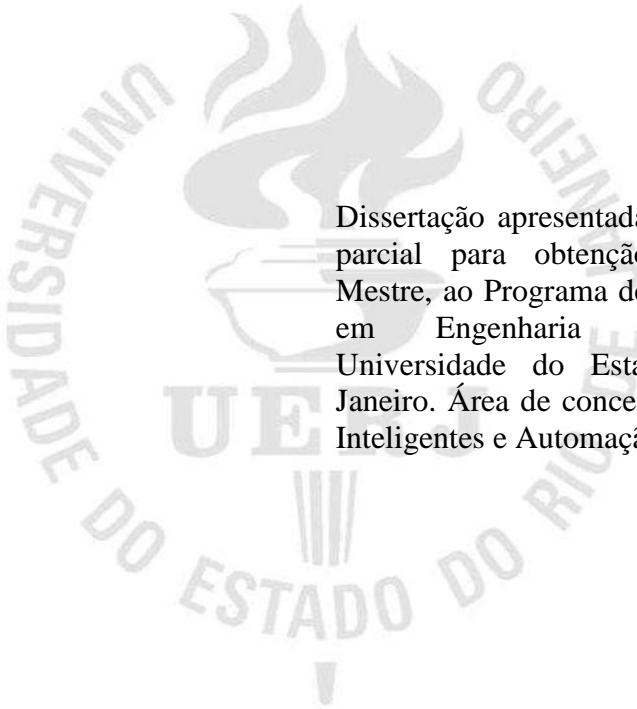
**Desenvolvimento de um medidor de vazão termal inteligente**

Rio de Janeiro

2010

Marcos Antônio Andrade de Oliveira

## **Desenvolvimento de um medidor de vazão termal inteligente**



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós- Graduação em Engenharia Eletrônica da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Orientador: Prof. Dr. Jorge Luís Machado do Amaral  
Coorientador: Prof. Dr. José Franco Machado do Amaral

Rio de Janeiro

2010

CATALOGAÇÃO NA FONTE  
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

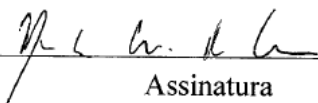
O48 Oliveira, Marcos Antônio Andrade de.  
Desenvolvimento de um medidor de vazão termal inteligente /  
Marcos Antônio Andrade de Oliveira. – 2010.  
113 f.

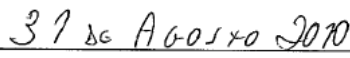
Orientador: Jorge Luís Machado do Amaral.  
Coorientador: José Franco Machado do Amaral.  
Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro,  
Faculdade de Engenharia.

1. Medição – instrumentos – Dissertações. 2. Vazão – medidores -  
Dissertações. 3. Engenharia Eletrônica – Dissertações. I. Amaral, Jorge  
Luís Machado do. II. Universidade do Estado do Rio. III. Título.

CDU 621.317.7

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta  
tese, desde que citada a fonte.

  
Assinatura

  
Data

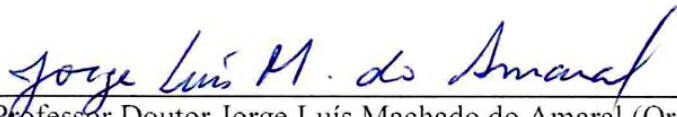
Marcos Antônio Andrade de Oliveira

## Desenvolvimento de um Medidor de Vazão Termal Inteligente

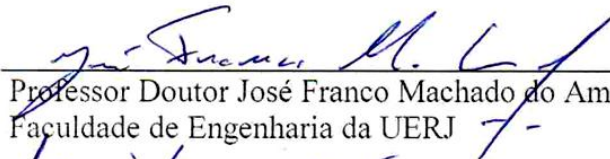
Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós- Graduação em Engenharia Eletrônica da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Aprovado em 07 de julho de 2010

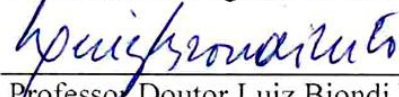
Banca Examinadora:



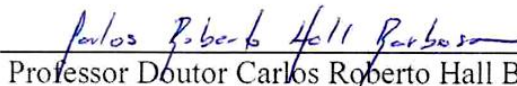
Professor Doutor Jorge Luís Machado do Amaral (Orientador)  
Faculdade de Engenharia da UERJ



Professor Doutor José Franco Machado do Amaral (Co-Orientador)  
Faculdade de Engenharia da UERJ



Professor Doutor Luiz Biondi Neto  
Faculdade de Engenharia da UERJ



Professor Doutor Carlos Roberto Hall Barbosa  
Programa de Pós-graduação em Metrologia para Qualidade e Inovação (PUC-RJ)

Rio de Janeiro

2010

## **DEDICATÓRIA**

À minha esposa Adriana, e à minha filha Tatiana, pelo apoio e compreensão.

## AGRADECIMENTOS

A Deus pelo dom da vida e proteção constante.

Ao professor Jorge Luís Machado do Amaral pela orientação, dedicação, paciência e amizade.

Ao professor José Franco Machado do Amaral um agradecimento especial pela compreensão e amizade.

Ao amigo Elton Santana pela ajuda nas revisões e dicas.

Aos amigos Cláudio Carraro e Neide Kawabata por terem acreditado no nosso potencial e nos apoiado nessa jornada.

Ao inestimável amigo José Evanildo pela ajuda através dos excelentes trabalhos prestados na área de tornearia.

Ao grande amigo José Flávio Pessoa de Barros pelo constante incentivo na busca do conhecimento científico.

Aos companheiros da Especialização em Engenharia Mecatrônica da UERJ: Aleci Paulo Dias e Álvaro Moreira.

Aos nossos pais, familiares e amigos pelo carinho, sem eles este trabalho não existiria.

Aos Laboratórios B.Braun S.A. pela oportunidade e apoio para realização deste projeto.

À UERJ e aos professores do programa de pós-graduação em engenharia eletrônica pelo apoio.

## RESUMO

OLIVEIRA, Marcos A. A. de. *Desenvolvimento de um Medidor de Vazão Termal Inteligente*, 2010. Dissertação (Mestrado em Engenharia Eletrônica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2010.

Técnicas não-intrusivas de medição de vazão constituem uma necessidade crescente em diversas aplicações. Atualmente, diversos estudos têm sido realizados com o objetivo de desenvolver técnicas de medição não-intrusivas que possam suprir as deficiências das técnicas existentes. Este trabalho visa desenvolver um medidor de vazão baseado no princípio de convecção forçada (termal) não-intrusivo inteligente. O medidor utiliza dois transdutores RTD comerciais do tipo PT100, um aquecido, que é responsável pela medição da velocidade de escoamento, e o outro utilizado como referência de set-point de temperatura do sensor aquecido. Uma Rede Neural é responsável por corrigir os erros de medição do instrumento. Para a avaliação do medidor construído, foi desenvolvida uma bancada de realização de ensaios, possibilitando a variação da vazão e temperatura na seção de teste. Com o intuito de prover a bancada de uma referência para comparação, foi instalado também um medidor do tipo Venturi normalizado segundo a ABNT.

Palavras chave: Não-Intrusivo. Convecção Forçada. Medição de Vazão. Rede Neural. Calibração. Ajuste.

## **ABSTRACT**

Non-intrusive techniques of flow measurement are very useful in several applications. Nowadays, several studies have been conducted to develop non-intrusive measuring techniques that can overcome the shortcomings of the existing ones. This work aims to design an intelligent non-intrusive flow meter device based on the forced heat convection principle (thermal). This device uses two commercial RTD transducers (PT100), one is used as reference of temperature set-point, and the other is responsible for the flow measurement. A neural network is responsible for correcting the errors in relation to the calibration standard. To evaluate the intelligent flow meter, test bench was built. In order to provide another flow meter to compare the results, an ABNT Venturi type flow meter was installed in the test bench.

**Keywords:** Non-intrusive. Forced Convection. Flow Measurement. Neural Network. Calibration. Adjust.



## LISTA DE FIGURAS

Figura 1 - Conceito básico conceito básico de sensor inteligente .....	18
Figura 2 - Rede Neural Genérica.....	20
Figura 3 - Rede Multilayer Perceptron (MLP) .....	20
Figura 4 - Características dos transdutores.....	26
Figura 5 - Medidor eletromagnético Williams (SHERCLIFF ,1962) .....	27
Figura 6 - Campo magnético gerado pelo medidor eletromagnético (NBR ISO 6817,1999)..	28
Figura 7 - Ultrassom por Tempo de trânsito (BRANCO, 2008) .....	30
Figura 8 - Ultrassom Método V (BRANCO, 2008) .....	31
Figura 9 - Ultrassom Método W .....	31
Figura 10 - Perfil de Escoamento .....	33
Figura 11 - Escoamento de Fluidos em um <i>Venturi</i> .....	33
Figura 12 - Detalhe do dimensionamento do tubo <i>Venturi</i> .....	34
Figura 13 - Princípios de medição dos sensores Termiais.....	35
Figura 14 - Detalhe do sensor de fio quente típico.....	37
Figura 15 - Detalhe do Escoamento ao redor da seção do fio .....	37
Figura 16 - Detalhamento do sensor termal intrusivo .....	38
Figura 17 - Diagrama de blocos de um medidor por convecção forçada .....	39
Figura 18 - Conceito básico medidor de Vazão Termal Intrusivo e Não Intrusivo.....	41
Figura 19 - Diagrama de blocos de um medidor de Vazão Termal Inteligente.....	42
Figura 20 - Detalhamento do aquecimento termal não-intrusivo .....	43
Figura 21 - Detalhamento da medição do termal não-intrusivo .....	43
Figura 22 - Detalhamento da referência do termal não-intrusivo.....	44
Figura 23 - Projeto do Sensor Termal .....	45
Figura 24 - Resistência de aquecimento do sensor termal (ativo).....	45
Figura 25 - Isolamento do Sensor Termal (ativo) .....	46
Figura 26 - Montagem final do Sensor Termal (ativo).....	47
Figura 27 - Montagem final do Sensor Termal (lateral).....	48
Figura 28 - Montagem final do Sensor Termal (superior).....	49
Figura 29 - Montagem da isolamento térmica do Sensor Termal.....	49
Figura 30 - Montagem Final do Sensor Termal com isolamento térmica .....	50
Figura 31 - Conservação de Energia do Sensor Termal - Corte longitudinal.....	51
Figura 32 - Bancada de Testes.....	53

Figura 33 - Esquema elétrico da bancada de testes .....	54
Figura 34 - Desenho técnico do tubo <i>Venturi</i> .....	55
Figura 35 - Detalhe das conexões do tubo <i>Venturi</i> .....	56
Figura 36 - Condicionador de fluxo .....	56
Figura 37 - Esquema Elétrico do Amplificador <i>Darlington</i> .....	57
Figura 38 - Curva de Resposta do Amplificador <i>Darlington</i> .....	57
Figura 39 - Esquema elétrico do amplificador com operacional.....	58
Figura 40 - Curva de Resposta do Amplificador c/ Operacional .....	58
Figura 41 - Temperatura externa das luvas de Teflon .....	59
Figura 42 - Temperatura externa das luvas de Celeron .....	60
Figura 43 - Temperatura externa das luvas de Celeron com isolamento de Neoprene .....	61
Figura 44 - Diagrama de Calibração.....	62
Figura 45 - Gráfico da Calibração Elétrica - Tensão.....	64
Figura 46 - Gráfico da Calibração Elétrica - Corrente .....	65
Figura 47 - Gráfico da Calibração Elétrica - Potência.....	65
Figura 48 - Estrutura Utilizada .....	66
Figura 49 - Calibração sem correção da Rede Neural / Dif.: 10 °C - Erro Relativo .....	69
Figura 50 - Calibração sem correção da Rede Neural / Dif.: 10 °C - Erro Absoluto .....	69
Figura 51 - Calibração sem correção da Rede Neural / Dif.: 15 °C - Erro Relativo .....	70
Figura 52 - Calibração sem correção da Rede Neural / Dif.: 15 °C - Erro Absoluto .....	70
Figura 53 - Calibração sem correção da Rede Neural / Dif.: 20 °C - Erro Relativo .....	71
Figura 54 - Calibração sem correção da Rede Neural / Dif.: 20 °C - Erro Absoluto .....	71
Figura 55 - Calibração sem correção da Rede Neural / Dif.: 25 °C - Erro Relativo .....	72
Figura 56 - Calibração sem correção da Rede Neural / Dif.: 25 °C - Erro Absoluto .....	72
Figura 57 - Calibração sem correção da Rede Neural / Dif.: 30 °C - Erro Relativo .....	73
Figura 58 - Calibração sem correção da Rede Neural / Dif.: 30 °C - Erro Absoluto .....	73
Figura 59 - Comparação entre os ajustes de Temperatura Diferencial.....	74
Figura 60 - Comparação entre os ajustes do número de neurônios .....	76
Figura 61 - Comparação entre as temperaturas diferenciais.....	77
Figura 62 - Comparação entre as redes neurais .....	77
Figura 63 - Superfície de correção gerada pela Rede Neural (RN1).....	78
Figura 64 - Superfície de correção gerada pela Rede Neural (RN2).....	79
Figura 65 - Superfície de correção gerada pela Rede Neural (RN3).....	79
Figura 66 - Painel frontal (interface gráfica) do software aplicativo .....	81

Figura 67 - Janela de carga do arquivo de correção .....	82
Figura 68 - Gráfico da calibração com correção da Rede Neural (RN1) - Erro Relativo .....	84
Figura 69 - Gráfico da calibração com correção da Rede Neural (RN1) - Erro Absoluto .....	84
Figura 70 - Gráfico da calibração com correção da Rede Neural (RN2) - Erro Relativo .....	85
Figura 71 - Gráfico da calibração com correção da Rede Neural (RN2) - Erro Absoluto .....	85
Figura 72 - Gráfico da calibração com correção da Rede Neural (RN3) - Erro Relativo .....	86
Figura 73 - Gráfico da calibração com correção da Rede Neural (RN3) - Erro Absoluto .....	86

## LISTA DE TABELAS

Tabela 1 - Características dos medidores de vazão .....	27
Tabela 2 - Comparação das características dos medidores de vazão .....	40
Tabela 3 - Resultado da Calibração Elétrica - Tensão.....	63
Tabela 4 - Resultado da Calibração Elétrica - Corrente .....	63
Tabela 5 - Resultado da Calibração Elétrica - Potência .....	64
Tabela 6 - Teste de Histerese (sem correção pela Rede Neural) - Dif. 25°C / Ar 50°C .....	75
Tabela 7 - Calibração com correção da Rede Neural / Ar: 35 °C.....	87
Tabela 8 - Calibração com correção da Rede Neural / Ar: 40 °C.....	88
Tabela 9 - Calibração com correção da Rede Neural / Ar: 45 °C.....	88
Tabela 10 - Calibração com correção da Rede Neural / Ar: 50 °C.....	88
Tabela 11 - Teste de Histerese (com correção pela Rede Neural) - Dif. 25°C / Ar 50°C.....	90

## SUMÁRIO

	<b>INTRODUÇÃO .....</b>	<b>13</b>
<b>1</b>	<b>CALIBRAÇÃO E AUTO-AJUSTE.....</b>	<b>15</b>
<b>1.1</b>	<b>Importância da Calibração e do auto-ajuste .....</b>	<b>15</b>
<b>1.2</b>	<b>Sensores Inteligentes .....</b>	<b>17</b>
<b>2</b>	<b>REDES NEURAIS.....</b>	<b>19</b>
<b>2.1</b>	<b>Introdução.....</b>	<b>19</b>
<b>2.2</b>	<b>Aplicações de Redes Neurais em sensores.....</b>	<b>24</b>
<b>3</b>	<b>MEDIDORES DE VAZÃO .....</b>	<b>26</b>
<b>3.1</b>	<b>Medidor de Vazão do Tipo Eletromagnético .....</b>	<b>27</b>
<b>3.2</b>	<b>Medidor de Vazão do Tipo Ultrassom.....</b>	<b>30</b>
<b>3.3</b>	<b>Medidor de Vazão por pressão diferencial .....</b>	<b>32</b>
<b>3.4</b>	<b>Medidores de Vazão Termiais.....</b>	<b>35</b>
<b>3.4.1</b>	<b><u>Anemometria de fio quente</u> .....</b>	<b>35</b>
<b>3.4.2</b>	<b><u>Medidor de Vazão por convecção forçada</u>.....</b>	<b>37</b>
<b>3.5</b>	<b>Comparação entre os Medidores de Vazão.....</b>	<b>39</b>
<b>4</b>	<b>PROJETO DO MEDIDOR PROPOSTO .....</b>	<b>41</b>
<b>4.1</b>	<b>Idéia Básica sobre o sensor proposto.....</b>	<b>41</b>
<b>4.2</b>	<b>Construção do sensor .....</b>	<b>43</b>
<b>4.3</b>	<b>Modelagem do sensor .....</b>	<b>50</b>
<b>4.4</b>	<b>Descrição da bancada de testes .....</b>	<b>52</b>
<b>4.5</b>	<b>Descrição das alterações da bancada.....</b>	<b>57</b>
<b>4.5.1</b>	<b><u>Calibração Elétrica</u> .....</b>	<b>61</b>
<b>4.6</b>	<b>Proposta para auto-ajuste usando Redes Neurais.....</b>	<b>65</b>
<b>5</b>	<b>AVALIAÇÃO EXPERIMENTAL.....</b>	<b>68</b>
<b>5.1</b>	<b>Validação do modelo .....</b>	<b>68</b>
<b>5.1.1</b>	<b><u>Calibração da Vazão usando a modelagem física</u> .....</b>	<b>68</b>
<b>5.1.2</b>	<b><u>Ajuste do Algoritmo de Correção (Matlab)</u> .....</b>	<b>75</b>
<b>5.1.3</b>	<b><u>Ajuste do Algoritmo de Correção (LabView)</u>.....</b>	<b>80</b>
<b>5.1.4</b>	<b><u>Calibração da Vazão (Inteligente)</u>.....</b>	<b>83</b>
<b>6</b>	<b>CONCLUSÃO .....</b>	<b>91</b>
	<b>REFERÊNCIAS .....</b>	<b>93</b>
	<b>ANEXO - Artigos Publicados em Congressos .....</b>	<b>96</b>

## INTRODUÇÃO

A medição de vazão de fluidos está presente em diversas atividades humanas. O hidrômetro de uma residência e o marcador de uma bomba de combustível são exemplos comuns no dia-a-dia das pessoas, mas ela também pode ser encontrada em uma série de aplicações industriais e científicas tais como: contabilização do total de bebida engarrafada em uma fábrica de refrigerantes, o controle do recebimento de gás/óleo em um gasoduto/oleoduto, o controle de vazão do dialisado e do ultrafiltrado em máquinas de diálise e medições da velocidade do vento em estações meteorológicas e aeroportos.

A grande variedade de aplicações, cada uma com diferentes requisitos, faz como que exista um grande número de medidores disponíveis que utilizam os mais variados princípios de medição. A escolha do medidor dependerá do tipo de fluido (e de suas condições físicas), da exatidão exigida, da faixa de operação, do custo, da complexidade, da facilidade de leitura e do tempo de vida em serviço.

Os medidores podem ser classificados de acordo com a perturbação que o elemento transdutor introduz na medida (BENYOUSEF, 2006). De um modo geral, eles podem ser intrusivos e não-intrusivos. Nos medidores intrusivos, o elemento transdutor fica em contato com o escoamento e torna-se um obstáculo ao fluido, o que gera uma perda de carga. Além disso, pode haver a deposição de materiais e/ou contaminação do escoamento, o que impede a utilização desses medidores em alguns processos, como na diálise em que o equipo, tubo por onde circula a solução de diálise, é estéril, e deve ser mantido assim durante toda a terapia. Um exemplo de medidor intrusivo é o Venturi, onde a vazão é relacionada com o diferencial de pressão entre as seções transversais de maior e menor área do medidor, de acordo com o teorema de Bernoulli (GRUBELNIK, 2005).

No caso dos medidores não-intrusivos não existe o contato entre o fluido e o equipamento de medição, o que proporciona uma série de vantagens em comparação com os medidores intrusivos, tais como: ausência de perda de carga, facilidade de instalação e maior vida útil. Estas vantagens têm aumentado o interesse por medidores não-intrusivos, com destaque para os medidores por indução magnética e por ultrassom (Doppler ou por tempo de trânsito). Entretanto, estes medidores também apresentam algumas desvantagens. Segundo Awwa (1989), os medidores magnéticos só podem ser usados com líquidos que tenham condutividade mínima de  $200\mu\text{S/m}$  e para tubulações de pequeno diâmetro, ele torna-se grande e caro. No caso dos medidores que utilizam ultrassom, aqueles que utilizam o efeito Doppler dependem da reflexão de ondas de ultrassom em partículas suspensas no fluido. Já os

medidores que estimam a vazão por diferença no tempo de trânsito apresentam dificuldade para fazer medições em pequenos diâmetros.

As limitações observadas nos medidores por indução magnética e por ultrassom sugerem a necessidade de pesquisar outras técnicas de medição não-intrusivas. Uma alternativa é a medição de vazão por convecção forçada ou termal, baseada no efeito refrigerante de um fluido que passa sobre um transdutor aquecido.

Este trabalho tem por objetivo pesquisar e desenvolver um medidor de vazão termal inteligente. Ele deve ser não-intrusivo, permitir auto-ajuste e possuir precisão melhor que 5% do valor lido, sendo que nesta precisão devem estar incluídos os fatores de reprodutibilidade e repetitividade.

Normalmente, o princípio de convecção forçada é usado de forma intrusiva sendo necessário buscar alternativas para que ele possa ser usado de forma não-intrusiva.

O auto-ajuste visa facilitar o ajuste e calibração da malha de medição de vazão em campo sem a necessidade de um metrologista, que é o profissional especializado em calibração. Isto vai permitir a correção dos erros devidos às limitações da modelagem e às turbulências causadas pelos acidentes da tubulação do circuito. Esta correção será feita por uma Rede Neural Artificial que foi treinada para aprender os erros de medição do instrumento.

A precisão de 5% é o valor encontrado nos equipamentos comerciais que utilizam princípios de medição diferentes do modelo proposto.

O restante deste trabalho está dividido da seguinte forma: o capítulo 1 introduz conceitos básicos sobre metrologia, auto-ajuste e sensores inteligentes. No capítulo 2, são apresentadas de forma sucinta as redes neurais do tipo *Multilayer Perceptron* (MLP). O capítulo 3 apresenta uma comparação das vantagens e desvantagens de alguns dos principais dispositivos de medição de vazão. O capítulo 4 detalha o projeto do sensor termal não-intrusivo e a bancada de teste utilizada neste trabalho. O capítulo 5 apresenta a avaliação experimental do medidor proposto e a sua bancada experimental. A conclusão final pode ser encontrada no capítulo 6.

## 1 CALIBRAÇÃO E AUTO-AJUSTE

Este capítulo descreve a importância da calibração, do ajuste, do auto-ajuste e dos sensores inteligentes.

A calibração e o auto-ajuste são tópicos da Metrologia. A Metrologia é a Ciência da medição. Medir é o procedimento experimental pelo qual o valor momentâneo de uma grandeza física é determinado como múltiplo ou fração de uma unidade (ARMANDO, 2008, p. 3).

A metrologia abrange todos os aspectos teóricos e práticos relativos às medições, qualquer que seja a incerteza, em quaisquer campos da ciência ou da tecnologia (INMETRO, 2005). Basicamente, a Metrologia está dividida em três grandes áreas de atuação: científica, industrial e legal (INACIO, 2009).

- A Metrologia Científica trata, fundamentalmente, dos padrões de medição internacionais e nacionais, dos instrumentos laboratoriais e das pesquisas e metodologias científicas relacionadas ao mais alto nível de qualidade metrológica, como por exemplo, a calibração de pesos-padrão e as balanças analíticas para laboratórios.
- A Metrologia Industrial abrange os sistemas de medição responsáveis pelo controle dos processos produtivos e pela garantia da qualidade e segurança dos produtos finais, como por exemplo, os ensaios em produtos certificados, tais como brinquedos, fios e cabos elétricos, entre outros.
- A Metrologia Legal é responsável pelos sistemas de medição utilizados nas transações comerciais e pelos sistemas relacionados às áreas de saúde, segurança e meio ambiente, como por exemplo, a verificação de bombas de abastecimento de combustível.

### 1.1 Importância da Calibração e do auto-ajuste

A qualidade de um processo de produção está intimamente ligada à capacidade dos instrumentos de medição de fornecerem medidas das variáveis do processo, sendo que os erros de medição devem estar situados dentro de uma faixa de valores aceita pelo usuário. Caso estes instrumentos possuam erros fora da faixa aceita, corre-se o risco de tomar decisões erradas que fatalmente irão comprometer a qualidade dos produtos obtidos, que estarão fora da especificação desejada. Para que isto não ocorra, os instrumentos de medição devem estar



calibrados e ajustados. A calibração é um conjunto de operações que estabelece, sob determinadas condições, a relação entre os valores indicados por um instrumento ou sistema de medição ou valores representados por uma medida materializada ou por um material de referência e os valores correspondentes das grandezas estabelecidos por padrões (INMETRO, 2005). A calibração permite verificar, através da comparação contra padrões rastreados, qual é o erro que o instrumento possui e qual é a incerteza associada à medição. De posse dessas informações, é possível verificar se o instrumento de medição está dentro das especificações esperadas. Instrumentos que atendam a sua especificação estão aptos a serem colocados em uso, enquanto aqueles que tiverem erros superiores aos especificados devem ser reavaliados. A calibração tem que ser periódica e normalmente é feita em laboratório. Para tanto, é necessário retirar o sensor da linha, implicando, na maioria das vezes, na interrupção do processo, o que representa um alto custo para a indústria. Mesmo nos casos em que a calibração pode ser feita no campo, o processo também é interrompido, gerando custos. Entretanto, é um procedimento de grande importância, pois ela permite que se conheça o valor convencional que um equipamento está medindo. Conhecendo-se este valor, é possível identificar o seu desvio ou erro (sistemático) em relação aos valores dos padrões e, desta forma, corrigir o erro. Essa correção pode ser feita através do ajuste do instrumento, operação destinada a fazer com que um instrumento de medição tenha desempenho compatível com o seu uso (INMETRO, 2005). O ajuste pode ser automático, semi-automático ou manual (INMETRO, 2005). O termo auto-ajuste também é conhecido como auto-calibração, ou ainda, em inglês, *Auto-Calibration* ou *Self-Calibration*. Todavia, apesar de ser bastante utilizado, o termo auto-calibração está em desacordo com o VIM (Vocabulário Internacional de Metrologia), preferimos, então, utilizar aqui o termo auto-ajuste.

Uma funcionalidade muito útil a ser agregada a um sensor é a capacidade de se auto ajustar, ou seja, de minimizar os erros sistemáticos de medição sem ajuda de nenhum dispositivo de cálculo externo, necessitando somente de uma referência externa para corrigir os erros sistemáticos de medição. O auto-ajuste ajuda a minimizar os custos de calibração, estendendo o período entre calibrações. Um exemplo são as balanças digitais que possuem uma massa padrão interna que, medida automaticamente em intervalos regulares, permite que o instrumento se auto-ajuste, diminuindo sua deriva. Esse recurso vem sendo conseguido graças à utilização de sensores inteligentes, ou seja, instrumentos com sistemas embutidos.

## 1.2 Sensores Inteligentes

O avanço da microeletrônica tornou possível o desenvolvimento de sensores inteligentes. Enquanto um sensor tradicional é um dispositivo capaz somente de realizar a medição de uma grandeza física e gerar a indicação ou transmissão dessa medida, um sensor inteligente é um dispositivo integrado no qual coexistem o sensor propriamente dito (transdutor), os circuitos de condicionamento de sinal e um dispositivo contendo um processador e uma memória não-volátil, a fim de introduzir a inteligência necessária.

A *Honeywell* introduziu no mercado o primeiro sensor inteligente comercial em 1983, Pallàs-Webster, (2001). Ela incluiu em dois dos seus transmissores de pressão (diferencial e estática) um sensor de temperatura, em que os valores de temperatura eram utilizados para compensação dos erros da medição da pressão em função da temperatura, pelo microcontrolador. A saída era processada e o sinal digital convertido para o sinal analógico padrão 4-20 mA.

Desde então, a crescente evolução na capacidade de processamento possibilitou novas funcionalidades aos sensores inteligentes como, por exemplo, funções de auto-identificação, auto-teste, auto-ajuste, filtro de ruídos e lógica de decisão. Além disso, esta capacidade de processamento também permitiu o desenvolvimento de interfaces para inúmeras redes industriais. Este grande crescimento de funcionalidades e formas de interfaceamento com as redes industriais fez com que o IEEE produzisse uma família de normas IEEE 1451 (“Standard for Transducer Interface for Sensor and Actuators”) que descreve os padrões para a implementação de sensores inteligentes, em particular, os tipos de interfaces, o comportamento, os atributos e as formas de transmissões de dados para assegurar a acessibilidade do transdutor à rede. Segundo esta norma, o sensor inteligente pode ser definido como um dispositivo com capacidade de processamento local, habilitado para tomar decisões baseando-se na grandeza medida, e que pode enviar ou receber dados em formato digital ou analógico, facilitando as atividades em sistemas distribuídos (IEEE 1451.0, 2007). A Figura 1 mostra os blocos de um sensor inteligente que segundo a norma deve possuir os seguintes elementos principais:

1. **Um transdutor ou elemento primário** que mede um ou mais parâmetros físicos;
2. **Um elemento computacional** que analisa a medição (as medições) sentida (s) pelo elemento sensor, e realiza os cálculos e operações necessárias;

3. **Interface de comunicação** que permite que o mundo exterior troque informação com os outros componentes do sistema.

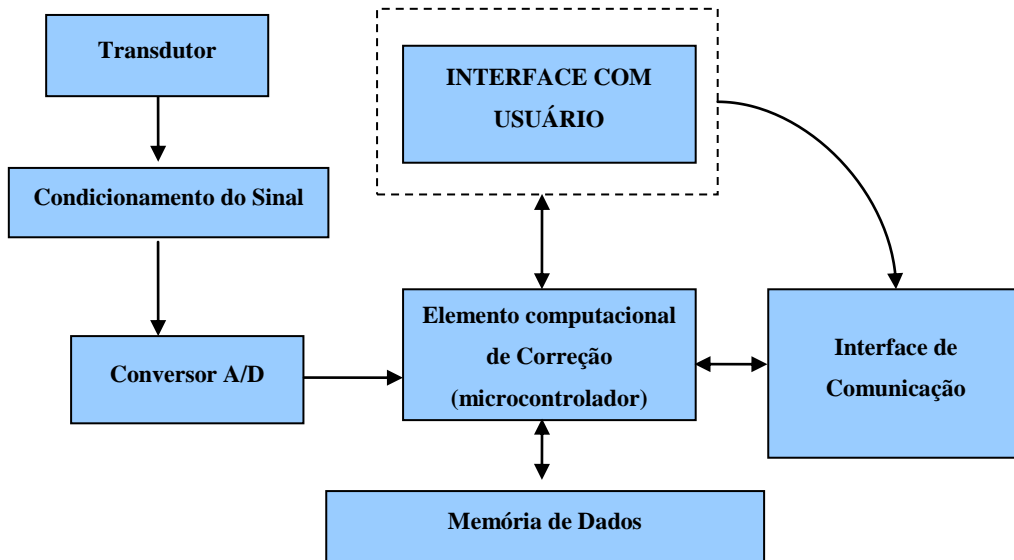


Figura 1 - Conceito básico conceito básico de sensor inteligente

A utilização de sensores inteligentes permite o uso de inteligência computacional para a obtenção de mecanismos de auto-ajuste eficientes. Em particular o uso de Redes Neurais é bastante atrativo, pois, graças à sua capacidade de aprendizado e aproximação de funções (HASSOUN, 1996), elas podem ser usadas para aprender a variação da curva de calibração e auto-ajustar o sensor. Conhecendo o padrão de variação de tal curva, é possível corrigir erros oriundos da deriva e indicar quando não estiver conforme.

## 2 REDES NEURAIAS

Este capítulo faz uma apresentação sucinta de Redes Neurais *Multilayer Perceptron* (MLP) e faz uma revisão da literatura relativa ao uso de Redes Neurais em aplicações com sensores.

### 2.1 Introdução

As principais características das Redes Neurais Artificiais (RNAs) são sua habilidade de aprender certo conteúdo e a capacidade de generalizar, adaptando-se a situações que jamais fizeram parte do conjunto de treinamento.

Enquanto sistemas de *software* convencionais são programados através de um grande número de instruções e regras, a rede neural absorve o conhecimento através da apresentação de exemplos básicos em seu treinamento (BIONDI et al, 1996).

Uma rede neural consiste em uma ou várias unidades processadoras básicas interligadas, dispostas em uma ou mais camadas. Cada camada pode conter diversos elementos processadores. A conexão entre as unidades processadoras é feita através do peso sináptico, que define a influência entre as unidades processadoras interligadas (BIONDI et al, 1996). Os pesos sinápticos, conhecidos como parâmetros internos, têm seu valor atualizado durante o processo de treinamento. Cada unidade processadora executa uma operação simples sobre a informação recebida da entrada ou de outro processador (HAYKIN, 1994). O resultado é então transmitido para outros processadores que, por sua vez, repetem a operação. O processo de atualização dinâmica dos pesos é feito de forma paralela e distribuídamente por toda a rede. Quando as saídas diferem dos alvos por um valor inferior à tolerância de erro pré-estabelecida, está concluído o processo de aprendizagem. Neste ponto, pode-se dizer que a rede está devidamente treinada e a matriz de pesos, que será usada na fase de execução, retém o conhecimento que a rede foi capaz de absorver durante a fase de aprendizado (DAYHOFF, 1990).

A figura 2 mostra a arquitetura de uma rede neural genérica com uma camada, em que  $p_1, p_2, p_3, \dots, p_R$  representam os elementos do vetor de treinamento  $P$  da rede (COELHO, 2001). O bloco somatório realiza a soma ponderada das entradas  $p_1, p_2, p_3, \dots, p_R$  com os pesos

$W_{ij}$ , normalmente conhecida, sob a forma matricial, como  $NET = W \cdot P$ . A saída  $a = F(NET)$  é o resultado da aplicação da soma ponderada NET na função de ativação  $F$ , que pode ser linear ou não (BIONDI et al, 1996).




Figura 2 - Rede Neural Genérica

As MLP (*Multilayer Perceptron*), conforme pode ser visto na figura 3, são redes em que os neurônios são dispostos em múltiplas camadas e conseguem representar funções não linearmente separáveis. Toda função limitada contínua por partes pode ser aproximada com um erro arbitrariamente pequeno por uma rede com uma camada escondida.




Figura 3 - Rede Multilayer Perceptron (MLP)

O algoritmo de retropropagação do erro (*BackPropagation-BP*) é um dos algoritmos de treinamento de Redes Neurais mais utilizados em aplicações práticas de previsão, de classificação e de reconhecimento de padrões em geral. Ele é dividido em duas fases principais: direta (*forward*) e reversa (*backward*). A primeira consiste na propagação dos estímulos apresentados na entrada para a saída. Esses estímulos fluem por toda a rede, recebendo a computação neural, camada por camada, até gerarem a saída. A partir do resultado desejado, calcula-se um erro na camada de saída. A segunda etapa ocorre em

sentido contrário. O erro calculado é retropropagado pelas camadas antecessoras (*backpropagation*), atualizando os pesos das conexões. O algoritmo de retropropagação (Eq. 1) de erro (BP) é baseado no método do gradiente descendente (HAYKIN, 1994), que computa as derivadas parciais de uma função de erro ( $e$ ), com relação ao vetor peso  $W$  de certo vetor de entrada  $P$ , e então atualiza os pesos ( $W$ ) e o *bias* ( $b$ ), de acordo com:

$$\begin{aligned}\Delta w^{(n)} &= -2\eta e^{(n)} \frac{\partial e^{(n)}}{\partial W} \\ \Delta b^{(n)} &= -2\eta e^{(n)} \frac{\partial e^{(n)}}{\partial b}\end{aligned}\tag{1}$$

$$W^{(n+1)} = W^{(n)} + \Delta w^{(n)} = W^{(n)} + 2\eta e^{(n)} P^{(n)}$$

$$b^{(n+1)} = b^{(n)} + \Delta b^{(n)} = b^{(n)} + 2\eta e^{(n)}$$

onde  $\eta$  é a taxa de aprendizado.

O algoritmo de retropropagação (*Backpropagation - BP*), embora aplicado com êxito em várias aplicações, apresenta algumas dificuldades: tempo de convergência longo; paralisia da rede; e mínimo local. Se a taxa de aprendizado e a arquitetura da rede não forem escolhidas adequadamente ou se o ajuste dos pesos for infinitesimal, o tempo de treinamento cresce infinitamente. Por outro lado, a rede pode operar em uma região onde a derivada da função de ativação seja nula ou infinitamente pequena, provocando a paralisia da rede. Finalmente, outro ponto que merece destaque é a possibilidade da existência de superfícies de erro que apresentem mínimos locais. Como se sabe, o *BP* emprega o método do gradiente decrescente, que flui na superfície de erro, ajustando os pesos na direção de um mínimo. Assim, durante o treinamento a rede pode ficar presa em um desses mínimos locais, não conseguindo chegar ao mínimo global (BISHOP, 1995), (HANG et al, 2002). A forma de minimizar esses problemas é encontrar o valor adequado para taxa de aprendizado  $\eta$  que geralmente varia entre 0 e 1. Se  $\eta$  for grande demais o aprendizado é rápido, porém corre-se o risco de a rede paralisar ou entrar em oscilação sem alcançar o mínimo desejado. Se  $\eta$  for muito baixo, aumentam as chances de que a rede fique presa em um mínimo local ou, na melhor das hipóteses, o treinamento será muito lento.

As soluções vistas na literatura para os problemas apresentados podem ser, de um modo geral, divididas em duas grandes categorias (RIVERA et al, 2007): o desenvolvimento de técnicas heurísticas e a utilização de outras técnicas de otimização numérica. Dentre as técnicas heurísticas, cabe destacar o uso de taxas de aprendizado adaptativas e do termo momento (HAYKIN, 1994), (HANG et al, 2002). Em relação ao uso de outras técnicas de otimização, o algoritmo de *Levenberg Marquardt* tem sido aplicado com sucesso no

treinamento de MLP (HANG et al, 2002). Ele foi desenvolvido para a minimização de funções que sejam a soma dos quadrados de funções não lineares, sendo indicado para treinar redes neurais onde o índice de desempenho seja o erro quadrático médio. Para a avaliação numérica do treinamento e da generalização da rede neural foi utilizado a fórmula do erro médio quadrático, conforme apresenta as Equações (2) e (3) (HAYKIN, 1994).

$$\xi_T(et) = \frac{1}{2.N_t} \cdot \sum_{n=1}^{N_t} (d_t(n) - y_t(n))^2 \quad (2)$$

Onde:  $d_t(n)$  é a saída desejada para o padrão de treinamento;

$n, y_t(n)$  é a saída da RNA para o respectivo padrão;

$N_t$  é o número de padrões do conjunto de treinamento;

$\xi_T(et)$  é o erro de treinamento da época  $et$ .

$$\xi_V(et) = \frac{1}{2.N_v} \cdot \sum_{n=1}^{N_v} (d_v(n) - y_v(n))^2 \quad (3)$$

Onde:  $d_v(n)$  é a saída desejada para o padrão de validação;

$n, y_v(n)$  é a saída da RNA para o respectivo padrão;

$N_v$  é o número de padrões do conjunto de validação;

$\xi_V(et)$  é o erro de validação ou aprendizagem da época de treinamento  $et$ .

Outro algoritmo baseado em técnicas de otimização é *Scaled Conjugate Gradient* (SCG), desenvolvido por Moller (HANG et al, 2002). Ele é baseado em uma técnica de otimização chamada de método do gradiente conjugado. Ao contrário de outros algoritmos de retropropagação do erro (*backpropagation*), este não necessita de nenhum parâmetro fornecido pelo usuário e sua execução tem um custo computacional baixo. Uma descrição do algoritmo pode ser encontrada em (HANG et al, 2002).

Conforme foi dito anteriormente, uma importante característica das redes neurais é a sua capacidade de generalizar o conhecimento a partir de exemplos de treinamento. Isto permite que a rede seja capaz de lidar com ruídos e distorções, e também responder corretamente a novos padrões, isto é, padrões que não foram apresentados no treinamento. Para que a rede tenha uma boa capacidade de generalização, deve-se evitar o

supertreinamento (*overfitting*). Ele acontece quando a rede demonstra um excelente desempenho (erro extremamente baixo) para o conjunto de dados do treinamento, mas apresenta um baixo desempenho quando lhe são apresentados dados que não estiveram presentes no processo de treinamento. Isto significa que a rede memorizou os exemplos de treinamento, mas não aprendeu as relações existentes entre estes dados para poder generalizar para novas situações.

As abordagens que são normalmente utilizadas para evitar o *overfitting* são: o *Early Stopping* (ES) e a Regularização Bayesiana (RB) (BISHOP, 1995), (MACKAY, 1992). Na abordagem que usa o *Early Stopping*, o conjunto de dados disponíveis é dividido em três conjuntos. O primeiro é o conjunto de treinamento, utilizado para atualizar os pesos da rede e calcular os gradientes. O segundo é chamado de conjunto de validação e seu erro é monitorado durante o processo de treinamento. Se este erro começar a subir por um determinado número de épocas, indica que a rede esta sendo supertreinada. Neste caso, devem ser utilizados os pesos calculados para o menor erro de validação encontrado. Embora seja uma técnica de simples aplicação, não é fácil determinar de antemão por quantas épocas (ciclos de treinamento) devemos esperar até poder dizer que ocorreu um supertreinamento. O terceiro e último é o chamado conjunto de teste que é utilizado para verificar a capacidade de generalização.

Na Regularização Bayesiana, modifica-se a função de custo  $F$  que é normalmente usada, o erro quadrático médio ( $E_d$ )

$$F = E_d = \frac{1}{N} \sum_{i=1}^N (e_i)^2 \quad (4)$$

Esta modificação tem o objetivo de melhorar a capacidade de geração do modelo. A função objetivo na eq.4 é expandida com a adição do termo  $E_w$  que é a soma dos quadrados dos pesos e bias

$$F = \beta E_d + \alpha E_w \quad (5)$$

Onde  $\alpha$  e  $\beta$  são os parâmetros de regularização e  $E_w$  é dada por:

$$E_w = \frac{1}{n} \sum_{j=0}^N (w_j)^2 \quad (6)$$

A utilização desta nova função de custo faz com que a rede tenha pesos e *bias* com valores menores, gerando uma resposta mais suave, o que diminui a possibilidade de supertreinamento. É bastante desejável que se obtenha os parâmetros de regularização ótimos de forma automática. Isto pode ser feito seguindo o que foi proposto por David MacKay



(MACKAY, 1992) que considera os pesos e *bias* variáveis aleatórias com distribuições especificadas. Os parâmetros de regularização estão relacionados com as variâncias desconhecidas destas distribuições. Sendo assim, é possível estimar estes parâmetros através de técnicas estatísticas.

## 2.2 Aplicações de Redes Neurais em sensores

A pesquisa bibliográfica realizada mostrou um crescente interesse no uso de redes neurais em sensores inteligentes como: predição da deriva (variação dos erros sistemáticos ao longo do tempo) de instrumentos entre calibrações utilizando redes neurais (SACHENKO et al, 2000), técnicas de auto-ajuste (self-calibration) (PATRA et al, 2004 e RIVERA et al, 2007), detecção de falhas (NAJAFI et al, 2004), monitoramento e verificação de calibração (PINTO et al, 2005) e linearização das características de um transdutor para compensar os distúrbios causados por outras grandezas de influência (PEREIRA, 2005).

Em Sachenko et al (2000), é proposto um método para diminuir a deriva do sensor utilizando redes neurais. Os dados usados para treinamento são obtidos a partir de calibrações do sensor no momento atual e de estimativas da deriva feitas a partir do histórico de calibração. Como resultados, são informados a configuração final da rede e os erros obtidos.

Em Patra et al (2004), é desenvolvido um esquema para auto-ajuste de um sensor de pressão por efeito capacitivo em ambientes industriais. São utilizadas duas redes MLP, onde a primeira estima a capacitância calibrada e a segunda, a partir desta capacitância, estima a pressão. O processo de escolha das redes foi feito por tentativa e erro e os resultados obtidos indicam o erro percentual em fundo de escala de 0,5%.

Em Pereira et al (2005), um conversor FDC (*frequency-to-digital*) de dois canais é usado para medir a umidade relativa e a temperatura, e uma rede neural do tipo MLP é utilizada para compensar as medidas de umidade relativa causada pela variação da temperatura. A rede recebe como entrada os valores de frequência correspondentes a umidade relativa e temperatura e fornece como saída os valores da umidade relativa. Existem informações suficientes para reproduzir a rede utilizada, mas não estão presentes as informações relativas ao processo de escolha da topologia da rede (sobretudo o número de neurônios) e sobre o processo de treinamento.

Em Rivera et al (2007) propõe-se uma metodologia para auto-ajuste de sensores inteligentes utilizando redes neurais. Para ilustrar o método, um sistema para medição de temperatura foi implementado. Neste artigo, compararam-se os resultados do método

proposto com aqueles obtidos através do polinômio padronizado. O treinamento da rede MLP foi feito com cinco a oito pontos da curva de calibração usando o algoritmo de Levenberg-Marquardt. O desempenho foi medido em termos da porcentagem máxima do erro de não linearidade de saída. Os resultados informados indicam que uma rede treinada com cinco pontos de calibração é capaz corrigir um sinal com 33% de não linearidade.

Em Barbosa et al (2007), são utilizadas redes MLP no ajuste de Curvas de Calibração de uma balança aerodinâmica externa multicomponente. O esquema apresentado envolve a combinação de um polinômio e de uma rede MLP, ou de duas redes MLP, que visa à aproximação de uma Função Principal (FPR) e de uma Função Desvio (FD). O ajuste da FPR tem como objetivo representar a relação entre valores da grandeza medida com os valores da grandeza do mensurando por uma única função. Após o ajuste da FPR, os valores dos desvios (erros) em relação ao valor medido são computados e, então, é aproximada uma Função Desvio (FD) que representará os desvios em relação à FPR. Os resultados informados são considerados encorajadores.

Em Oliveira et al (2009a), é proposto um algoritmo para auto-ajuste de sensores inteligentes a partir do uso de Redes Neurais Artificiais. Através de dados gerados em uma calibração, o algoritmo aprende a corrigir os desvios encontrados. Uma continuação deste estudo pode ser vista em Oliveira et al (2009b).

De acordo com as descrições realizadas anteriormente, observa-se que todos os trabalhos utilizam redes MLP. É importante notar também que a utilização de duas redes ou de combinações de polinômio e redes neurais tem a função de dividir o trabalho que seria feito por apenas uma rede. Esta, certamente, seria mais complexa e teria requisitos de treinamento bem mais exigentes. Observa-se também que nos artigos descritos não é mencionado de forma explícita o que foi feito para garantir que não haja supertreinamento da rede, sendo este problema especialmente importante quando utilizamos um conjunto de treinamento pequeno como em Rivera et al (2007).

### 3 MEDIDORES DE VAZÃO

A medição de vazão de fluidos está presente em diversas atividades humanas. O hidrômetro de uma residência e o marcador de uma bomba de combustível são exemplos comuns no dia-a-dia das pessoas. Mas ela também poder ser encontrada em uma série de aplicações industriais e científicas tais como: a contabilização do total de bebida engarrafada em uma fábrica de refrigerantes, o controle do recebimento de gás/óleo em um gasoduto/oleoduto, o controle de vazão do dialisado e do ultrafiltrado em máquinas de diálise e medições da velocidade do vento em estações meteorológicas e aeroportos.

A grande variedade de aplicações, cada uma com diferentes requisitos, faz com que exista um grande número de medidores disponíveis que utilizam os mais variados princípios de medição. A escolha do medidor dependerá do tipo de fluido (e de suas condições físicas), da exatidão exigida, da faixa de operação, do custo, da complexidade, da facilidade de leitura e do tempo de vida em serviço.

Os medidores podem ser classificados de acordo com a perturbação que o elemento transdutor introduz na medida (BENYOSEF, 2006):

- **Transdutores INVASIVOS:** são aqueles que têm contato e apresentam interação físico-química com o processo em que se efetua a medida.
- **Transdutores INTRUSIVOS:** são aqueles que têm interação físico-química com o processo em que se efetua a medida.

A figura 4 elucida a diferença entre estes dispositivos:




Figura 4 - Características dos transdutores

A tabela 1 mostra a distribuição dos princípios de medição mais utilizados para a grandeza vazão e sua correlação entre a característica de intrusividade e invasividade. Nas

seções seguintes serão apresentados alguns dos tipos principais de medidores que estão relacionados com este trabalho.

Tabela 1 - Características dos medidores de vazão

	Invasivo	Não-invasivo
Intrusivo	Deprimogênios (Bocais, <i>Venturis</i> , Placas de Orifício, Pitots); Deslocamento Positivo; Mássico Termal (comercial)	Mássico Coriolis
Não-intrusivo	Eletromagnético; Mássico Termal não-intrusivo (esta proposta)	Ultrassom ( <i>Doppler</i> )

### 3.1 Medidor de Vazão do Tipo Eletromagnético

Segundo a norma ISO 6817 (1980), que é equivalente à ABNT NBR ISO 6817 (1999), o medidor eletromagnético é um medidor de vazão que utiliza o princípio da Lei de Indução Magnética de Faraday, em que a força-eletromotriz (f.e.m.) é induzida ortogonalmente a um campo magnético gerado, quando um corpo condutor atravessa o mesmo. O medidor de vazão eletromagnético cria então um campo magnético perpendicular ao escoamento do líquido que, ao ser atravessado pelo fluido condutor, induz uma f.e.m. perpendicular ao escoamento e ao campo magnético proporcional à velocidade média do escoamento. Essa f.e.m. provoca então uma diferença de potencial nos eletrodos do medidor que é proporcional à velocidade do escoamento, a partir da qual é possível calcular a vazão. A representação espacial destas forças pode ser observada na figura 5.




Figura 5 - Medidor eletromagnético Williams (SHERCLIFF, 1962)

Quando percorre a tubulação, o fluido varia o campo magnético entre os eletrodos primários, gerando uma f.e.m. (lei de indução de Faraday) que é então enviada para o circuito secundário para conversão desse sinal.

Na figura 6, podemos observar o campo magnético gerado pela bobina magnética em que  $\Phi_B$  é o campo magnético;  $D$  é o diâmetro do tubo;  $\varepsilon$ , a f.e.m. e  $V$  é a velocidade de escoamento. A figura, que foi extraída da norma ISO 6817 (1980), também é encontrada na norma NBR ISO 6817 (1999), e apresenta um esquema simples do medidor eletromagnético. Nele podemos ver a posição relativa do campo magnético aos eletrodos e a distância entre eles, que é igual ao diâmetro da tubulação. A força eletromotriz é representada pela letra  $V$  e a velocidade do escoamento é representada pela letra  $U$ . O diâmetro da tubulação é indicado por  $\phi D$ .




Figura 6 - Campo magnético gerado pelo medidor eletromagnético (NBR ISO 6817,1999)

A norma, além de descrever o funcionamento do medidor, ainda quantifica as variáveis envolvidas:

$$\varepsilon = K \cdot \Phi_B \cdot D \cdot V \quad (7)$$

em que:

$\varepsilon$  = sinal de vazão (volts);

$K$  = constante;

$\Phi_B$  = densidade do fluxo magnético;

$D$  = distância entre os eletrodos;

$V$  = velocidade média axial do fluido

Segundo Elonka & Parsons (1976), as principais vantagens dos medidores eletromagnéticos são:

- Funcionamento linear em que os dados de saída obedecem a uma função linear (ao contrário dos medidores deprimogênicos, onde o sinal de saída é uma função quadrática da diferença de pressão);
- Possibilidade de trabalho em vazões muito baixas;
- Não há limite teórico para vazão máxima (limitado hidraulicamente);
- Não há erros com fluidos de alta condutividade;
- Perda de carga desprezível (corresponde à perda de carga de um trecho de tubo equivalente, sem singularidades);
- Exatidão e sensibilidade elevadas, aliadas a um baixo tempo de resposta.

Segundo Troskolanski (1960) as vantagens dos medidores de princípio eletromagnético são:

- Alta sensibilidade;
- Pequena interferência com o escoamento;

Bentley (1995), também apresenta um resumo das principais vantagens dos medidores eletromagnéticos, sendo estas:

- Boa precisão, aproximadamente +/- 1% da vazão máxima indicada;
- Calibração independente de mudanças na viscosidade, pressão, densidade e temperatura;
- Consumo de energia baixo, sendo em geral menor que 30W.

Segundo Awwa (1989), as principais desvantagens do medidor eletromagnético são:

- Líquido a ser medido deve ter condutividade mínima de  $200\mu\text{S}/\text{m}$ ;
- Para pequenos diâmetros o medidor pode ser relativamente grande e caro;
- Cada medidor deve ser calibrado individualmente em uma linha de teste;
- Medidor é sensível a propriedades geométricas da linha;
- Medidor é sensível a variações da tensão e corrente de alimentação.

### 3.2 Medidor de Vazão do Tipo Ultrassom

A idéia básica dos sistemas de medição que utilizam sensores ultrassônicos consiste em transmitir ondas de ultrassom por meio de um transdutor emissor; após a interação com o meio de propagação, estas ondas são recebidas no transdutor receptor. A partir do sinal recebido e levando em consideração o sinal transmitido, são realizadas operações de processamento de sinais para estimação da velocidade do fluido e conseqüentemente da vazão (HAUPTMANN, 2001). Os métodos mais comuns utilizados são por efeito Doppler e por determinação do tempo de trânsito.

Os medidores por efeito Doppler dependem da reflexão de ondas em partículas espalhadas no fluido e, por isso, necessitam gerar ondas com uma frequência bem definida. Quando as partículas se movem na velocidade do escoamento, a mudança de frequência é proporcional à vazão.

O método do tempo de trânsito utiliza a medição do tempo de propagação da onda ultrassônica através do fluido entre dois transdutores para a determinação da variável medida. Um possível arranjo pode ser visto na figura 7.




Figura 7 - Ultrassom por Tempo de trânsito (BRANCO, 2008)

Quando há um escoamento, o efeito da velocidade do líquido no sinal acústico faz com que este seja mais rápido no mesmo sentido do que no sentido contrário. Isto cria uma diferença de tempo em função da velocidade, se utilizados os dois tempos de trânsito  $t_{up}$  e  $t_{down}$  e a distância entre os sensores recebendo e emitindo sinais. Assim, é possível determinar a vazão volumétrica (BRANCO, 2008). A equação abaixo é usada como base para determinar a velocidade de fluxo do líquido.

$$V = \frac{M \times D}{\text{sen } 2\theta} \times \frac{T_{up} - T_{down}}{T_{up} \times T_{down}} \quad (8)$$

V = Velocidade do fluxo (m/s);

M = Tempo de trânsito do sinal ultra-sônico (s);

D = Diâmetro do tubo (m);

$\theta$  = Ângulo entre o sinal ultra-sônico e a vazão (°);

T<sub>up</sub> = Tempo de trânsito na direção do fluxo (s);

T<sub>down</sub> = Tempo de trânsito na direção reversa (s).

Dependendo do processo, os transdutores podem ser montados de quatro formas diferentes, visando o melhor desempenho possível para a aplicação:

O método V é utilizado principalmente em tubulações de grandes diâmetros (DN100 ~ 300 mm, 4''~12''), ver figura 8.




Figura 8 - Ultrassom Método V (BRANCO, 2008)

Para a aplicação em tubulações de pequeno diâmetro (abaixo de DN50mm, 2''), o método W pode apresentar melhores resultados, ver figura 9.




Figura 9 - Ultrassom Método W



Segundo Branco (2008), as principais vantagens dos medidores de ultrassom são:

- Ampla largura da faixa (*rangeability*) 120:1;
- Medição bidirecional;
- Alta precisão (cerca de 0,5% do valor lido);
- O mesmo sensor opera em diâmetros de 1” a 200” (25 a 5000 mm);
- Medição com ou sem contato com o fluido;
- Tecnologia sem partes móveis.

A principal desvantagem se refere à dificuldade de medição em pequenos diâmetros.

### 3.3 Medidor de Vazão por pressão diferencial

Entre os medidores de vazão baseados na queda de pressão por obstrução de área, os principais são os do tipo *Venturi*, placa de orifício e os bocais de fluxo. A medição da vazão de fluidos por tubos de *Venturi* é adotada nos mais diversos ramos industriais. Eles podem ser utilizados nas seguintes aplicações: transporte de misturas multifásicas, processamento de gás natural, transferência de custódia e distribuição de gás para consumo residencial. Contudo, aspectos relacionados a baixas faixas de utilização e a sensibilidade a efeitos de instalação representam limitações para as aplicações mais generalizadas de medidores de vazão por pressão diferencial.

Perturbações no perfil de escoamento causadas por acidentes de tubulação (curva, válvula, redução de diâmetros, T, etc.), conforme pode ser visto na figura 10, podem interferir na leitura destes medidores. Uma forma de lidar com estas perturbações no escoamento consiste em garantir que haja certo trecho reto mínimo de tubulação, à montante do elemento primário (*Venturi*, placa de orifício, etc.), de forma a permitir um desenvolvimento do escoamento que atenua o efeito das distorções no mesmo. Por outro lado, instalações mais compactas podem ser obtidas com a utilização de condicionadores de escoamento, embora a eficácia destes condicionadores e seus efeitos sobre a medição de vazão ainda sejam objeto de investigação (LAWS, 1995).




Figura 10 - Perfil de escoamento

Nos dispositivos de medição do tipo deprimogênios a vazão pode ser calculada aplicando-se a Equação da Conservação da Massa, bem como a Equação da Conservação da Energia, sendo, esta última, na sua forma simplificada, que é a Equação de Bernoulli. Assim, para o escoamento incompressível através de uma redução de área, se for tomada uma linha de corrente entre os pontos 1 e 2, conforme pode ser visto na figura 11, tem-se:




Figura 11 - Escoamento de Fluidos em um Venturi

$$\frac{V_1^2}{2} + \frac{p_1}{\rho} = \frac{V_2^2}{2} + \frac{p_2}{\rho} \quad (9)$$

$$V_1 A_1 = V_2 A_2 \quad (10)$$

onde  $p_1$  e  $p_2$  são as pressões estáticas nos pontos 1 e 2 e  $\rho$  é a densidade do fluido.

Sendo  $\beta$  a razão entre os diâmetros do medidor (figura 12) da tubulação, pode-se isolar uma das velocidades:

$$V_2 = \sqrt{2 \left( \frac{p_1 - p_2}{\rho} \right) (1 - \beta^4)^{-1}} \quad (11)$$

e a partir da velocidade pode-se obter a vazão mássica ideal:

$$\dot{m}_{teorica} = \frac{A_{obstrução}}{\sqrt{1 - \beta^4}} \sqrt{2\rho(p_1 - p_2)} \quad (12)$$

A vazão mássica real pode ser obtida multiplicando a vazão mássica teórica pelo coeficiente de descarga  $C_d$  para incorporar outros fatores que não estão previstos na equação ideal.

$$\dot{m}_{real} = C_d \frac{A_{obstrução}}{\sqrt{1 - \beta^4}} \sqrt{2\rho(p_1 - p_2)} \quad (13)$$




Figura 12 - Detalhe do dimensionamento do tubo Venturi

Segundo Delmée (1986), as principais vantagens dos medidores deprimogênicos são:

- Facilidade de fabricação;
- Existência de dados para larga faixa de aplicação;
- Grande aceitação;
- Baixa perda de carga (*Venturi*);

E as desvantagens são:

- Baixa largura de faixa (*rangeability*);
- Necessidade de elemento secundário (medição de pressão);
- Necessidade de longos trechos retos;

### 3.4 Medidores de Vazão Termiais

Os medidores de Vazão Termiais são baseados na troca térmica de um fluido através do seu escoamento em contato com um corpo de temperatura diferente do fluido objeto da medição, conforme se vê na figura 13 (NGUYEN, 1999). Podemos notar nesta figura que uma grandeza mecânica (vazão) gera um efeito térmico que é detectado por um transdutor gerando um efeito elétrico.

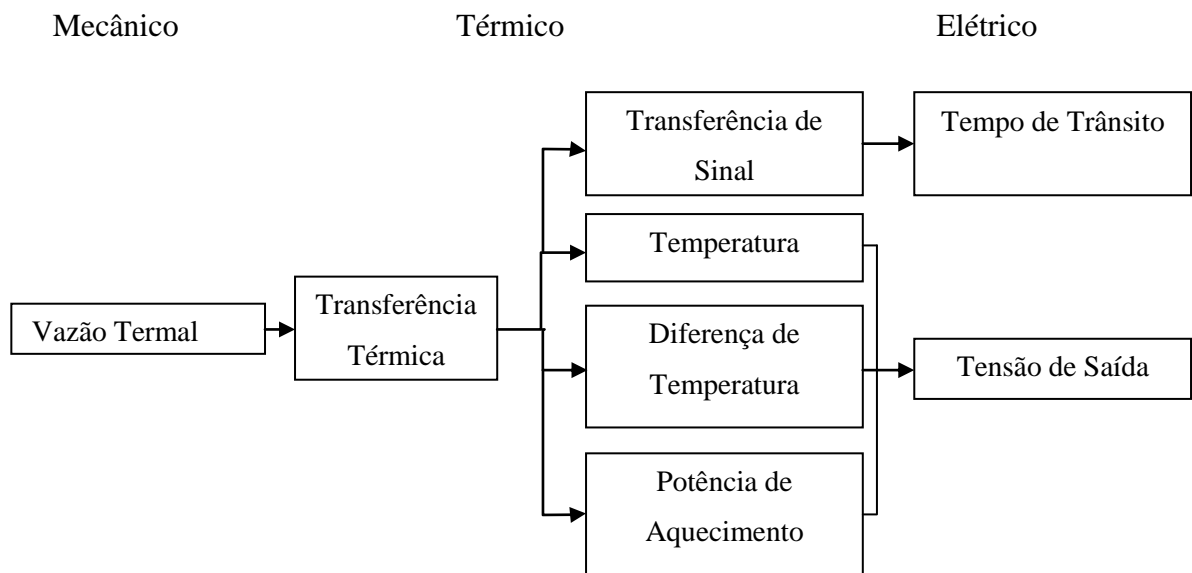


Figura 13 - Princípios de medição dos sensores Termiais

#### 3.4.1 Anemometria de fio quente

A anemometria de fio quente é uma consagrada técnica experimental estabelecida há cerca de um século. Abrange aplicações em diversas áreas da engenharia, tais como instrumentação eletrônica, controle, aquisição de dados, sistemas aeroespaciais, mecânica dos fluidos, termodinâmica, química, meteorologia etc.

De maneira geral, o trabalho de King em 1914, constitui o alicerce principal para a anemometria de fio quente, sendo sua análise citada, direta ou indiretamente, em praticamente todas as referências consultadas no presente trabalho. A dedução da expressão que relaciona a

troca de calor de cilindros aquecidos imersos num meio fluido recebeu o nome de “Lei de King”, em razão da sua contribuição ao desenvolvimento do anemômetro de fio quente, conforme aponta Comte - Bellot (1976) dentre outros.

Anemômetros são instrumentos usados para medidas de velocidade de ar, podendo ter diversas características de construção e operação. Para baixas velocidades, os anemômetros termais são os mais indicados e seu funcionamento se baseia nas trocas de calor entre o sensor aquecido e o fluido, provocando alteração da resistência elétrica ou da potência dissipada (medidores a resistência constante) do sensor, que pode ser correlacionada à velocidade do fluido.

Muitas versões de medidores de fluxo termais têm sido fabricadas, a partir de 1900, originalmente rotulados de anemômetros de “fio quente”. Eles eram utilizados em laboratórios para pesquisas na obtenção de perfis de velocidade e turbulência. Pequenos, frágeis e dispositivos pouco práticos. Geralmente, os sensores eram operados a corrente constante e muito raramente possuíam compensação de temperatura.

Devido a seu tamanho reduzido, eles apresentam uma rápida velocidade de resposta, porém são extremamente susceptíveis a sujeira e rupturas. Para uso industrial, são necessários sensores mais robustos.

Quando comparados a outros tipos de medidores de fluxo como placas de orifício, por exemplo, fica fácil verificar o motivo pelo qual os medidores termais de fluxo vêm ganhando rapidamente grande aceitação. Como é de conhecimento geral, os controles de processos industriais vêm rapidamente passando de pneumáticos para eletrônicos e, por isso, a indústria vem buscando métodos que se ajustem mais facilmente a sistemas computadorizados de controle.

Os medidores termais medem a vazão mássica, pois estão baseados no princípio da troca térmica entre o fluido e o medidor:

$$\dot{Q} = \dot{m} \times C_p \times \Delta T \quad (14)$$

Onde:

$\dot{Q}$  = Potência fornecida pelo sensor ao fluido (J/s);

$\dot{m}$  = Vazão mássica do fluido (kg/s);

$C_p$  = Calor específico volumétrico do fluido (J/m<sup>3</sup>K);

$\Delta T$  = Diferença de temperatura entre o fluido e o medidor (K).

O medidor termal pode ser empregado para vários fluidos, mas o termo anemômetro é específico para medidores de velocidade do ar, conforme pode ser visto na figura 14.

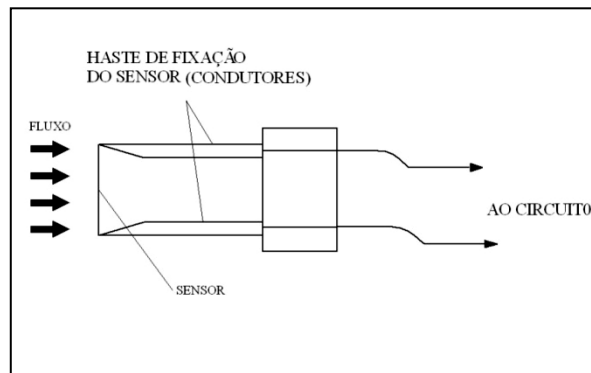


Figura 14 - Detalhe do sensor de fio quente típico

O filamento geralmente é de platina ou tungstênio. Quando submetido a uma corrente elétrica, o filamento se aquece e o calor gerado é dissipado pelo fluxo de fluido ao redor do filamento, conforme a figura 15.




Figura 15 - Detalhe do Escoamento ao redor da seção do fio

### 3.4.2 Medidor de Vazão por convecção forçada

A medição de vazão por convecção forçada baseia-se no efeito refrigerante de um fluido ao passar sobre um transdutor aquecido. Em Oliveira (2008), o fluido que se desloca através de uma seção tubular passa de modo intrusivo sobre dois transdutores de temperatura

(RTDs) do tipo Pt-100, que podem ser vistos na figura 16. Um dos sensores é usado para a medição da temperatura do fluido, o outro, mantido aquecido, mede a vazão do fluido. Quanto maior a vazão que passa sobre o transdutor aquecido, maior o efeito refrigerante e maior será a potência requerida para manter constante a diferença de temperatura entre os dois sensores constante. Desse modo, a potência requerida na resistência de aquecimento é função da vazão do fluido. Devido a seu princípio de funcionamento, é inerente a este sensor um pequeno aquecimento no fluido, este aquecimento é proporcional a temperatura diferencial utilizada.




Figura 16 - Detalhamento do sensor termal intrusivo

Neste medidor, a vazão mássica pode ser calculada através da seguinte equação:

$$\dot{m} = \left[ \frac{1}{B} \left( \frac{\dot{Q}}{\Delta T} - A \right) \right] \quad (15)$$

onde  $A$  e  $B$  são constantes da equação de King,  $\Delta T$  é a diferença de temperatura entre os dois sensores e  $\dot{Q}$  é a potência dissipada.

A Figura 17 mostra o diagrama de blocos do medidor de vazão por convecção forçada (OLIVEIRA, 2008). Neste diagrama, podemos notar as interconexões entre os componentes físicos da bancada (transdutores, transmissores, atuadores e placa de aquisição) e os componentes funcionais (cálculos e algoritmos). Os transmissores de temperatura são responsáveis pelo condicionamento do sinal dos sensores de temperatura em ohms, transformando em um sinal padronizado de instrumentação de 4 a 20 mA. Os canais de entrada analógica (A/D) digitalizam o sinal elétrico para processamento dos algoritmos necessários. Um controlador PID é responsável pelo controle da temperatura diferencial do

RTD aquecido. A tensão e a corrente na resistência de aquecimento são utilizados para calcular a potência necessária para manter a temperatura diferencial constante. A partir da potência obtida pode-se calcular a vazão mássica por meio da modelagem física, observando as perdas por condução.

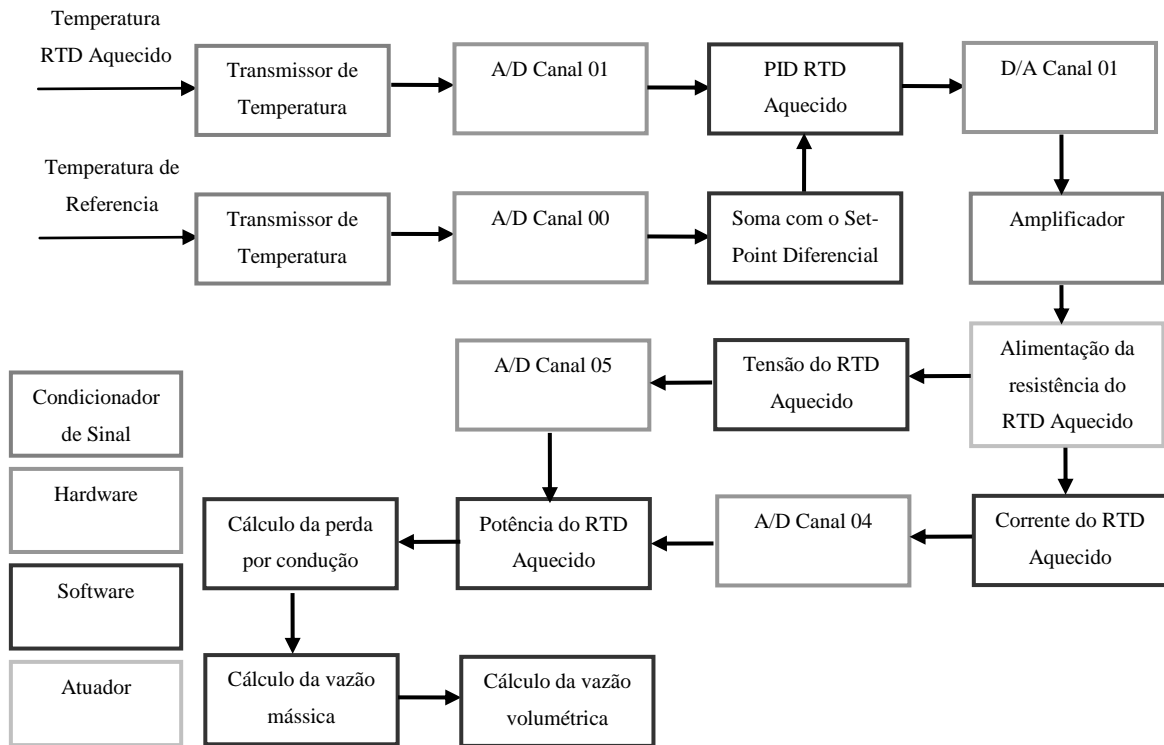


Figura 17 - Diagrama de blocos de um medidor por convecção forçada

### 3.5 Comparação entre os Medidores de Vazão

A Tabela 2 apresenta as vantagens e desvantagens dos tipos de medidores de vazão pesquisados neste trabalho. A partir da observação da tabela, nota-se que seria bastante interessante desenvolver um medidor de vazão termal que não fosse intrusivo, para usufruir das vantagens de um medidor termal e ser uma alternativa aos outros medidores não-intrusivos.



Tabela 2 - Comparação das características dos medidores de vazão

Tipo de Medidor	Vantagem	Desvantagem
Eletromagnético	Possibilidade de trabalho em vazões muito baixas; Perda de carga desprezível;	Líquido a ser medido deve ter condutividade mínima de 200 $\mu$ S/m; Para pequenos diâmetros o medidor pode ser relativamente grande e caro;
Ultrassom	Boa largura da faixa (rangeability) 120:1; Medição bidirecional; Medição com ou sem contato com o fluido (Não-intrusivo e Não invasivo); Perda de carga desprezível;	Dificuldade de medição em pequenos diâmetros;
Pressão diferencial	Facilidade de fabricação; Existência de dados para larga faixa de aplicação; Grande aceitação;	Baixa largura de faixa ( <i>rangeability</i> ); Necessidade de elemento secundário (medição de pressão); Necessidade de longos trechos retos; Perda de carga considerável;
Termal	Facilidade de fabricação; Baixo Custo; Ampla largura da faixa; Baixa perda de carga; Pequena interferência com o escoamento;	Medição com contato com o fluido;

## 4 PROJETO DO MEDIDOR PROPOSTO

Este trabalho tem por objetivo pesquisar e desenvolver um medidor de vazão termal inteligente. Ele deve possuir as seguintes características: ser não-intrusivo, permitir auto-ajuste, apresentar precisão melhor que 5% do valor lido.

As premissas para o projeto do medidor de vazão termal inteligente são as seguintes:

- Não-intrusivo;
- Capacidade de Auto-ajuste;
- Medição da vazão por meio da potência elétrica necessária para manter uma seção da tubulação a uma temperatura diferencial (em relação ao fluido) constante.

### 4.1 Idéia Básica sobre o sensor proposto

Utilizando como base para este trabalho o medidor desenvolvido por Oliveira (2008), foram feitas modificações para se obter um medidor não-intrusivo. A Figura 18 mostra as diferenças entre a versão intrusiva e a não-intrusiva.




Figura 18 - Conceito básico medidor de Vazão Termal Intrusivo e Não Intrusivo

Nas duas versões (intrusiva e não-intrusiva), a temperatura do sensor aquecido é controlada por um PID diferencial implementado em *LabView*. Contudo, na versão não-

intrusiva, o sensor aquecido é constituído de um trecho de tubo usinado em aço inox AISI 304 (carretel) envolto em uma resistência elétrica de tungstênio e um sensor Pt-100. Existe ainda outro carretel, sem resistência de aquecimento, com as mesmas dimensões do primeiro, também dotado de um sensor Pt-100, cuja função é medir a temperatura do fluido que é usada como referência para o controlador diferencial.

A Figura 19 mostra um diagrama de blocos da versão não intrusiva. Observe que além das alterações realizadas nos sensores, a determinação da vazão volumétrica é feita de um modo diferente. Enquanto na versão intrusiva a vazão mássica era calculada a partir da potência dissipada no RTD aquecido, na versão não-intrusiva o cálculo da vazão é feito a partir de uma nova modelagem física para sensor (que agora não consiste apenas de um RTD) e de um bloco de correção, realizado por uma rede neural, para atenuar as deficiências da modelagem física utilizada.

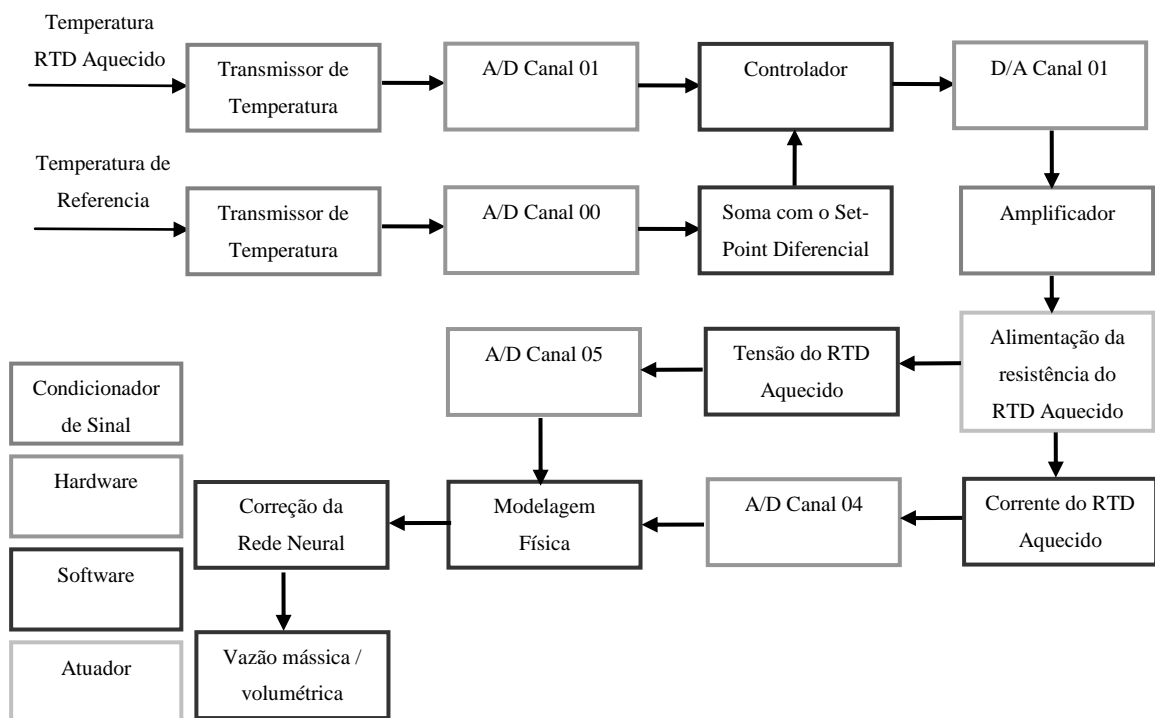


Figura 19 - Diagrama de blocos de um medidor de Vazão Termal Inteligente

O software controle da versão intrusiva foi desenvolvido em LabView 7.1, foi reformulado para versão não-intrusiva e atualizado para o LabView 8.6.

## 4.2 Construção do sensor

O carretel foi construído com rebaixos externos, de modo a receber a resistência de tungstênio. Foi ainda usinada uma cavidade perpendicular ao tubo, posicionada no centro deste, para fixação do Pt-100. Estes detalhes podem ser verificados na figura 20. Na figura 21, o leitor pode observar o detalhe do sensor Pt-100 montado em sua cavidade e notar que o posicionamento escolhido visa a obter a temperatura no centro do tubo e a resistência posicionada em volta do mesmo.




Figura 20 - Detalhamento do aquecimento termal não-intrusivo




Figura 21 - Detalhamento da medição do termal não-intrusivo

A versão não-intrusiva envolve todo um trecho da tubulação por onde o fluido escoa. Isto impossibilita que o sensor de referência seja posicionado ao lado do sensor termal, como na versão intrusiva, da figura 18 (OLIVEIRA et al, 2008). Por isso, foi incluída uma versão passiva, ou seja, sem resistência de aquecimento, que pode ser vista na figura 22. Para obter simetria, o sensor passivo tem as mesmas dimensões e materiais da versão ativa, de modo a medir a temperatura do fluido com a mesma isolação e capacitância térmica do sensor ativo e com o objetivo de obter o mesmo tempo de resposta às variações da temperatura do fluido (objeto da medição). A temperatura do fluido é a referência do controle diferencial da temperatura do sensor ativo.




Figura 22 - Detalhamento da referência do termal não-intrusivo

Além dos dois carretéis torneados em aço *inox*, foram torneadas duas luvas em *Teflon*, conforme desenho apresentado na figura 23.




Figura 23 - Projeto do Sensor Termal

O carretel do sensor ativo recebeu uma camada de *Teflon* para proporcionar o isolamento elétrico, sobre este isolamento o carretel recebeu 4 voltas de um fio resistivo de tungstênio de 0,21mm de diâmetro que possui uma resistividade de  $33\Omega$  por metro, perfazendo uma resistência de 20 *Ohms*, conforme figura 24.



Figura 24 - Resistência de aquecimento do sensor termal (ativo)

O carretel recebeu a seguir mais uma camada de *Teflon* e aplicação de pasta térmica na cavidade de acomodação do Pt-100, conforme figura 25.



Figura 25 - Isolamento do Sensor Termal (ativo)

Após esta etapa, o carretel foi introduzido na luva de *Teflon*, de modo a proporcionar rigidez mecânica e isolamento térmico ao conjunto, sendo em seguida inserido o Pt-100, responsável pela medição da temperatura do carretel, que trocará calor com o fluido, cuja vazão será medida, ver figura 26.




Figura 26 - Montagem final do Sensor Termal (ativo)



O carretel do sensor passivo apenas foi inserido em sua respectiva luva e recebeu o seu sensor Pt-100, diferindo da versão ativa apenas por não receber uma resistência de aquecimento. Entre os dois sensores (ativo e passivo) foi introduzida uma terceira luva, de modo a proporcionar o isolamento térmico entre os sensores, conforme figura 27.




Figura 27 - Montagem final do Sensor Termal (lateral)

Na figura 28, podemos notar o aspecto não-intrusivo dos sensores, não criando nenhum obstáculo ao fluxo do fluido.



Figura 28 - Montagem final do Sensor Termal (superior)

Na figura 29, podemos notar o isolamento térmico adicional, devido à baixa isolamento térmica da luva de teflon.




Figura 29 - Montagem da isolamento térmica do Sensor Termal

A Figura 30, a montagem final do sensor ativo (aquecido) na bancada.



Figura 30 - Montagem Final do Sensor Termal com isolamento térmica

### 4.3 Modelagem do sensor

Para realizar a modelagem do sensor, partiu-se da equação do medidor de vazão mássico por tubo aquecido, que foi desenvolvido originalmente por C. C. Thomas em 1911 (TODA, 1996).

$$\dot{m} = \frac{\dot{Q}_{cf}}{C_p \Delta T} \quad (16)$$

$$\dot{m} = \text{Vazão mássica (Kg/s);}$$

$$\dot{Q}_{cf} = \text{Calor roubado pelo fluido (J/s);}$$

$$C_p = \text{Calor específico volumétrico do ar (J/m}^3\text{K);}$$

$$\Delta T = \text{Diferença de temperatura (K).}$$

Utilizando a lei física de conservação de energia, em fluxos térmicos em W (J/s):

$$\dot{Q}_e - \dot{Q}_{cf} - \dot{Q}_c - \dot{Q}_r = 0 \quad (17)$$

ou,

$$\dot{Q}_e = \dot{Q}_{cf} + \dot{Q}_c + \dot{Q}_r \quad (18)$$

Onde;

$\dot{Q}_e$  = Taxa de geração de energia térmica pelo efeito *Joule* (aquecimento elétrico)

$\dot{Q}_{cf}$  = Taxa de transferência de energia por convecção forçada

$\dot{Q}_c$  = Taxa de transferência de energia por condução

$\dot{Q}_r$  = Taxa de transferência de energia por radiação

As trocas de calor são mostradas na figura 31.




Figura 31 - Conservação de Energia do Sensor Termal - Corte longitudinal

Foram adotadas as seguintes hipóteses simplificadoras:

- Transferência de energia térmica por radiação ( $\dot{Q}_r$ ) desprezível, principalmente para o lado externo do tubo, devido ao isolamento térmico;
- Transferência de energia térmica por condução ( $\dot{Q}_c$ ) para o lado externo do tubo é minimizada pelo isolamento térmico, podendo ser ajustada na modelagem ou ainda pela rede neural;
- Temperatura e densidade constante no fluido;

Ou seja,

$$\dot{Q}_r = 0,$$

$$\dot{Q}_c = 0 \text{ (por ajuste) então,}$$

$$\dot{Q}_e = \dot{Q}_{cf} \tag{19}$$

e portanto,

$$\dot{m} = \frac{\dot{Q}_e}{C_p \Delta T} \tag{20}$$

#### 4.4 Descrição da bancada de testes

A bancada de testes desenvolvida para a versão intrusiva foi alterada para o modo não-intrusivo com o intuito de realizar todos os estudos necessários para a conclusão deste trabalho. Ver figura 32.




Figura 32 - Bancada de Testes

Na figura 33, podemos ver o esquema elétrico da bancada de testes.

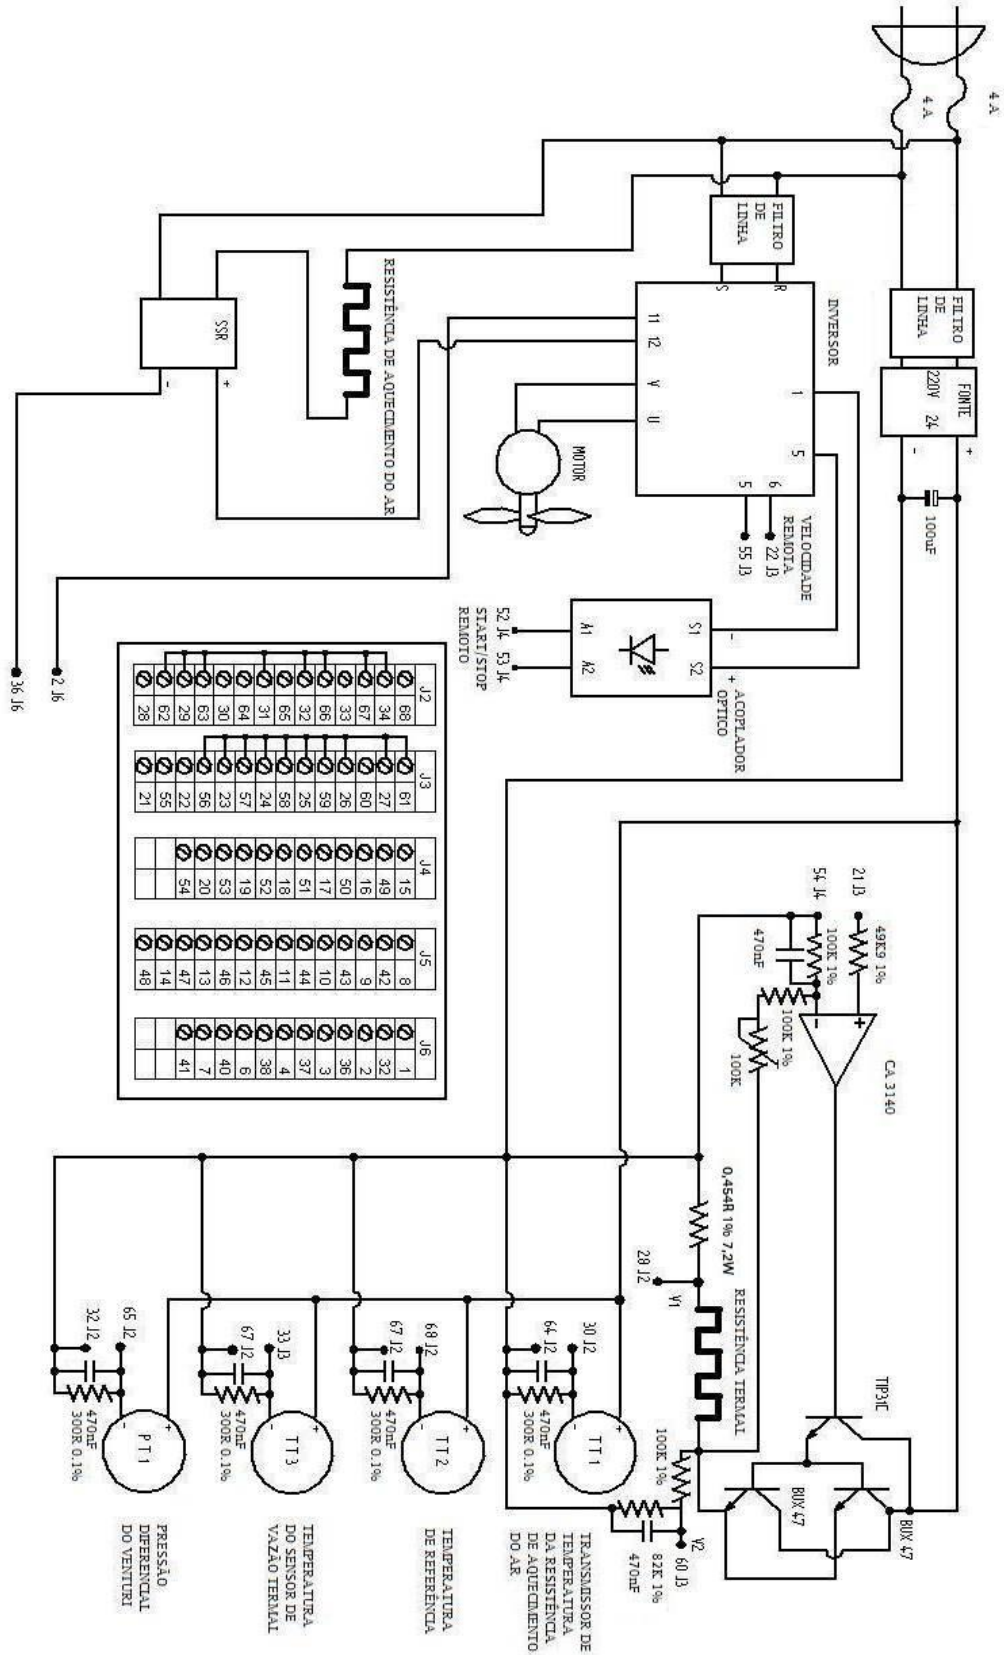


Figura 33 - Esquema elétrico da bancada de testes

Podemos ver no esquema elétrico: o inversor de frequência utilizado para variar a velocidade do ventilador centrífugo; os filtros de linha para minimizar os efeitos do ruído gerado pelo inversor; a fonte de 24V que fornece alimentação para os transmissores e para a resistência de aquecimento do sensor de vazão; o amplificador que alimenta a resistência de aquecimento do sensor de vazão; a chave estática que controla a resistência responsável pelo aquecimento do ar e o acoplador óptico que transmite o comando para ligar e desligar o inversor.

A fim de obter um medidor de vazão adicional de modo a facilitar as comparações com o modelo proposto, foi fabricado especialmente para este projeto um *Venturi* torneado em *nylon*. As dimensões do *Venturi* podem ser vistas na figura 34 e sua fotografia pode ser vista na figura 35.




Figura 34 - Desenho técnico do tubo *Venturi*





Figura 35 - Detalhe das conexões do tubo *Venturi*

Para diminuir a turbulência no fluxo de ar, foram fabricados especialmente para este projeto dois difusores torneados em *nylon*, conforme figura 36.




Figura 36 - Condicionador de fluxo

#### 4.5 Descrição das alterações da bancada

De modo a fornecer a potência necessária para o aquecimento do corpo do sensor Termal, a bancada é dotada de um amplificador com transistores de potência em configuração *Darlington*, para obtenção do ganho necessário. Este amplificador é o circuito eletrônico responsável por transformar o sinal de saída analógico da placa de aquisição, que possui uma excursão de 0 a 10 volts com capacidade de corrente máxima de 10 mA para até 2 A. Na figura 37, podemos ver com detalhes o esquema elétrico do amplificador e, na figura 38, a sua curva de resposta.

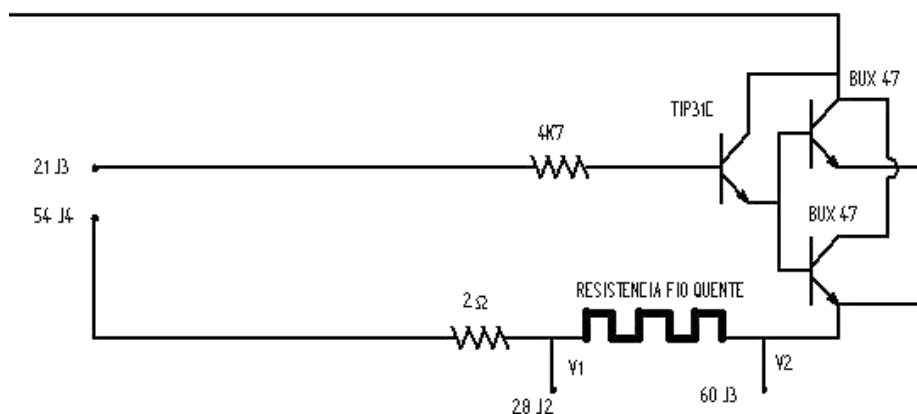


Figura 37 - Esquema Elétrico do Amplificador *Darlington*




Figura 38 - Curva de Resposta do Amplificador *Darlington*

O amplificador *Darlington* gerava uma tensão máxima de aproximadamente 7 volts, tendo como carga uma resistência elétrica de aproximadamente 20 ohms, sendo gerada uma potência elétrica máxima de aproximadamente 2,45 watts. Potência esta que, embora fosse suficiente para o modelo intrusivo, foi inadequada ao modelo não-intrusivo devido a sua maior massa e capacitância térmica.

Diante deste cenário, foi projetado um novo amplificador, dotado de outro circuito amplificador capaz de aumentar a excursão de tensão de saída. Este circuito, baseado em um amplificador operacional Bi-FETs comum, o CA3140 da RCA, cumpre a função de transformar o sinal de 0 a 10 volts da placa de aquisição em cerca de 0 a 20 volts para a resistência de aquecimento, permitindo uma potência de saída máxima de aproximadamente 20 watts. O esquema elétrico do amplificador pode ser visto na figura 39. Devido a esta nova arquitetura, também se tornou necessária a inclusão de um divisor de tensão para a medição da tensão na resistência de aquecimento do sensor termal, motivada pela limitação da faixa de medição da A/D da placa de aquisição, que possui uma faixa de 0 a 10 volts, obrigando a inclusão de um divisor de tensão resistivo. A curva de resposta do novo amplificador pode ser vista na figura 40.

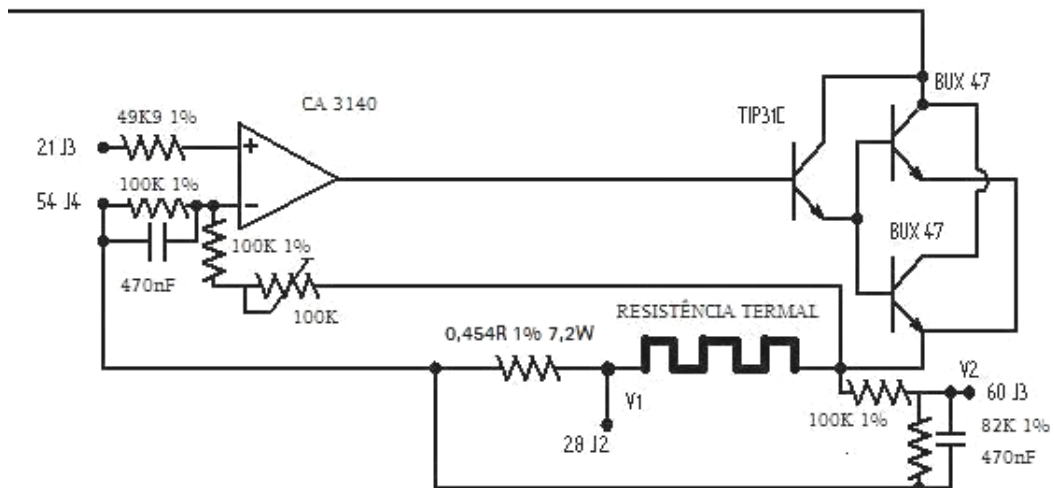


Figura 39 - Esquema elétrico do amplificador com operacional




Figura 40 - Curva de Resposta do Amplificador c/ Operacional

Durante os testes iniciais para a calibração da vazão, foi notado um excessivo aquecimento na área externa do sensor de vazão termal. Este aquecimento pode ser visto na figura 41.



Figura 41 - Temperatura externa das luvas de Teflon

A partir desta observação, foram confeccionadas novas luvas, substituindo o material *Teflon* pelo *Celeron*, com o objetivo de minimizar as perdas de calor no sensor. As novas luvas têm 80 mm de diâmetro ao invés dos 65 mm das luvas originais de *Teflon*. Na figura 42, podemos ver as novas luvas montadas e suas temperaturas externas.



Figura 42 - Temperatura externa das luvas de Celeron

Foram introduzidos isolantes térmicos de *Neoprene* nas luvas de *Celeron*, conseguindo então um bom nível de isolamento térmico, como pode ser visto na figura 43. Essas medições foram realizadas com a bancada em sua vazão máxima, temperatura do ar ajustada para 50°C , temperatura diferencial de 30°C e temperatura ambiente de 28,5°C. Esta nova configuração proporcionou um excelente isolamento térmico, minimizando eficientemente a perda de calor para o meio externo.



Figura 43 - Temperatura externa das luvas de Celeron com isolamento de Neoprene

#### 4.5.1 Calibração Elétrica

Os circuitos de medição de corrente e tensão da resistência de aquecimento do sensor termal são utilizados para a medição da potência requerida no aquecimento do sensor. Os medidores termais normalmente só se baseiam na medição da tensão, provocando um erro de medição devido à variação da resistência elétrica na resistência de aquecimento, em função da temperatura a que é exposto o fio resistivo. Este efeito é anulado pela medição direta da corrente e tensão na resistência de aquecimento. Foram utilizados dois multímetros,

devidamente calibrados, como instrumentos de referência (padrão) para a calibração elétrica da bancada de testes (indicadores das grandezas elétricas). Os multímetros utilizados são fabricados pela Fluke modelo 87.

Foram utilizados dois multímetros: um para medir a corrente que circula na resistência do sensor termal e outro para medição da tensão que alimenta a mesma resistência. O esquema elétrico da ligação dos multímetros é mostrado na figura 44.

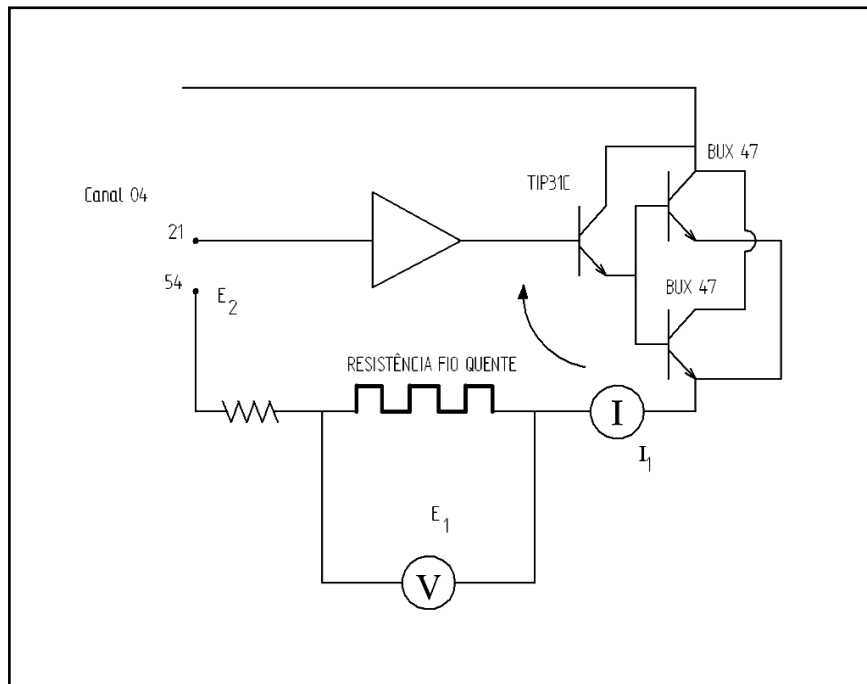


Figura 44 - Diagrama de Calibração

Nas tabelas 3, 4 e 5 são apresentados respectivamente os resultados da calibração das grandezas tensão, corrente e potência que incidem na resistência do sensor termal. Nas figuras 45, 46 e 47 são mostrados os gráficos dos erros das mesmas grandezas elétricas. O cálculo da incerteza de calibração foi realizado com um índice de confiança de aproximadamente 95%, dois desvios padrão.

Tabela 3 - Resultado da Calibração Elétrica - Tensão

Tensão D/A	Padrão - Multímetro (V)	Valor Medido - Amplificador (V)	Erro	Incerteza
0	0.013	0.011	-0.002	0.001
1	2.012	2.017	0.005	0.002
2	4.012	4.020	0.008	0.003
3	6.002	6.012	0.010	0.004
4	8.003	8.015	0.012	0.005
5	10.005	10.015	0.010	0.006
6	12.009	12.018	0.009	0.016
7	14.012	14.016	0.004	0.017
8	16.006	16.008	0.002	0.018
9	18.008	18.002	-0.006	0.019
10	19.985	19.971	-0.014	0.020

Tabela 4 - Resultado da Calibração Elétrica - Corrente

Tensão D/A	Padrão - Multímetro (A)	Valor Medido - Amplificador (A)	Erro	Incerteza
0	0.0005	0.001	0.001	0.002
1	0.0994	0.099	0.000	0.002
2	0.1976	0.198	0.000	0.002
3	0.2957	0.296	0.000	0.003
4	0.3937	0.395	0.001	0.003
5	0.4923	0.491	-0.001	0.003
6	0.5903	0.589	-0.001	0.003
7	0.6875	0.686	-0.001	0.003
8	0.7840	0.783	-0.001	0.004
9	0.8799	0.880	0.000	0.004
10	0.9725	0.971	-0.002	0.004



Tabela 5 - Resultado da Calibração Elétrica - Potência

Tensão D/A	Padrão - Multímetro (W)	Valor Medido - A/D (W)	Erro	Incerteza
0	0.000	0.000	0.000	0.012
1	0.200	0.200	0.000	0.012
2	0.793	0.798	0.005	0.012
3	1.775	1.777	0.002	0.011
4	3.151	3.164	0.013	0.011
5	4.925	4.921	-0.004	0.011
6	7.089	7.089	0.000	0.011
7	9.633	9.624	-0.009	0.011
8	12.549	12.548	-0.001	0.010
9	15.845	15.856	0.011	0.010
10	19.435	19.425	-0.010	0.010




Figura 45 - Gráfico da Calibração Elétrica - Tensão




Figura 46 - Gráfico da Calibração Elétrica - Corrente




Figura 47 - Gráfico da Calibração Elétrica - Potência

Os resultados das calibrações (tabelas e gráficos) mostradas foram considerados satisfatórios. Os erros máximos encontrados foram: 0,015 V na calibração da tensão, 0,0015 A em corrente e 0,015 W em potência. Nos gráficos não notamos nenhuma tendência definida, indicando que os erros são provavelmente provenientes de quantização dos conversores A/Ds de 12 bits da placa de aquisição que possui uma especificação de 0,2%.

#### 4.6 Proposta para auto-ajuste usando Redes Neurais

A pesquisa bibliográfica realizada demonstrou que as redes neurais são capazes de aproximar diferentes tipos de funções e podem ser facilmente integradas a um sensor inteligente (RIVERA, 2007), (OLIVEIRA, 2009b).

Foi escolhida uma estrutura que utiliza uma rede neural MLP para corrigir os erros no valor da vazão obtido por meio da modelagem física apresentada na seção 4.3. Estruturas semelhantes podem ser encontradas em Barbosa et al (2007) e em Patra et al (2004). Na estrutura proposta, que pode ser vista na Figura 48, o treinamento da rede neural é feito utilizando como entrada a temperatura e a potência medidas e como saída o erro entre a vazão fornecida pela modelagem física e a vazão obtida pelo Venturi que está instalado na bancada. Deste modo, a rede neural aprende qual o erro da modelagem física em função da potência e temperatura medidas. Assim, durante a operação normal do sensor, o valor calculado pela modelagem física é corrigido pela rede neural.

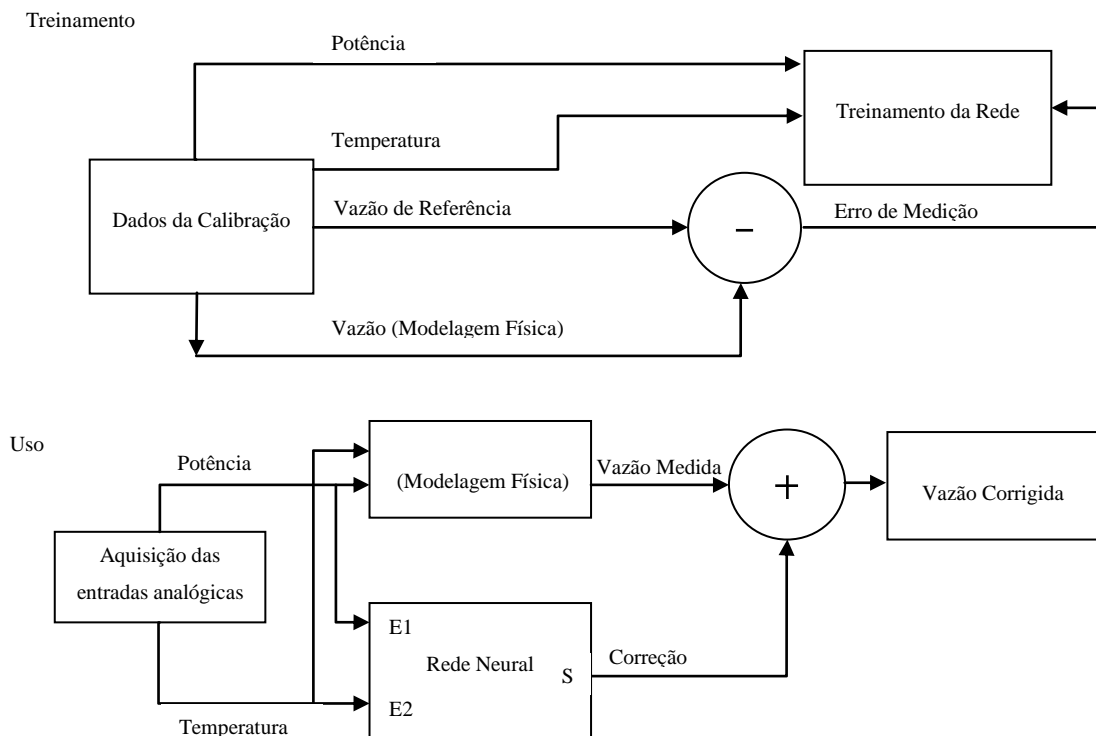


Figura 48 - Estrutura Utilizada

O conjunto de dados disponível foi obtido por meio de uma calibração com 14 pontos na faixa de 0,00375 Kg/s a 0,01275 Kg/s, combinado com o ajuste da temperatura do ar em 35, 40, 45 e 50 °C, perfazendo um total de 56 pontos.

A escolha do número de neurônios na camada escondida é feita com auxílio da validação cruzada, que é uma técnica usada para estimar o desempenho de um modelo (WITTEN, 2005). O conjunto de dados disponível é dividido em K partes e para cada uma destas partes, uma rede neural diferente é treinada usando as partes restantes como conjuntos de treinamento e validação para o *Early Stopping*. Este procedimento é repetido K vezes, e a média dos erros obtidos nos K conjuntos fornece uma estimativa do desempenho. Para reduzir a variância, todo o processo de validação cruzada pode ser repetido certo número de vezes. Experimentando diferentes valores para o número de neurônios na camada escondida,

pode-se escolher aquele que fornece o melhor desempenho, isto é, a menor média do erro médio quadrático.

Uma vez obtido o número de neurônios na camada escondida, três redes podem ser obtidas utilizando diferentes estratégias de treinamento. A primeira rede, RN1, é obtida repetindo-se o processo de validação cruzada, e guardando a rede que teve o menor erro. A segunda rede, RN2, é obtida usando todo o conjunto de dados disponível para treinamento. RN2 é treinada com o número médio de épocas de treinamento de todas as redes treinadas durante a validação cruzada. O erro de treinamento desejado é dado pela média dos erros médios quadráticos obtidos durante a validação cruzada. Finalmente, obtém-se a terceira rede, RN3, usando-se a regularização Bayesiana no treinamento (MACKAY, 1992), pois ela faz com que a rede tenha pesos com valores menores, o que torna as saídas mais suaves, diminuindo a possibilidade de supertreinamento.

## 5 AVALIAÇÃO EXPERIMENTAL

Neste capítulo podemos encontrar os testes iniciais, evoluções e experimentos realizados na bancada experimental.

### 5.1 Validação do modelo

Neste item podemos encontrar os resultados das calibrações do medidor proposto.

#### 5.1.1 Calibração da Vazão usando a modelagem física

O procedimento de calibração:

- A partir de testes realizados na bancada foi definida as faixas de medição do instrumento.
  - Vazão de 0,00375 kg/s a 0,01275 kg/s;
  - Temperatura do ar 35 a 50°C;
  - Temperatura diferencial de 10 a 30 °C;
  - Temperatura do sensor aquecido de 45 a 80 °C.
- Devido à própria construção física da bancada, os medidores de vazão (*Venturi* e Termal) estão em série e as leituras das suas medições são realizadas simultaneamente pelo *software* de controle.
- A cada nova temperatura do Ar o medidor foi submetido à vazão máxima do sistema por trinta minutos, tempo necessário para estabilização do sistema devido à massa e à capacitância térmica do sensor;
- A cada novo ponto de calibração (vazão), aguardou-se cinco minutos para estabilização do sistema;

A calibração da medição da vazão do sensor termal foi realizada tendo como instrumento de referência o medidor de vazão tipo *Venturi* da própria bancada. Foram feitas calibrações com 14 pontos na faixa de 0,00375 kg/s a 0,01275 kg/s, combinadas com o ajuste da temperatura do ar em 35, 40, 45 e 50 °C e temperaturas diferenciais de 10, 15, 20, 25 e 30 °C, perfazendo um total de 280 pontos. Nas figuras 49, 51, 53, 55 e 57 podemos ver os erros percentuais sobre os valores lidos nas temperaturas diferenciais de 10, 15, 20, 25 e 30 °C, nas

figuras 50, 52, 54, 56 e 58 podemos ver os erros absolutos na mesmas temperaturas. O erro percentual é definido pela diferença o valor lido e o valor de referência dividida pelo valor de referência, multiplicado por cem.




Figura 49 - Calibração sem correção da Rede Neural / Dif.: 10 °C - Erro Relativo




Figura 50 - Calibração sem correção da Rede Neural / Dif.: 10 °C - Erro Absoluto




Figura 51 - Calibração sem correção da Rede Neural / Dif.: 15 °C - Erro Relativo




Figura 52 - Calibração sem correção da Rede Neural / Dif.: 15 °C - Erro Absoluto




Figura 53 - Calibração sem correção da Rede Neural / Dif.: 20 °C - Erro Relativo




Figura 54 - Calibração sem correção da Rede Neural / Dif.: 20 °C - Erro Absoluto






Figura 55 - Calibração sem correção da Rede Neural / Dif.: 25 °C - Erro Relativo




Figura 56 - Calibração sem correção da Rede Neural / Dif.: 25 °C - Erro Absoluto




Figura 57 - Calibração sem correção da Rede Neural / Dif.: 30 °C - Erro Relativo




Figura 58 - Calibração sem correção da Rede Neural / Dif.: 30 °C - Erro Absoluto

Podemos notar, nas figuras 49 a 58, uma forte influência da temperatura do ar na dispersão dos erros do sensor termal, principalmente nas baixas vazões pela diferença entre as curvas. A modelagem simples que foi feita não consegue representar corretamente o sistema. Com o intuito de compensar a variação da temperatura do ar, a temperatura do sensor termal é mantida constante de modo diferencial em relação à do ar. No entanto, com a modelagem aplicada, esta compensação não é suficiente para alcançarmos o nosso objetivo de precisão. Uma possível causa para a perturbação na modelagem é a transmissão de calor entre o trecho de tubulação que mede a temperatura de referência e o trecho aquecido que mede a vazão, além das perdas de calor para a tubulação de um modo geral.

Na figura 59, foi feita uma comparação entre os resultados das calibrações nas temperaturas diferenciais de 10, 15, 20, 25 e 30 °C, nesta comparação podemos ver os erros médios e o desvio padrão deste erro para três execuções consecutivas do *software* em *Matlab*.




Figura 59 - Comparação entre os ajustes de Temperatura Diferencial

A partir da análise da figura 59, foi definido o ajuste de 25°C para a temperatura diferencial do sensor termal, por causa do somatório do seu erro médio e desvio padrão dos erros. Na tabela 6, podemos ver o resultado do teste da Histerese do sensor termal na temperatura diferencial de 25°C. Neste teste, o sensor foi exposto a saltos de vazão, retornando aos mesmos pontos através de percursos diferentes. O que não aconteceu na

calibração, em que o sensor foi exposto a uma rampa descendente com intervalos regulares dentro da faixa de medição. Pode-se notar, nas variações encontradas na medição de vazão, que a variação na temperatura de referência é provavelmente o principal agente causador da geração de erros no sistema, como já foi visto nas curvas de calibração. O motivo da dispersão de valores de vazão em função da variação da temperatura de referência está provavelmente correlacionado a deficiências no isolamento térmico, massa e capacitância térmica dos sensores. A modelagem física, por sua vez, não está cobrindo todos estes aspectos.

Tabela 6 - Teste de Histerese (sem correção pela Rede Neural) - Dif. 25°C / Ar 50°C

Ar 50 °C / Dif. 25 °C (Teste de Histerese)						
Tensão D/A (Inversor)	Temp. Referência (°C)	Potência (W)	Vazão Mássica de Referência (kg/s)	Vazão Mássica Medida (kg/s)	Erro (kg/s)	Erro (% V.L.)
0.00	39.18	6.731	0.00367	0.00341	0.00026	7.62%
2.90	40.52	9.036	0.00838	0.00778	0.00060	7.71%
9.35	42.45	11.375	0.01318	0.01271	0.00047	3.70%
2.90	41.36	8.734	0.00777	0.00782	-0.00005	-0.64%
0.00	39.82	6.583	0.00335	0.00363	-0.00028	-7.71%
9.35	42.50	11.191	0.01279	0.01273	0.00006	0.47%
Ar 50 °C / Dif. 25 °C (Teste de Histerese - Diferenças)						
0.00	-0.64	0.148	0.00032	-0.00022	0.00054	15.84%
2.90	-0.84	0.302	0.00061	-0.00004	0.00065	8.35%
9.35	-0.05	0.184	0.00039	-0.00002	0.00041	3.23%

### 5.1.2 Ajuste do Algoritmo de Correção (*Matlab*)

Para ajustar as configurações do algoritmo de correção através de rede neural desenvolvido em *Matlab*, foi utilizado o roteiro abaixo descrito:

- Definição do algoritmo de treinamento a ser utilizado. Com base na pesquisa realizada, foi definido o algoritmo “*Levenberg-Marquardt*” (HANG et al, 2002).
- Definição da temperatura diferencial a ser aplicada à correção pela rede neural. De acordo com o gráfico, os menores erros ocorrem para a temperatura de 25 °C, logo, esta foi a temperatura diferencial escolhida.

- Definição da constante “K”, ou seja, o número de partições para a validação cruzada. Foi definido o valor 5 para constante “K”.
- Definição do número de repetições do algoritmo, ou seja, o número de vezes que a validação cruzada é realizada com o objetivo de reduzir a variância. Foi definido o valor 10 para o número de repetições.
- Definição do número de neurônios da camada escondida através da validação cruzada. Foi realizado um experimento variando-se o número de neurônios de 1 a 20 e verificando-se o erro médio na validação cruzada, com os dados da calibração à 25°C de temperatura diferencial.
- Com todos os parâmetros definidos, isto é, “K”, número de repetições, número de neurônios e temperatura diferencial, foram geradas e treinadas as redes RN1, RN2 e RN3 e comparados os erros médios das redes.

Em todos os testes, o algoritmo foi executado três vezes seguidas, de modo a medir sua repetitividade. Na figura 60, pode-se ver o resultado do teste variando-se o número de neurônios da camada escondida, nesta comparação podemos ver os erros médios normalizados e o desvio padrão deste erro para três execuções consecutivas do *software* em *Matlab*. Com base neste teste foram escolhidos nove neurônios para a camada escondida. O erro médio normalizado é definido como erro médio quadrático para os valores das saídas normalizados entre -1 e 1.




Figura 60 - Comparação entre os ajustes do número de neurônios

Com o algoritmo ajustado, a etapa posterior foi a comparação do desempenho do algoritmo com os resultados da calibração inicial em todas as temperaturas diferenciais. Na figura 61, podemos ver o resultado desta comparação e novamente identificamos que a temperatura diferencial de 25°C apresentou melhor resultado.




Figura 61 - Comparação entre as temperaturas diferenciais

A seguir, foi feito o experimento que compara o desempenho entre as redes RN1, RN2 e RN3. O resultado deste teste pode ser visto na figura 62, em que se pode notar que os melhores resultados são obtidos com RN1, para o erro médio.




Figura 62 - Comparação entre as redes neurais

O Algoritmo de correção baseado em Redes Neurais gerou uma tabela com as correções necessárias para o sensor termal, para a temperatura diferencial de 25°C. Um gráfico com a superfície desta tabela, gerada pela rede RN1, pode ser visto na figura 63. Na figura 64, vê-se a resposta da RN2 e na figura 65, a resposta da RN3. Podemos notar respostas suaves às variações de temperatura e potência, demonstrando ausência de supertreinamento. Notamos também que foi apontada necessidade de maiores correções nos extremos da temperatura de referência, principalmente nas potências mais baixas (menores vazões).

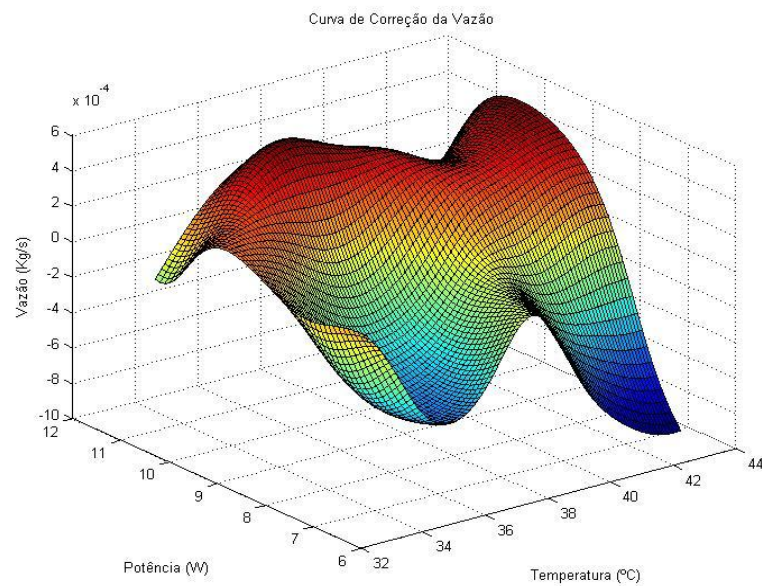


Figura 63 - Superfície de correção gerada pela Rede Neural (RN1)




Figura 64 - Superfície de correção gerada pela Rede Neural (RN2)




Figura 65 - Superfície de correção gerada pela Rede Neural (RN3)

Em análise preliminar nos gráficos das superfícies das correções das redes, podemos notar que: A RN2 apresentou uma superfície mais pobre em detalhes, com uma provável baixa eficiência no treinamento, valendo ressaltar que esta rede apresentou um erro médio maior. A RN3 apresentou uma superfície com um nível médio de detalhes, com uma provável



média eficiência no treinamento, apresentando erro médio intermediário. A RN1 apresentou uma superfície com um bom nível de detalhes, com boa eficiência no treinamento, apresentando um erro médio mais baixo entre as redes.

As tabelas de correção foram geradas pela inferência da rede neural a partir da excursão de potência e temperatura diferencial na faixa da calibração, com passos fixos de 0,1 °C e 0,1 W. O programa desenvolvido em *Matlab* salva em disco, no formato do *Excel* (campos delimitados pelo caractere *Tab*), tendo sido este padrão adotado por ser facilmente lido por vários *softwares*, inclusive o *LabView*. São exportados três arquivos: um contendo uma matriz quadrada em que estão os valores da correção (cuja superfície pode ser vista nas figuras 63, 64 e 65); outro contendo um vetor com os valores de temperatura diferencial que foram submetidos à rede; e o terceiro arquivo contendo um vetor com os valores de potência que também foram submetidos à rede.

### 5.1.3 Ajuste do Algoritmo de Correção (*LabView*)

O *software* aplicativo desenvolvido, em *LabView* versão 8.6, para controlar a bancada foi alterado de modo a “ler” os arquivos de correção gerados pela Rede Neural. O usuário decide se deseja carregar um arquivo de correção e escolhe que arquivo deseja carregar e o sistema se encarrega de carregar automaticamente os dois outros arquivos necessários para correção. Mesmo após a carga dos arquivos de correção, esta pode ser ligada ou desligada em qualquer instante. O painel frontal (interface gráfica) do *software* aplicativo pode ser visto na figura 66 e a janela de carga do arquivo de correção pode ser vista na figura 67.

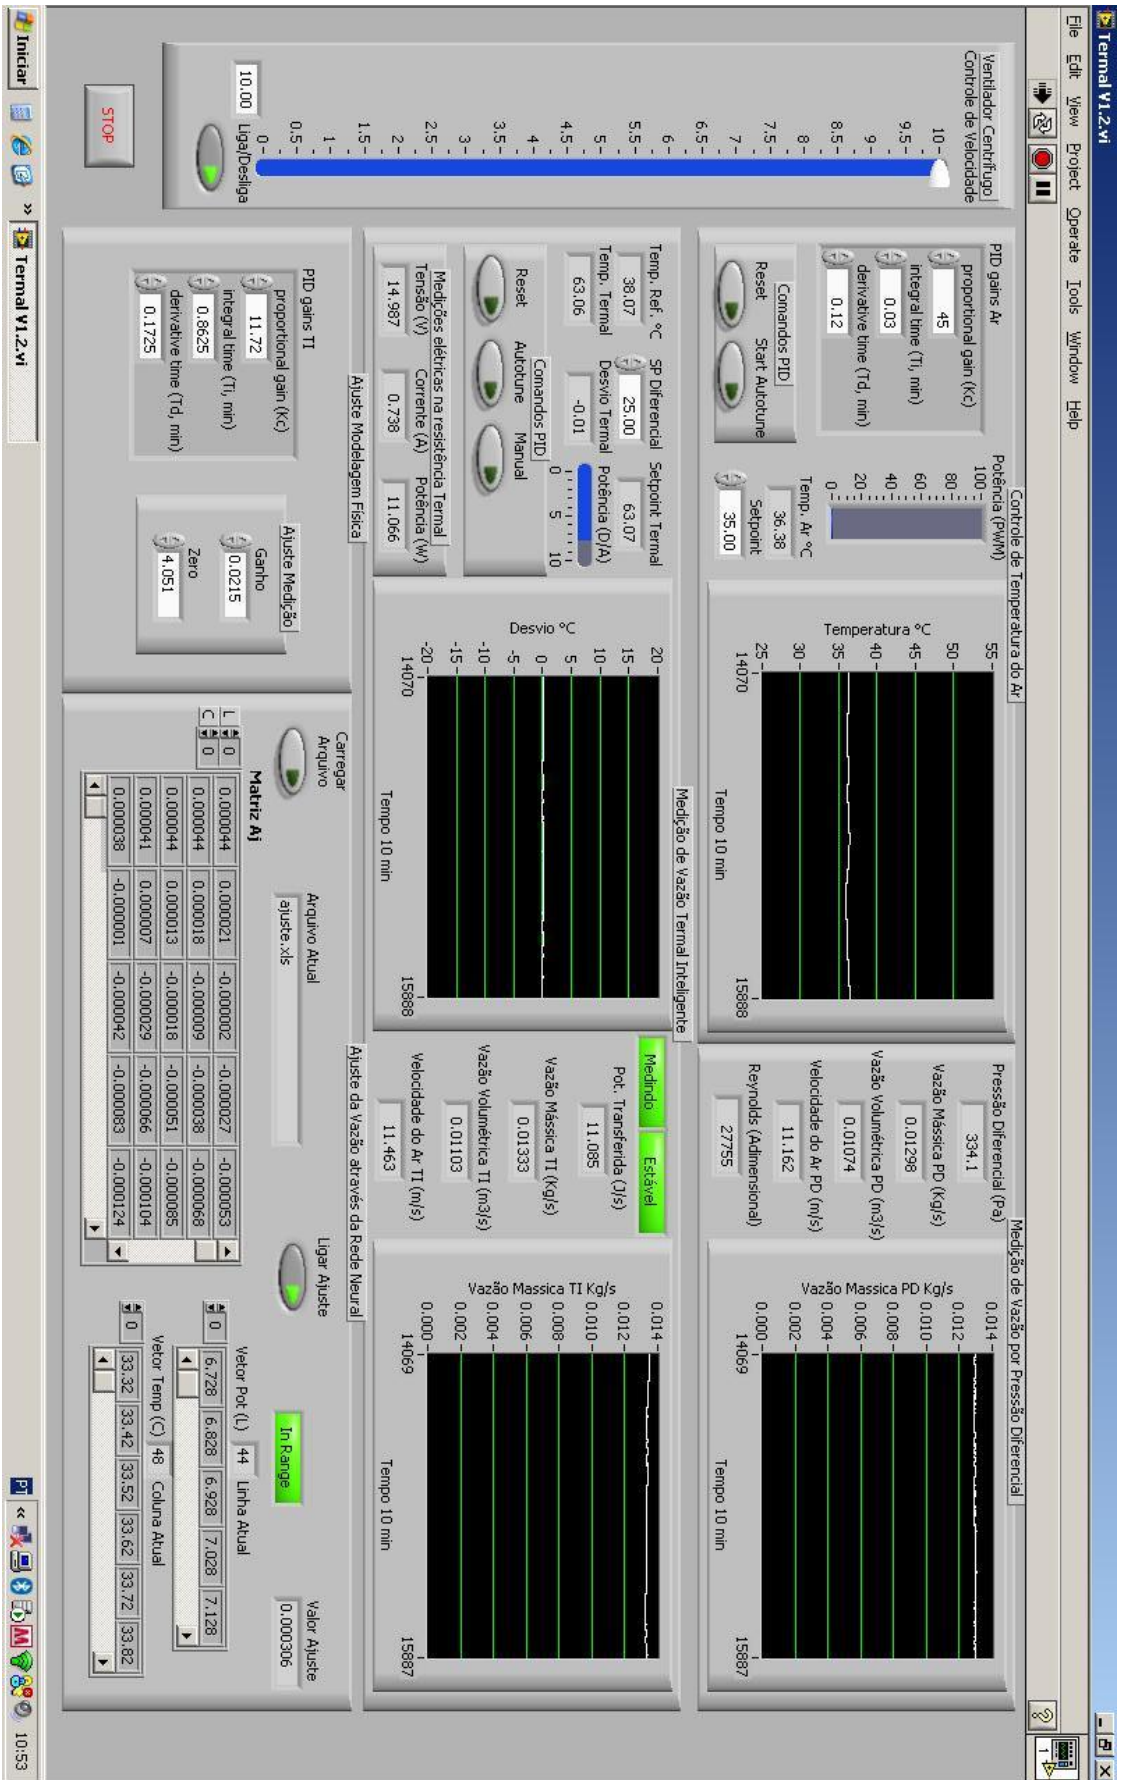


Figura 66 - Painel frontal (interface gráfica) do software aplicativo

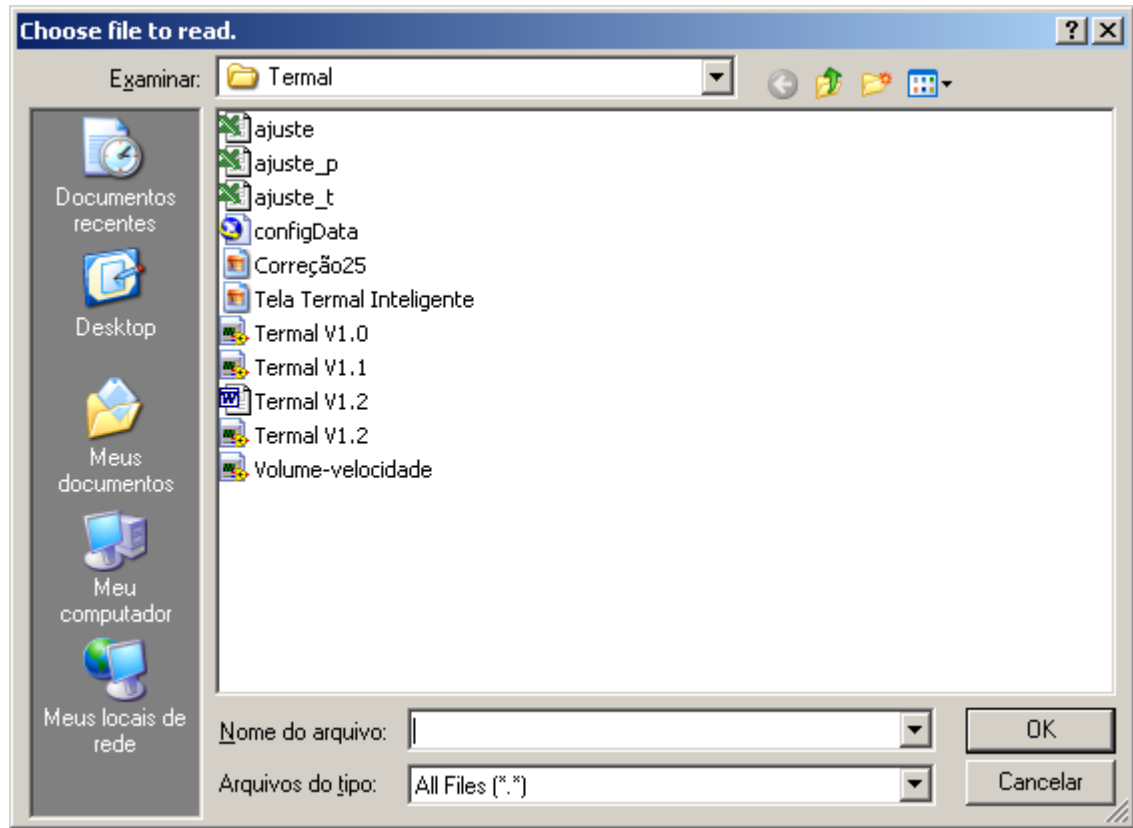


Figura 67 - Janela de carga do arquivo de correção

No painel frontal foram incluídos indicadores para visualização da matriz de correção e dos vetores de temperatura diferencial e potência, de modo a facilitar a depuração de qualquer possível erro no *software*. O aplicativo utiliza os vetores (temperatura diferencial e potência) para indexar a matriz de correção e localizar a melhor correção para a medição de potência e temperatura de referência que está sendo medida naquele instante, o valor utilizado no momento pode ser visto no indicador “Valor Ajuste”, existem também indicadores para os indexadores: “Linha Atual” e “Coluna Atual”. Foi incluído ainda um indicador booleano, de modo a informar se os valores medidos naquele instante estão dentro ou fora da faixa de correção. Mesmo que os valores estejam fora da faixa, a correção mais próxima é utilizada.

#### 5.1.4 Calibração da Vazão (Inteligente)

Com intuito de finalizar a validação do nosso sistema, o medidor proposto foi submetido a uma nova calibração, desta vez com a tabela de correção gerada pela rede neural. Nesta calibração foi utilizada somente a temperatura diferencial de 25°C, por ter obtido melhores resultados na primeira calibração e nos testes com a rede neural. No entanto, toda a faixa da temperatura do ar foi utilizada para submeter o novo sistema de medição às mesmas condições da calibração anterior.

O procedimento de calibração foi exatamente (com exceção das outras temperaturas diferenciais) o mesmo da primeira calibração:

- A cada nova temperatura do ar, o medidor foi submetido à vazão máxima do sistema por trinta minutos;
- A cada novo ponto calibração (vazão), aguardou-se cinco minutos para estabilização do sistema;
- Foram executadas três medições consecutivas (temperatura referência, potência, vazão mássica medida, vazão mássica de referência) com um intervalo de tempo de um minuto entre o conjunto de medições.
- O cálculo da incerteza de medição da calibração foi expandida com um índice de confiança de aproximadamente 95%, dois desvios padrão.

Nas figuras 68, 70 e 72 podemos ver os gráficos que resumem os erros de medição do sensor proposto, em valor percentual sobre o valor lido, em todas as faixas de vazão e temperatura do ar, para as três propostas de redes neurais, RN1, RN2 e RN3. Nas figuras 69, 71 e 73 podemos ver os gráficos com os erros em valores absolutos para as três redes testadas.




Figura 68 - Gráfico da calibração com correção da Rede Neural (RN1) - Erro Relativo




Figura 69 - Gráfico da calibração com correção da Rede Neural (RN1) - Erro Absoluto




Figura 70 - Gráfico da calibração com correção da Rede Neural (RN2) - Erro Relativo




Figura 71 - Gráfico da calibração com correção da Rede Neural (RN2) - Erro Absoluto




Figura 72 - Gráfico da calibração com correção da Rede Neural (RN3) - Erro Relativo




Figura 73 - Gráfico da calibração com correção da Rede Neural (RN3) - Erro Absoluto

É importante ressaltar que neste gráfico nota-se que atingimos nossa meta inicial de 5% de erro sobre o valor lido em toda a faixa de medição, somente com a RN1 (figura 68).

Nas tabelas 7, 8, 9 e 10, vê-se o comportamento médio do sensor em cada ponto de calibração, nas temperaturas do ar: 35, 40, 45 e 50 °C. Notam-se também as incertezas associadas a cada ponto de calibração, usando a correção da RN1.

Tabela 7 - Calibração com correção da Rede Neural / Ar: 35 °C

Temperatura do Ar 35°C				
Temp. Referência (°C)	Vazão Mássica de Referência (kg/s)	Vazão Mássica Medida (kg/s)	Erro (kg/s)	Incerteza de Medição (kg/s)
36.21	0.01276	0.01282	0.00006	0.00011
36.29	0.01205	0.01205	0.00000	0.00008
36.19	0.01148	0.01137	-0.00012	0.00009
36.05	0.01070	0.01040	-0.00030	0.00005
36.14	0.00974	0.00940	-0.00034	0.00003
35.67	0.00923	0.00882	-0.00041	0.00005
35.57	0.00850	0.00812	-0.00038	0.00005
35.50	0.00781	0.00743	-0.00038	0.00005
35.42	0.00697	0.00664	-0.00033	0.00005
35.30	0.00618	0.00590	-0.00028	0.00002
35.24	0.00562	0.00543	-0.00020	0.00002
35.19	0.00481	0.00469	-0.00012	0.00009
35.15	0.00435	0.00429	-0.00006	0.00003
35.06	0.00383	0.00384	0.00002	0.00010



Tabela 8 - Calibração com correção da Rede Neural / Ar: 40 °C

Temperatura do Ar 40°C				
Temp. Referência (°C)	Vazão Mássica de Referência (kg/s)	Vazão Mássica Medida (kg/s)	Erro (kg/s)	Incerteza de Medição (kg/s)
38.55	0.01275	0.01253	-0.00022	0.00009
38.60	0.01205	0.01185	-0.00020	0.00002
38.50	0.01146	0.01115	-0.00031	0.00001
38.39	0.01066	0.01028	-0.00038	0.00002
38.14	0.00970	0.00922	-0.00047	0.00008
37.99	0.00922	0.00877	-0.00045	0.00004
37.85	0.00851	0.00809	-0.00042	0.00003
37.69	0.00781	0.00743	-0.00038	0.00004
37.55	0.00705	0.00670	-0.00034	0.00003
37.42	0.00620	0.00597	-0.00023	0.00003
37.32	0.00573	0.00555	-0.00018	0.00004
37.18	0.00480	0.00481	0.00000	0.00008
37.07	0.00429	0.00428	-0.00001	0.00012
36.96	0.00370	0.00367	-0.00003	0.00007

Tabela 9 - Calibração com correção da Rede Neural / Ar: 45 °C

Temperatura do Ar 45°C				
Temp. Referência (°C)	Vazão Mássica de Referência (kg/s)	Vazão Mássica Medida (kg/s)	Erro (kg/s)	Incerteza de Medição (kg/s)
40.53	0.01280	0.01240	-0.00041	0.00014
40.72	0.01211	0.01162	-0.00049	0.00002
40.68	0.01153	0.01109	-0.00045	0.00001
40.60	0.01071	0.01041	-0.00030	0.00002
40.44	0.00971	0.00951	-0.00020	0.00003
40.33	0.00919	0.00901	-0.00018	0.00005
40.18	0.00849	0.00831	-0.00018	0.00008
39.97	0.00784	0.00766	-0.00017	0.00012
39.78	0.00704	0.00689	-0.00015	0.00002
39.62	0.00622	0.00622	0.00000	0.00001
39.50	0.00568	0.00571	0.00003	0.00014
39.35	0.00493	0.00506	0.00012	0.00010
39.20	0.00421	0.00440	0.00019	0.00004
39.08	0.00374	0.00391	0.00017	0.00003

Tabela 10 - Calibração com correção da Rede Neural / Ar: 50 °C

Temperatura do Ar 50°C				
Temp. Referência (°C)	Vazão Mássica de Referência (kg/s)	Vazão Mássica Medida (kg/s)	Erro (kg/s)	Incerteza de Medição (kg/s)
42.70	0.01279	0.01252	-0.00027	0.00004
43.07	0.01212	0.01186	-0.00026	0.00005
43.12	0.01151	0.01122	-0.00029	0.00002
43.06	0.01067	0.01046	-0.00021	0.00008
42.89	0.00969	0.00956	-0.00013	0.00003
42.77	0.00935	0.00921	-0.00013	0.00003
42.62	0.00867	0.00852	-0.00014	0.00006
42.39	0.00789	0.00769	-0.00019	0.00010
42.20	0.00709	0.00677	-0.00031	0.00005
41.90	0.00629	0.00598	-0.00031	0.00004
41.51	0.00555	0.00529	-0.00026	0.00002
41.28	0.00453	0.00434	-0.00019	0.00009
41.12	0.00391	0.00375	-0.00016	0.00018
40.97	0.00336	0.00321	-0.00015	0.00006

Foi executado novamente o teste de histerese e o novo resultado pode visto na tabela 11. Pode ser notada uma significativa evolução em relação ao teste sem a correção da rede neural, confirmando influência da variação da temperatura nos resultados do teste.

Tabela 11 - Teste de Histerese (com correção pela Rede Neural) - Dif. 25°C / Ar 50°C

Ar 50 °C / Dif. 25 °C (Teste de Histerese)						
Tensão D/A (Inversor)	Temp. Referência (°C)	Potência (W)	Vazão Mássica de Referência (kg/s)	Vazão Mássica Medida (kg/s)	Erro (kg/s)	Erro (% V.L.)
0.00	40.88	6.178	0.00325	0.00340	-0.00015	-4.41%
2.90	41.42	8.408	0.00812	0.00814	-0.00002	-0.25%
9.35	42.61	10.570	0.01240	0.01287	-0.00047	-3.65%
2.90	42.12	8.286	0.00785	0.00801	-0.00016	-2.00%
0.00	41.60	6.251	0.00326	0.00340	-0.00014	-4.12%
9.35	42.58	10.525	0.01233	0.01286	-0.00053	-4.12%
Ar 50 °C / Dif. 25 °C (Teste de Histerese - Diferenças)						
0.00	-0.72	-0.073	-0.00001	0.00000	-0.00001	-0.29%
2.90	-0.70	0.122	0.00027	0.00013	0.00014	1.72%
9.35	0.03	0.045	0.00007	0.00001	0.00006	0.47%

## 6 CONCLUSÃO

Técnicas não-intrusivas de medição de vazão constituem uma necessidade crescente em diversas aplicações. Atualmente, diversos estudos têm sido realizados com o objetivo de desenvolver técnicas de medição não-intrusivas que possam suprir as deficiências das técnicas existentes.

Nesta dissertação foi construído um medidor de vazão termal não-intrusivo apresentou uma técnica de medição de vazão pelo princípio termal não-intrusivo, utilizando redes neurais para aumentar a exatidão do medidor proposto e proporcionar a funcionalidade de auto-ajuste. Além do medidor propriamente dito foi modificada uma bancada de testes descrita em Oliveira (2008) para possibilitar a medição da vazão em diferentes temperaturas.

Inicialmente, foram feitas alterações nos elementos transdutores em um medidor de vazão intrusivo termal (OLIVEIRA, 2008), para que ele se tornasse um medidor não-intrusivo. A seguir, foi desenvolvida uma modelagem para este medidor não-intrusivo, partindo-se da equação do medidor de vazão mássico por tubo aquecido, que foi desenvolvido originalmente por Thomas (TODA, 1996).

Observou-se que esta modelagem não fornecia resultados satisfatórios, sobretudo para valores mais baixos de vazão. Isto foi uma indicação de que algumas das características físicas do sensor projetado não foram totalmente levadas em consideração através da modelagem proposta.

A partir da pesquisa bibliográfica desenvolvida, percebeu-se o crescente uso de redes neurais em sensores inteligentes em diversas aplicações tais como: predição da deriva (variação dos erros sistemáticos ao longo do tempo) de instrumentos entre calibrações utilizando redes neurais (SACHENKO et al, 2000), técnicas de auto-ajuste (self-calibration) (PATRA et al, 2004 e RIVERA et al, 2007), detecção de falhas (NAJAFI et al, 2004), monitoramento e verificação de calibração (PINTO et al, 2005) e linearização das características de um transdutor para compensar os distúrbios causados por outras grandezas de influência (PEREIRA, 2005). Então, foi concebida uma estrutura na qual uma rede neural aprende os erros da vazão calculada pela modelagem física em relação a uma referência, para que, durante a utilização do medidor, a rede possa corrigir a vazão calculada. Esta estrutura foi testada para corrigir o erro de sensores PT-100 em relação a uma calibração, e os resultados dos testes foram publicados em congressos de metrologia (OLIVEIRA et al, 2009a e 2009b).

Foram avaliadas três redes neurais, obtidas por diferentes estratégias de treinamento. A primeira foi aquela que apresentou o menor erro médio quadrático em diversas repetições com diferentes conjuntos de treinamento, validação e teste. A segunda foi treinada com todos os dados disponíveis até que atingisse o erro médio encontrado na validação cruzada ou atingisse o número médio de épocas também encontrado durante a validação cruzada. A terceira foi treinada usando a Regularização Bayesiana.

Embora nem todas as redes tenham conseguido corrigir os erros para que o medidor obtivesse a precisão desejada, todas conseguiram melhorar a precisão do sensor proposto.

Uma característica interessante deste projeto é que devido à simplicidade da modelagem, através apenas de uma calibração, podem ser medidos outros gases ou até mesmo outros fluidos, pois a rede neural se encarregará de ajustar o medidor para o novo fluido. Da mesma maneira, turbulências geradas por acidentes na tubulação como: curvas, reduções, válvulas, bombas etc., podem ser corrigidas.

Os resultados mostraram que é possível o desenvolvimento de um sensor não-invasivo, além de não-intrusivo, ou seja, o fluido objeto da medição, não entrará em contato com o sensor, a medição será feita externamente ao tubo por onde o fluido escoar.

Com o objetivo de melhorar os resultados apresentados, são feitas algumas sugestões para trabalhos futuros:

- Melhorar o tempo de resposta do sensor através da diminuição da massa dos sensores e da melhoria do isolamento térmico.
- Analisar o efeito do aquecimento do fluido causado pelo princípio de medição para identificar os possíveis processos onde este efeito não seja prejudicial.
- Utilizar potência constante ao invés de temperatura diferencial constante para permitir que a medição se torne mais imune aos desvios e perturbações do controlador PID.
- Desenvolver outros modelos para o sensor que procurem levar em conta um maior número de características físicas.
- Avaliar o desempenho de outros tipos de redes neurais para realizar a correção.

## REFERÊNCIAS

\_\_\_\_\_. ABNT NBR ISO 6817: Medição de vazão de líquido condutivo em condutos fechados - Método utilizando medidores de vazão eletromagnéticos, 1999.

\_\_\_\_\_. IEEE 1451.0: Standard for a Smart Transducer Interface for Sensors and Actuators - Common Functions, Communication Protocols, and Transducer Electronic Data Sheet (TEDS) Formats, 2007.

\_\_\_\_\_. INMETRO VIM: Vocabulário Internacional de Termos Fundamentais e Gerais de Metrologia, 4ª edição, Rio de Janeiro, 2005.

\_\_\_\_\_. ISO 6817: ISO 6817 (1980): Measurement of conductive fluid flowrate in closed conduits - Methods using electromagnetic flowmeters, International Organization for Standardization, 1980.

ALBERTAZZI, A. G. Jr.; SOUZA, A. R.. Fundamentos de Metrologia Científica e Industrial. 1ª edição, Editora Manole, São Paulo, 2008.

AWWA. Flowmeters in Water Supply. 1ª edição, Denver, American Water Works Association, 1989.

BARBOSA, I. M.; del Moral Hernandez, E. ; REIS, Maria Colluci da Costa; MELO, Olimpio Achiles de Faria. Predições em Ajuste de Curva de Calibração Utilizando Redes Neurais Artificiais. In: Encontro para a Qualidade Laboratorial - ENQUALAB2007, 2007, São Paulo. CD do Encontro, 2007.

BENTLEY, J.P.. Principles of Measurement Systems. 3ª edição, Essex: Inglaterra, Longman G. L., 1995.

BENYOSEF, Luiz. TÓPICOS DE INSTRUMENTAÇÃO. OBSERVATÓRIO NACIONAL/Coord. Geofísica. GEOFÍSICA II. Disponível em: <[http://obsn3.on.br/laterra/2TRIMESTRE/INSTRUMENTAÇÃO\\_GEOFÍSICA/Aula\\_4\\_Geofísica\\_II.pdf](http://obsn3.on.br/laterra/2TRIMESTRE/INSTRUMENTAÇÃO_GEOFÍSICA/Aula_4_Geofísica_II.pdf)>. Acesso em: 18 set. 2008.

BIONDI, L. N.; PACHECO, M. A. C.; VELLASCO, M. M. B. R.; PASSOS, E. P. L.; CHIGANER, L.. Sistema Híbrido de Apoio à Decisão para Detecção e Diagnóstico de Falhas em Redes Elétricas. Anais do III Simpósio Brasileiro de Redes Neurais, Recife, p. 197-204, 1996.

BISHOP, C. M.. Neural Networks for Pattern Recognition. Oxford: Oxford University Press, 1995.

BRANCO, Gilberto. Medição de vazão com ultra-som. Mecatrônica Atual. Disponível em: <<http://www.mecatronicaatual.com.br/secoes/leitura/58>>. Acesso em: 23 Out. 2008.

COELHO, P. H. G.. A Simple Recurrent Neural Network Equalizer Structure. In: V Congresso Brasileiro de Redes Neurais, Rio de Janeiro, 2001.

- COMTE-BELLOT, G.. Hot wire anemometry. *Annu. Rev. Fluid Mech.*, 8, 209–231, 1976.
- DAYHOFF, Judith E.. *Neural Network Architectures an Introduction*, London, Van Nostrand Reinhold, 1990.
- DELMÉE, Gérard Jean. *Manual de medição de vazão. 2ª Edição*, São Paulo: Edgard Blücher, 1982.
- ELONKA, S. M.; PARSONS, A.R.. *Manual de Instrumentação.*, (Standard Instrumentation Questions and Answers), 1a edição, volume 1, São Paulo, Mc Graw Hill do Brasil Ltda., 1976.
- GRUBELNIK, V.; MARHL, M.. Drop Formation in a Falling Stream of Liquid, *American Journal of Physics*. 73 (5) May 2005, pp. 415-419
- HANG T. M.; HOWARD D. B.; MARK B.. *Neural Network Design*. PWS Publishing Company: Beijing, 2002.
- HASSOUN, M. H.. *Fundamentals of Artificial Neural Networks*. MIT PRESS, 1996
- HAUPTMANN, P.; HOPPE, N.; PUETTMET.. Ultrasonic Sensor for Process Industry. *IEEE Ultrasonic Symposium*, Vol. 1, pp:369-378, 2001.
- HAYKIN, S.. *Neural Networks a Comprehensive Foundation*, Englewood Cliffs: Macmillan College Publishing Company, 1994.
- INACIO, Joilson José. *Metrologia. Rede Metrológica Goiás*. Disponível em: <[http://www.ielgo.com.br/fiegiel/repositorio/editor/File/rede\\_metrologica\\_goias/notas\\_materias/artigo\\_metrologia\\_joilson.pdf](http://www.ielgo.com.br/fiegiel/repositorio/editor/File/rede_metrologica_goias/notas_materias/artigo_metrologia_joilson.pdf)>. Acesso em: 15 jan. 2009.
- LAWS, E.M; OUZZANE, A.K.. A Further Investigation in Flow Conditioner Design Yielding Compact Installations for Orifice Plate Flow Metering. *Flow Meas. Instrum.*, vol. 6, n. 3, pp.187-199. , 1995.
- MACKAY, D.J.C.. A Practical Bayesian Framework for Backpropagation Networks. *Neural Computation*, Vol. 4(3), pp. 448-472, 1992.
- NAJAFI, M.; CULP, C.; LANGARI, R.. *Performance Study of Enhanced Auto-Associative Neural Networks for Sensor Fault Detection*, Energy Systems Laboratory, 2004.
- NGUYEN, Nam-Trung. *Flow Measurement*, 28.9, by CRC Press LLC, 1999.
- OLIVEIRA, M. A. A. de; AMARAL, J. L. M. ; AMARAL, J. F. M. ;PINHEIRO, G. R. V.. *Desenvolvimento de um Anemômetro por Convecção Forçada*. I CIMMEC - Primeiro Congresso Internacional de Metrologia Mecânica, Rio de janeiro, Brasil, 2008
- OLIVEIRA, M. A. A. de; AMARAL, J. L. M. do; AMARAL, J. F. M. do. *Algoritmos para Auto-Ajuste de Sensores Utilizando Redes Neurais*. VIII Semetro - Oitavo Seminário Internacional de Metrologia Elétrica, João Pessoa, PB, Brasil, 2009a.

OLIVEIRA, M A. A. de; AMARAL, J. L. M. do; AMARAL, J. F. M. do. Auto-Ajuste De Sensores Com Poucos Pontos Utilizando Redes Neurais. METROLOGIA 2009- Quinto Congresso Brasileiro de Metrologia, Salvador, Bahia – Brasil, 2009b

PALLÀS-ARENY, RAMON; WEBSTER JOHN G.. Sensor and signal condition, 2and ed, pp. 2, 492-493, 2001.

PATRA, J. C.; GOPALKRISHNAN, V.; ANG, E. L.; DAS, A.. Neural Network-Based Self-Calibration/ Compensation of Sensors Operating in Harsh Environments. Sensors, 2004. Proceedings of IEEE Volume, Issue, 24-27 Oct. 2004 Page(s): 425 - 428 vol.1.

PEREIRA, J.M. D.; POSTOLACHE, O.; GIRÃO, P. S.. Using a Dual-Channel FDC Device and ANN Techniques to Improve Measurements Accuracy. Sensors & Transducers Magazine (S&T e-Digest),2005, vol.62, Issue 12, pp.462-472.

PINTO, J. O. P.; PINTO, A. M. A. C; TATIBANA, G. S.; SANCHES, R. O.; CARRASCO, B. N.; FLORA, N.; HINES, J. W.. Uma Nova Estratégia de Modelagem para Monitoramento de Instrumentos e Verificação de Calibração Usando Redes Neurais Artificiais. Anais do 3º Congresso Brasileiro de P&D em Petróleo e Gás, 2005.

RIVERA, J.; CARRILLO, M.; CHACÓN, M.; HERRERA, G.; BOJORQUEZ, G.. Self-Calibration and Optimal Response in Intelligent Sensors Design Based on Artificial Neural Networks. Sensors ISSN 1424-8220, 7, 1509-1529, 2007.

SACHENKO, A.; KOCHAN, V.; TURCHENKO, V.. Intelligent System for Prediction of Sensor Drift. In Proc. of International Workshop on Virtual and Intelligent Measurement Systems,2000, Annapolis, USA, pp 88-92.

SHERCLIFF, J.A.. The Theory of Eletromagnetic Flowmeasurement. 1ª edição, Londres, Ed. Cambridge Univ., 1962.

TODA, K.; SANEMASA, I.; ISHIKAWA, K.. Simple temperature compensation of thermal air-flow sensor. Sensors and Actuators A: Physical. Volume 57, Issue 3, December 1996, Pages 197-201.

TROSKOLANSKI, A. T.. Hydrometry - Theory and Praticce of Hydraulic Measurements, Oxford, Pergamon Press, 1960.

WITTEN, I. H.; FRANK, E.. Data Mining: Practical Machine Learning Tools and Techniques. San Francisco: Morgan Kaufmann; 2 edition ,June , 2005.



## ANEXO - Artigos Publicados em Congressos

### I CIMMEC 1º CONGRESSO INTERNACIONAL DE METROLOGIA MECÂNICA DE 8 A 10 DE OUTUBRO DE 2008 Rio de Janeiro, Brasil

## DESENVOLVIMENTO DE UM ANEMÔMETRO POR CONVECÇÃO FORÇADA

Marcos A. A. de Oliveira<sup>1</sup>, Gil Roberto Vieira Pinheiro<sup>2</sup>, Jorge L. M. do Amaral<sup>3</sup>, José F. M. do Amaral<sup>4</sup>

<sup>1</sup> UERJ / Laboratórios BBraun S.A., Rio de Janeiro, Brasil, marcos.oliveira@bbraun.com

<sup>2</sup> UERJ, Rio de Janeiro, Brasil, gilpinheiro@petrobras.com.br

<sup>3</sup> UERJ, Rio de Janeiro, Brasil, jamaral@uerj.br

<sup>4</sup> UERJ, Rio de Janeiro, Brasil, franco@uerj.br

**Resumo:** A medição de vazão por convecção forçada baseia-se no efeito refrigerante de um fluido que passa sobre um transdutor aquecido. O fluido que se desloca através de uma seção tubular passa sobre dois transdutores de temperatura (RTD) do tipo PT100. Um dos sensores é usado para a medição da temperatura do fluido, o outro, mantido aquecido, mede a vazão do fluido.

**Palavras chave:** Anemometria, Convecção Forçada, Medição de Vazão.

### 1. INTRODUÇÃO

A medição de vazão de fluidos está presente em diversas atividades humanas. Não precisamos ir muito longe, o hidrômetro de uma residência, o marcador de uma bomba de combustível são exemplos comuns no dia-a-dia das pessoas. Em muitos processos industriais, ela é uma necessidade imperiosa, sem a qual dificilmente poderiam ser controlados ou operados de forma segura, eficiente e econômica.

Na História, grandes nomes marcaram suas contribuições. Provavelmente a primeira foi dada por Leonardo da Vinci que, em 1502, observou que a quantidade de água por unidade de tempo que escoava em um rio era a mesma em qualquer parte, independente da largura, profundidade, inclinação e outros. Entretanto, o desenvolvimento de dispositivos práticos só foi possível com o surgimento da era industrial e o trabalho de pesquisadores como Bernoulli, Pitot e outros.

Existe uma variedade de tipos de medidores de vazão, desde os simples aos mais sofisticados, para as mais diversas aplicações. O tipo a usar sempre irá depender do fluido, do seu estado físico (líquido ou gás), das características de exatidão e confiabilidade desejadas além de outros fatores.

A qualidade da medição da vazão depende das técnicas de medição, e os principais fatores intervenientes são: o conhecimento do comportamento as condições físicas do fluido, no ponto da medição e a forma construtiva do

medidor e, em alguns casos, a condição de instalação do medidor.

### 2. OBJETIVO

O objetivo principal deste trabalho é o desenvolvimento para fins acadêmicos de um medidor de vazão baseado no princípio da convecção térmica forçada, utilizando-se de recursos comerciais como sensores para medição de temperatura, transdutores e um dispositivo de aquisição conectado a um PC.

### 3. MÉTODOS

Para a avaliação mais completa do medidor de vazão, foi desenvolvida uma bancada experimental dotada de um outro medidor de vazão que utiliza o princípio deprimogênio, permitindo a comparação dos resultados em tempo real nos dois medidores. Para a calibração dos medidores de vazão convecção forçada e por diferencial de pressão foi utilizado como padrão um anemômetro do tipo turbina do fabricante TESTO modelo 400.

O princípio de medição que foi o objetivo principal deste trabalho baseia-se no efeito refrigerante de um fluido que passa sobre um transdutor aquecido. O fluido que se desloca através de uma seção tubular passa sobre dois transdutores de temperatura (RTD) do tipo PT100. Um dos sensores é usado para a medição da temperatura do fluido, o outro, mantido aquecido, mede a vazão do fluido. Ver figura 1

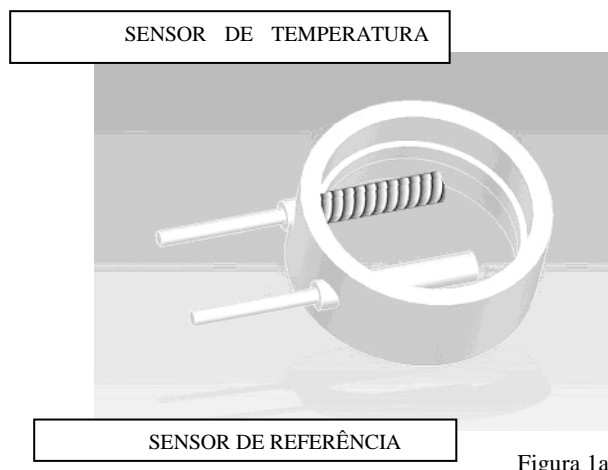


Figura 1a




Figura 1b




Figura 1c

O sensor de referência monitora a temperatura do fluido, enquanto o sensor aquecido é mantido a uma temperatura diferencial constante (acima da temperatura do fluido). O diferencial de temperatura é controlado variando-se a tensão que alimenta a resistência de aquecimento acoplada ao sensor.

Quanto maior o fluxo que passa sobre o transdutor aquecido, maior o efeito refrigerante, e a potência requerida para manter o diferencial de temperatura constante.

Desse modo à potência na resistência de aquecimento é função da velocidade do fluido conforme será mostrado ao longo deste trabalho.

Um medidor do tipo Venturi foi conectado a um transmissor de pressão diferencial com saída analógica, que tem o seu sinal capturado pelo software de controle através de uma placa de aquisição da National Instruments. Ver figura 2




Figura 2

Foi utilizado no experimento um ventilador centrífugo cuja variação da vazão de ar é obtida pela variação da frequência e tensão de alimentação do motor. Para tal, foi empregado um inversor de frequência acionado através do software de controle da bancada. Uma resistência de aquecimento associada a um sensor de temperatura, em uma malha de controle, foi utilizada para controlar a temperatura do fluido. Desta forma poderemos variar a temperatura do fluido e verificar qual a influência desta no comportamento do medidor de vazão por convecção forçada.

Um software aplicativo foi desenvolvido especialmente para o controle da bancada de testes utilizando exclusivamente a linguagem de programação LabView. Neste aplicativo foram projetadas as malhas de controle abertas e fechadas, assim como, os indicadores e gráficos do sistema, gerenciando todos os instrumentos da bancada, ilustrados no diagrama de blocos da figura 3.

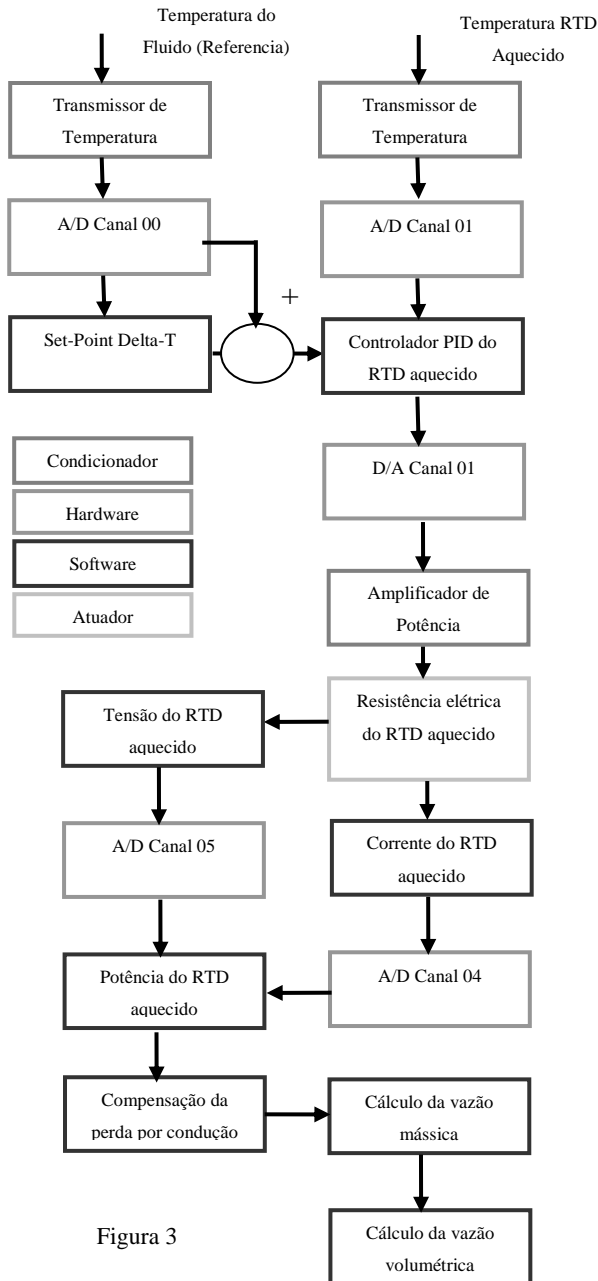


Figura 3

### 3.1 Equações utilizadas

Obtenção de Vazão Mássica a partir da pressão diferencial:

$$\dot{m}_{real} = C_d \times \frac{A_{obstrução}}{\sqrt{1 - \beta^4}} \times \sqrt{2 \times \rho \times \Delta p} \quad (1)$$

Obtenção de Vazão Volumétrica a partir da Vazão Mássica (utilizada para o princípio pressão diferencial e convecção forçada):

$$Q_{vol} = \frac{\dot{m}}{\rho} \quad (2)$$

Obtenção de Velocidade de Escoamento a partir da Vazão Volumétrica (utilizada para o princípio pressão diferencial e convecção forçada):

$$V = \frac{4Q_{vol}}{\pi \times D^2} \quad (3)$$

Obtenção da perda por condução térmica no RTD aquecido:

$$Q_c = S \times K \times \frac{(T_s - T_a)}{L} \quad (4)$$

Obtenção da potência transferida para o fluido:

$$\dot{Q}_{cf} = J_{medido} - (Q_c + Z) \quad (5)$$

Obtenção de Vazão Mássica a partir da potência transferida:

$$\dot{m} = \frac{\dot{Q}_{cf}}{kf(\Delta T) A_s \times C} \quad (6)$$

## 4. RESULTADOS

Os resultados obtidos nos ensaios de calibração indicam que dentro da faixa de velocidade de escoamento de 1m/s a 7m/s com a temperatura do ar em torno de 40 °C, os erros encontrados estão abaixo da faixa de exatidão do padrão utilizado na calibração, podendo este contribuir com a maior parte dos erros encontrados durante o ajuste, calibração e testes, ver tabela 1 e figura 4.

Convecção Forçada (Set Point do Ar 40 °C Set Point Diferencial 30 °C)						
Potência Transf. (W)	Vazão Mássica (Kg/s)	Vazão Volumétrica (m³/s)	Vel. Padrão (m/s)	Vel. Medido (m/s)	Erro	Incerteza
0,365	0,00170	0,00142	1,5	1,50	0,000	0,215
0,614	0,00281	0,00232	2,4	2,42	0,020	0,224
0,826	0,00381	0,00317	3,3	3,28	-0,020	0,233
0,997	0,00457	0,00378	4,0	3,94	-0,060	0,240
1,149	0,00528	0,00436	4,6	4,55	-0,050	0,246
1,287	0,00592	0,00491	5,1	5,07	-0,030	0,251
1,390	0,00637	0,00527	5,5	5,47	-0,030	0,255
1,464	0,00673	0,00557	5,9	5,77	-0,130	0,259
1,550	0,00712	0,00587	6,2	6,11	-0,090	0,262
1,626	0,00745	0,00615	6,4	6,38	-0,020	0,264
1,650	0,00760	0,00630	6,6	6,57	-0,030	0,266

Tabela 1 – Calibração da Velocidade de Escoamento (Convecção Forçada)




Figura 4 – Gráfico do Erro da Velocidade de Escoamento por Convecção Forçada

Notamos que no medidor venturi foi encontrado um erro considerável com a temperatura do ar de 30 a 50°C e no início da faixa de velocidade (1 a 2 m/s), provavelmente por causa da variação da densidade e viscosidade do gás com a temperatura, embora uma parte considerável deste erro seja devida a incerteza do teste, ver tabela 2 e figura 5.

Pressão Diferencial (Set Point do Ar 40 °C)						
Pressão Diferencial (Pa)	Vazão Mássica (Kg/s)	Vazão Volumétrica (m³/s)	Vel. Padrão (m/s)	Vel. Medido (m/s)	Erro	Incerteza
17,3	0,00178	0,00147	1,4	1,53	0,130	0,214
43,7	0,00278	0,00230	2,4	2,40	0,000	0,224
78,1	0,00372	0,00308	3,3	3,20	-0,100	0,233
112,2	0,00446	0,00369	4,0	3,84	-0,160	0,240
152,0	0,00520	0,00431	4,6	4,46	-0,140	0,246
188,9	0,00580	0,00480	5,1	4,99	-0,110	0,251
220,1	0,00626	0,00517	5,5	5,38	-0,120	0,255
250,1	0,00667	0,00552	5,9	5,74	-0,160	0,259
279,0	0,00705	0,00583	6,1	6,06	-0,040	0,261
306,3	0,00738	0,00611	6,4	6,34	-0,060	0,264
313,7	0,00746	0,00618	6,6	6,43	-0,170	0,266

Tabela 2 – Calibração da Velocidade de Escoamento (Pressão Diferencial)




Figura 5 – Gráfico do Erro da Velocidade de Escoamento por Pressão Diferencial

Pelo princípio de convecção forçada notamos que com a temperatura do ar a 30 e 50°C, foi encontrado um erro aceitável no início da faixa (1 a 2 m/s) a 30°C, ver figura 6 e erros maiores em toda a faixa a 50°C, ver figura 7. Provavelmente por causa da variação da densidade e viscosidade do gás com a temperatura, embora uma parte considerável deste erro seja devida a incerteza do teste.

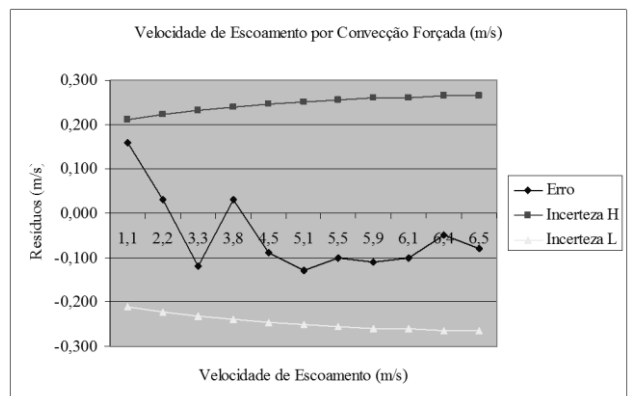


Figura 6 – Gráfico do Erro da Velocidade de Escoamento (Convecção Forçada) (30°C)




Figura 7 – Gráfico do Erro da Velocidade de Escoamento (Convecção Forçada) (50°C)

Todavia, quando avaliamos o instrumento com outros ajustes de temperatura diferencial vimos um erro considerável, tanto no início quanto no fim da faixa de trabalho da velocidade de escoamento em uma excursão de 20 a 40 °C de temperatura diferencial, com melhores resultados á 30°C devido a ser esta a temperatura em que o instrumento foi ajustado, ver figura 8, possivelmente um refino na modelagem pode minimizar este efeito.




Figura 8 – Gráfico do Erro da Velocidade de Escoamento (Vazão Máxima)

## 5. CONCLUSÃO

De um modo geral nós consideramos que os resultados encontrados foram satisfatórios.

Aplicações futuras:

- Uso como objeto de aprendizagem.
- Medição de vazão em sistemas HVAC (“Heating, Ventilation and Air Conditioning”), ou seja sistema de ar condicionado industrial.
- Medição de vazão em líquidos com sólidos em suspensão.
- Medição de vazão em estações de tratamento de efluentes (ETE).

Possibilidades para evolução deste trabalho:

- Uso de lógica Fuzzy para o controle da temperatura do RTD aquecido.
- Uso de uma rede neural para modelar a relação entre potência transferida e vazão mássica.
- Teste de outros posicionamentos para os sensores de vazão por convecção forçada.

- Projeto de formas construtivas específicas para o RTD aquecido objetivando a medição em líquidos, com ou sem sólidos em suspensão.

## REFERÊNCIAS

- DIAS, Aleci Paulo, FILHO, Álvaro Moreira da Costa OLIVEIRA, Marcos Antônio Andrade de. Desenvolvimento de um Anemômetro por Convecção Forçada, Rio de Janeiro: UERJ, 2007.
- DELMÉE, Gérard Jean. Manual de medição de vazão. 2ª Edição, São Paulo: Edgard Blücher, 1982.
- DJORUP, Robert. Directional Heat Loss Anemometer Transducer, United States Patent, 20 Lovewll Rd, Wellesley, mass: 02181 Appl. No: 110,841 Filled: Jan, 10, 1980
- Endress+Hauser. Thermal mass Flowmeter t-mass S Direct Mass Flow Measurement of Gases, Technical Information TI 0013A 1999
- J. E. Hardy, J. O. Hylton, T. E. McKnight. Empirical correlations for thermal flowmeters covering a wide range of thermal – physical properties. (Paper prepared for the National Conference of Standards Labs (NCSL)), Charlotte - NC, 1999
- KURZ Instruments Inc. Theory and application of Kurz thermal convection mass flow meters, 2411 Garden Road, Monterey, CA: ,1997



## Algoritmos para Auto-Ajuste de Sensores Utilizando Redes Neurais

Marcos A. A. de Oliveira <sup>1</sup>, Jorge L. M. do Amaral <sup>2</sup>, José F. M. do Amaral <sup>2</sup>

<sup>1</sup> UERJ / Laboratórios B.Braun S.A., Rio de Janeiro, Brasil, [marcos.oliveira@bbraun.com](mailto:marcos.oliveira@bbraun.com)

<sup>2</sup> UERJ, Rio de Janeiro, Brasil, [jamaral@uerj.br](mailto:jamaral@uerj.br)

<sup>3</sup> UERJ, Rio de Janeiro, Brasil, [franco@uerj.br](mailto:franco@uerj.br)

**Resumo:** Este trabalho propõe o desenvolvimento de um algoritmo para auto-ajuste de sensores inteligentes a partir do uso de Redes Neurais Artificiais. Através de dados gerados em uma calibração, o algoritmo aprende a corrigir os desvios encontrados. A título de exemplo foi utilizado um sensor do tipo Pt-100. O desafio é fazer uma rede neural aprender uma curva com poucos pontos, como os gerados em uma calibração tradicional [1].

**Palavras chave:** Rede Neural, Calibração, Ajuste, Auto-ajuste, sensores inteligentes.

### 1. INTRODUÇÃO

O avanço da micro-eletrônica permitiu o desenvolvimento de sensores inteligentes, isto é, sensores com microcontroladores ou microprocessadores embarcados dotados de *softwares* específicos que são capazes de executar uma grande variedade de funções. Uma das funções mais úteis que pode ser agregada a um sensor inteligente é a capacidade de se auto-ajustar, ou seja, de minimizar os erros sistemáticos de medição sem ajuda de nenhum dispositivo externo. O ajuste (de um instrumento de medição) é a operação destinada a fazer com que um instrumento de medição tenha desempenho compatível com o seu uso [2]. O ajuste pode ser: automático, semi-automático ou manual [2]. O termo auto-ajuste também é conhecido como auto-calibração, ou ainda em Inglês *Auto-Calibration* ou *Self-Calibration*. Todavia, o termo auto-calibração está em desacordo com o VIM (Vocabulário Internacional de Metrologia). Nos instrumentos que a sua curva de calibração não é linear, e/ou sua deriva é elevada em relação ao uso pretendido, ou ainda, quando o número de grandezas e faixas de indicação são muito elevados, o ajuste pode gerar um custo indesejável. Logo, a capacidade de auto-ajuste em um sensor é uma característica interessante, pois facilita a manutenção do seu estado metrológico. Isto é particularmente importante, por exemplo, em medidores de pH.

A pesquisa bibliográfica realizada mostrou várias possibilidades de uso de rede neurais em sensores inteligentes como: Predição da deriva (variação dos erros sistemáticos ao longo do tempo) de instrumentos entre calibrações utilizando redes neurais para previsão de séries temporais [11], técnicas de auto-ajuste (*self-calibration*)

[12] [16], detecção de falhas [13], monitoramento e verificação de calibração [14], linearizar as características de um transdutor ou para compensar os distúrbios causados por outras grandezas de influência [15].

Neste trabalho foi utilizado uma rede neural recorrente do tipo *Elman* e um polinômio padronizado por norma para desenvolver um algoritmo para auto-ajuste de sensores inteligentes.

### 2. TERMÔMETROS DE RESISTÊNCIA

Os termômetros de resistência (termoresistências) são considerados sensores de alta exatidão e boa repetibilidade de leitura, também são conhecidos como RTD que é abreviação inglesa de "*Resistance Temperature Detector*". Vários metais podem ser utilizados, como:

- Cobre (Cu), faixa: -200 a 260 °C;
- Molibdênio (Mo), faixa: -200 a 200 °C;
- Níquel (Ni), faixa: -80 a 260 °C;
- Níquel-ferro (Ni-Fe), faixa: -200 a 200 °C;
- Platina (Pt), faixa: -200 a 650 °C.

O elemento sensor mais utilizado é a platina, preferencialmente com o mais alto grau de pureza e encapsulados em bulbos de cerâmica ou vidro [3]. O primeiro a usar o termômetro de platina foi *William Siemens* em 1871. No entanto, a termometria de precisão com platina só foi iniciada com a publicação do trabalho de *Hugh Callendar* em 1887.

As termoresistências de platina também são conhecidas como PRT que é abreviação inglesa de "*Platinum Resistance Thermometers*", ou ainda TRP que seria a abreviação de Termômetro de Resistência de Platina.

Atualmente a termoresistência de Platina mais utilizada na indústria é do tipo Pt-100, cujo sufixo numérico corresponde a sua resistência elétrica quando submetida a uma temperatura de 0°C, mas existem outros tipos:

- Pt-0,25;
- Pt-2,5;
- Pt-25;
- Pt-200;
- Pt-1000.

Outro aspecto importante das termoresistências é o seu coeficiente de variação térmica, alfa ( $\alpha$ ), que é definido pela equação 1:

$$\alpha = \frac{R_{100} - R_0}{100 \cdot R_0} \quad (1)$$

Onde:

$R_{100}$  = resistência na temperatura de 100 °C;

$R_0$  = resistência na temperatura de 0°C.

Os valores de  $\alpha$  mais comuns são:

- 0,00385 °C<sup>-1</sup>;
- 0,00375 °C<sup>-1</sup>;
- 0,00392 °C<sup>-1</sup>.

Os valores especificados de temperatura estão definidos na ITS-90 (“*International Temperature Scale of 1990*”) [4], escala internacional de temperatura do ano de 1990, ou ainda a EIT-90. E segundo a ASTM (“*American Society Testing and Materials*”) E 1137 – 97, para as variações de temperatura a serem medidas são válidas as equações (2) e (3), conhecidas como *Callendar-Van Dunsen*, que seria à união da equação original de *Callendar* para a faixa positiva de temperatura (2), mais a contribuição posterior de *Van Dunsen* para a faixa negativa (3):

De 0 a 650 °C;

$$R_t = R_0 [1 + A \cdot t + B \cdot t^2] \Omega \quad (2)$$

De -200 a 0 °C;

$$R_t = R_0 [1 + A \cdot t + B \cdot t^2 + C \cdot (t-100) \cdot t^3] \Omega \quad (3)$$

Onde:

$t$  = temperatura (ITS-90) °C;

$R_t$  = resistência na temperatura ( $t$ );

$R_0$  = resistência à 0°C;

Valores típicos para  $\alpha = 0,00385$  °C<sup>-1</sup> [5]

$A = 3,9083 \times 10^{-3}$  °C<sup>-1</sup>;

$B = -5,775 \times 10^{-7}$  °C<sup>-2</sup>;

$C = -4,183 \times 10^{-12}$  °C<sup>-4</sup>;

A equação *Callendar-Van Dunsen* e os seus coeficientes padronizados para cada tipo de Pt-100 é utilizada para gerar as tabelas padrão dos sensores. Os instrumentos que são utilizados para obter as leituras das termoresistências geralmente indicam em ohm, porém a grandeza de interesse é a temperatura e normalmente a unidade é grau Celsius. Desta maneira, necessitamos de equações onde o termo

independente seja resistência elétrica e o termo dependente seja temperatura, ou seja, a partir de uma dada resistência, seja possível determinar a temperatura do sensor.

A equação de *Van Dunsen* (utilizada na faixa negativa) não permite facilmente a sua dedução inversa, por esse motivo à norma ASTM E 1137, sugere as seguintes equações inversas, para a parte negativa (4) e para a parte positiva (5):

De -200 a 0 °C;

$$t = \sum_{i=0}^4 D_i \left( \frac{R_t}{R_0} - 1 \right)^i \quad (4)$$

De 0 a 650 °C;

$$t = \frac{\sqrt{A^2 - 4B \left(1 - \frac{R_t}{R_0}\right)} - A}{2B} \quad (5)$$

Onde:

$t$  = temperatura (ITS-90) °C;

$R_t$  = resistência na temperatura ( $t$ );

$R_0$  = resistência à 0°C;

Valores típicos para  $\alpha = 0,00385$  °C<sup>-1</sup> [5]

$A = 3,9083 \times 10^{-3}$  °C<sup>-1</sup>;

$B = -5,775 \times 10^{-7}$  °C<sup>-2</sup>;

$D_1 = 255,819$  °C;

$D_2 = 9,14550$  °C;

$D_3 = -2,92363$  °C;

$D_4 = 1,79090$  °C;

A equação (5) é uma aproximação da *Van Dunsen*, por isso um erro de até 0,002 °C é esperado [5].

### 3. REDES NEURAIS ARTIFICIAIS

As principais características das Redes Neurais Artificiais (RNAs) são sua habilidade de aprender certo conteúdo e a capacidade de generalizar, adaptando-se a situações que jamais fizeram parte do conjunto de treinamento.

Enquanto sistemas de softwares convencionais são programados através de um grande número de instruções e regras, a rede neural absorve o conhecimento através da apresentação de exemplos básicos em seu treinamento [6].

Uma rede neural consiste em uma ou várias unidades processadoras básicas interligadas dispostas em uma ou mais camadas. Cada camada pode conter diversos elementos processadores. A conexão entre as unidades processadoras é feita através do peso sináptico, que define a influência entre as unidades processadoras interligadas [6]. Os pesos sinápticos, conhecidos como parâmetros internos, têm seu valor atualizado durante o processo de treinamento. Cada unidade processadora executa uma operação simples

sobre a informação recebida da entrada ou de outro processador [9].

O resultado é então transmitido para outros processadores que, por sua vez, repetem a operação. O processo de atualização dinâmica dos pesos é feito de forma paralela e distribuída por toda a rede.

Quando as saídas diferem dos alvos por um valor inferior à tolerância de erro pré-estabelecida, está concluído o processo de aprendizagem. Neste ponto, pode-se dizer que a rede está devidamente treinada e a matriz de pesos, que será usada na fase de execução, retém o conhecimento que a rede foi capaz de absorver durante a fase de aprendizado [8].

A Figura 1 mostra a arquitetura de uma rede neural genérica com uma camada, onde  $P_1, P_2, P_3, \dots, P_R$  representam os elementos do vetor de treinamento  $P$  da rede [7]. O bloco somatório realiza a soma ponderada das entradas  $P_1, P_2, P_3, \dots, P_R$  com os pesos  $W_{ij}$ , normalmente conhecida, sob a forma matricial, como  $NET = W \cdot P$

A saída  $a = F(NET)$  é o resultado da aplicação da soma ponderada  $NET$  na função de ativação  $F$ , que pode ser linear ou não [6].




Figura 1 - Arquitetura Genérica de uma Rede Neural Artificial.

A regra de *Widrow-Hoff* [9] é a base fundamental dos diversos métodos de treinamento das RNAs. Ela avalia o erro médio quadrático a cada iteração através da derivada parcial do erro quadrático em relação ao peso  $W$  e ao limiar (bias)  $b$ .

Terminado o treinamento, a rede está pronta para ser executada. Nesta fase são fornecidos à RNA novos padrões, denominados padrões de teste, e a rede responde, rapidamente, de acordo com o que lhe foi imposto durante o treinamento.

As MLP (*Multi Layer Perceptron*) são redes em que os neurônios são dispostos em múltiplas camadas, conforme pode ser visto na figura 2.




Figura 2 – Rede MLP

O algoritmo de treinamento das MLPs é chamado de *backpropagation*. Conforme pode ser visto na figura 3, ele é composto de duas etapas: na primeira, chamada de passo direto, a rede é ativada por um exemplo e o erro de cada neurônio da camada de saída é calculado. Na segunda etapa, chamada de passo reverso (*backward*), o erro da rede é usado para atualizar os pesos. Os neurônios da camada escondida não estão relacionados ao erro de forma direta, mas através de neurônios da próxima camada. A partir da camada de saída, o erro é retropropagado (*backpropagation*) através da rede de camada a camada.




Figura 3 - *backpropagation*

O *backpropagation* é um dos algoritmos de treinamento de Redes Neurais mais utilizado em aplicações de previsão, de classificação e de reconhecimento de padrões em geral. Toda função limitada contínua por partes pode ser aproximada com um erro arbitrariamente pequeno por uma rede de camada escondida.

Uma importante característica das Redes Neurais é a sua capacidade de generalizar o seu conhecimento a partir de exemplos de treinamento. Isto permite que a rede seja capaz de lidar com ruídos e distorções, e também responder corretamente a novos padrões, isto é, padrões que não foram apresentados no treinamento.

Para que a rede tenha uma boa capacidade de generalização, utiliza-se o treinamento com validação cruzada (*cross validation*), evitando o super treinamento (*overfitting*), que diminui a capacidade de generalização.

Para se utilizar essa técnica, os padrões devem ser divididos em dois conjuntos:

Treinamento: padrões utilizados para modificar os pesos;

Teste: padrões utilizados para testar o desempenho do modelo final.

A seguir, a rede é treinada com os padrões de treinamento, observando o erro obtido pela rede quando os padrões de teste são apresentados.

### 3.1 Redes Recorrentes

As redes recorrentes possuem laços de realimentação, ou seja, a saída de um neurônio pode ser uma entrada para outro de uma camada precedente ou, no caso de auto-realimentação, para o próprio neurônio. As redes recorrentes, chamadas de redes com memória, não possuem organização rígida e seus neurônios possuem liberdade para se ligar a qualquer outro neurônio [9]. A rede de *Elman* é uma estrutura de rede neural com características recorrentes [17], isto é, pode apresentar uma ou mais malhas de realimentação, fazendo com que suas conexões permitam à rede memorizar as informações atuais na camada de



contexto no momento seguinte à seqüência investigada, ver figura 4.




Figura 4 – Rede Elman

A Rede Elman é empregado tipicamente nas situações onde seqüência dos dados de entrada da rede é importante, isto é, quando se deseja que a rede, de algum modo, utilize as entradas precedentes, levando-as em consideração juntamente com a entrada atual para gerar uma resposta. Isto permite que a rede execute a aprendizagem das tarefas que estendem sobre o tempo. De fato, é devido à natureza da realimentação em torno das unidades escondidas, estes neurônios escondidos continuam reciclando a informação através da rede sobre as etapas de tempo múltiplas, e descobrem deste modo a representação interna abstrata do tempo, ou ainda no nosso caso a seqüência dos pontos de calibração. Esta característica é muito interessante para que a curva de correção da calibração seja uniforme, assumindo valores fisicamente coerentes entre os pontos de calibração.

3.2 Leave-One-Out

Foi utilizado o algoritmo de treinamento *Leave-One-Out* que é um caso especial de validação cruzada. Que é computacionalmente dispendioso e frequentemente é usado em amostras pequenas. Para uma amostra de tamanho  $n$  ( $n > 2$ ), uma hipótese é induzida utilizando  $(n-1)$  exemplos; a hipótese é então testada no único exemplo remanescente. Esse processo é repetido  $n$  vezes, cada vez induzindo uma hipótese deixando de considerar um único exemplo[10].

4. ALGORITMOS PARA AUTO-AJUSTE

Para esse trabalho foi escolhida uma topologia utilizando os polinômios para termoresistências e um rede neural *Elman*. Nesta topologia, durante a fase de treinamento, os erros que os pontos de calibração possuem em relação ao polinômio padronizado, são apresentados para o treinamento da rede neural. Durante a fase de utilização o valor de entrada é apresentado ao polinômio e á rede neural simultaneamente e á saída do sistema é o somatório da saída de ambas, conforme figura 5.




Figura 5 – Topologia do Algoritmo

A partir do *Leave-One-Out* a nossa rede foi treinada cinco (número de pontos disponíveis) vezes, deixando a

cada treino um ponto diferente fora do treinamento, para testar o erro da rede. A rede que apresentou um menor erro em relação ao ponto de teste é automaticamente selecionada pelo algoritmo, ver figura 7.

Com o objetivo de aumentar a repetibilidade do sistema este procedimento foi repetido  $n$  vezes (tentativas) e o melhor resultado, em relação ao maior erro, em módulo, foi guardado, ver figura 6.

A fim de minimizar os erros, o próximo passo foi refinar a rede escolhida, treinando a mesma por  $x$  épocas, salvando este treinamento caso apresente erros menores que o anterior. Repetindo este procedimento por  $y$  vezes (refino) e ficando com o melhor resultado, como pode ser visto na figura 8.

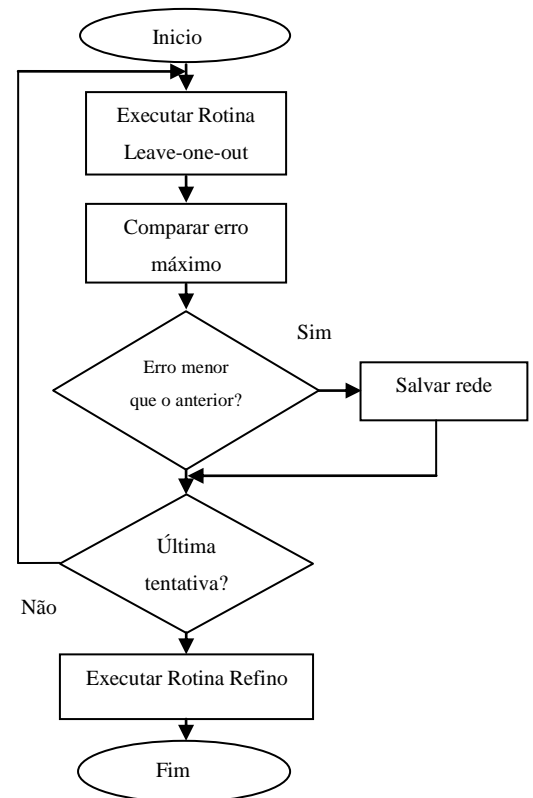


Figura 6 – Fluxograma Geral

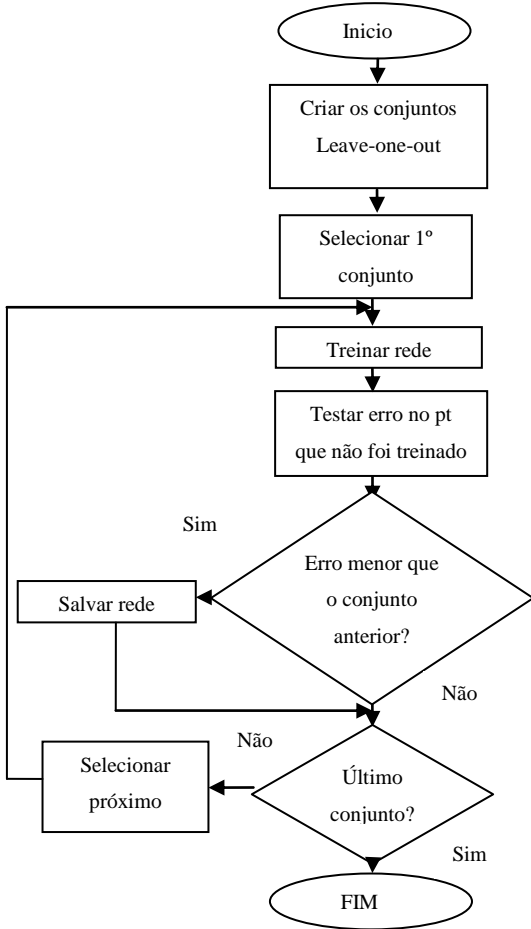


Figura 7 – Fluxograma Leave-one-out

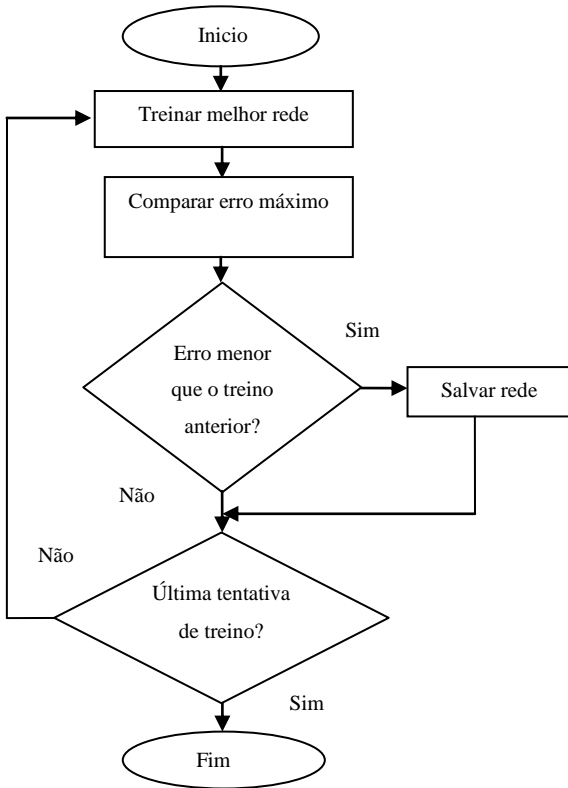


Figura 8 – Fluxograma de Refino

Neste trabalho, os pontos da curva resistência x temperatura, foram retirados de uma calibração feita em um laboratório da RBC (Rede Brasileira de Calibração) em um Pt-100 padrão (Isothech T100) com uma incerteza máxima na faixa calibrada de 0,11°C, calibração em 05 pontos na faixa de -20 a 300 °C.

Para o projeto da rede *Elman* e o treinamento, foram utilizados os dados da tabela 1:

Tabela 1. Parâmetros da Rede

Parâmetro	Valor
Taxa de aprendizado	0,1
Número máximo de épocas de aprendizado (Leave-one-out)	1000
Número máximo de épocas de aprendizado (Refino)	20 x 500 (20 épocas com 500 testes intermediários)
Objetivo de erro (máximo absoluto)	0
Números de neurônios na camada de saída	1
Função de ativação da camada escondida	Tansig (Sigmóide Tangente Hiperbólica)
Função de ativação da camada de saída	Purelin (linear)
Método de treinamento	Traingdx (Gradiente de descida com momento e adaptativo)
Números neurônios na camada escondida	11

Outro grande desafio para esse algoritmo foi torná-lo repetitivo, desta forma, melhorar o seu grau de concordância entre os resultados de edições sucessivas de um mesmo mensurando efetuadas sob as mesmas condições de medição [2]. Os ajustes de tentativas (repetições do *leave-one-out*), refino (repetições da rotina de refino) e épocas (quantidade de épocas de treinamento em cada refino), que foram mais decisivos na evolução da repetibilidade e redução do erro máximo, podem ser vistos na figura 9. Sendo então escolhidos os valores de 20 tentativas de leave-one-out com 500 repetições de refino e 20 épocas de aprendizagem para cada refino. Com este ajuste conseguimos com 5 repetições, uma média de erros máximos de 0,0024 °C com um desvio padrão de 0,0007 °C.

5. EXPERIMENTOS




Figura 9 – Repetitividade

Após execução do programa no *Matlab*®, obtivemos os resultados apresentados nas figuras 10 e 11. Na figura 10 podemos ver o erro em relação polinômio, esse erro corrigido pela rede neural (0,0026°C), e a correção final com o refinamento da rede (0,0022 °C). Na figura 11 podemos ver a curva de correção da rede e da rede refinada em toda a faixa ajustada, com intervalo de simulação de 1 ohm, a fim de comprovar a ausência de *over-fitting*.




Figura 10 – Erros do Sistema

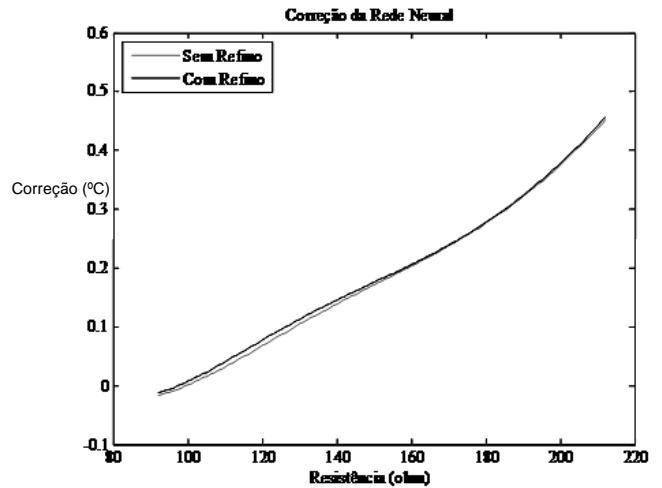


Figura 11 – Correção da Rede Neural

Observando os resultados obtidos nas simulações no *Matlab*®, vimos que essa rede teve um excelente comportamento, convergindo para um resultado muito próximo da curva apresentada no aprendizado. Na figura 12 e na tabela 2, podemos ver um teste de reprodutibilidade a partir do histórico das calibrações do nosso sensor, ao mesmo tempo comparando-se com os ajustes obtidos com *software* comercial para *fit-curve* muito utilizado em metrologia o *TableCurve*®. De acordo com a tabela podemos notar que a nossa rede neural se comporta melhor que o método tradicional principalmente quando temos poucos pontos de calibração.

Reprodutibilidade dos resultados de medição é o grau de concordância entre os resultados das medições de um mesmo mensurando efetuadas sob condições variadas de medição[2].




Figura 12 – Reprodutibilidade

Tabela 2. Reprodutibilidade

Levantamento de Reprodutibilidade			
Ano da Calibração	Erro Table Curve (°C)	Erro Rede Neural (°C)	Pontos da Calibração
2008	0,0164	0,0022	5
2006	0,0191	0,0119	7
2005	0,0203	0,0150	7
2004	0,0264	0,0042	7
2003	0,0215	0,0027	7
2002	0,0307	0,0063	7
2000	0,0118	0,0031	5
1999	0,0099	0,0006	7

## 6. CONCLUSÃO

A vantagem que este método pode apresentar em relação ao método estatístico tradicional, é a facilidade de implementação deste algoritmo em sistemas embarcados como: transmissores e termômetros, criando instrumentos auto-ajustáveis. Somando-se a isto, também a capacidade de absorver desvios de modelagem dos polinômios utilizados, devido à capacidade de generalização das redes neurais artificiais.

O próximo passo para aperfeiçoamento deste sistema seria: Implementar essa técnica em um microcontrolador e ou com um *software* com recursos específicos para instrumentação e controle como o *LabView*® e comparar os resultados com aqueles obtidos no *Matlab*®, ou ainda desafiar o sistema com um número menor de pontos (3 ou 4).

## REFERÊNCIAS

- [1] OLIVEIRA, M. A. A. ; AMARAL, J. L. M. ; AMARAL, J. F. M. ; SOARES, D.R.M ; BIONDI NETO, L . Utilização de uma Rede Neural Artificial para a Interpolação de Valores de Medição de Termoresistências (RTD). Anais do Primeiro Congresso Internacional de Metrologia Mecânica, Rio de Janeiro, 2008.
- [2] INMETRO, Vocabulário Internacional de Termos Fundamentais e Gerais de Metrologia, 4a edição, Rio de Janeiro, 2005.
- [3] NICHOLAS, J. V. and WHITE, D.R., Traceable Temperatures, JOHN WILEY & SONS, 1997
- [4] PRESTON-THOMAS, H., The International Temperature Scale of 1990 (ITS-90), Metrologia, Vol 27, No. 1, 1990, pp 3-10
- [5] ASTM E 1137-97, Standard Specification for Industrial Platinum Resistance Thermometers, 1997
- [6] BIONDI, L. N.;PACHECO, M. A. C.; VELLASCO, M. M. B. R.; PASSOS, E. P. L. e CHIGANER, L.. Sistema Híbrido de Apoio à Decisão para Detecção e Diagnóstico de Falhas em Redes Elétricas. Anais do III Simpósio Brasileiro de Redes Neurais, Recife, p. 197-204, 1996.
- [7] COELHO, P. H. G.. A Complex EKF - RTRL Neural Networks. Proceedings of the IJCNN'2001, New Jersey, IEEE Press, v.1, p. 120-125, 2001.
- [8] DAYHOFF, Judith E.. Neural Network Architectures: An Introduction. New York: Van Nostrand Reinhold, 1990.
- [9] HAYKIN, Simon. Neural Networks a Comprehensive Foundation, Englewood Cliffs: Macmillan College Publishing Company, 1994.
- [10] MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre Aprendizagem de Máquina. Capítulo 4. In: REZENDE, S. O. Sistemas Inteligentes: Fundamentos e Aplicações. Barueri: Manole, 2002.
- [11] GOLOVKO, V.; SAVITSKY, J.; SACHENKO, A.; KOCHAN, V.; TURCHENKO, V.; LAOPOULOS, T.; GRANDINETTI, L.. Intelligent System for Prediction of Sensor Drift. International Conference on Neural Networks and Artificial Intelligence ICNNAI'99, 1999.
- [12] PATRA, J. C.; GOPALKRISHNAN, V.; ANG, E. L.; DAS, A.. Neural Network-Based Self-Calibration/ Compensation of Sensors Operating in Harsh Environments. Sensors, 2004. Proceedings of IEEE Volume , Issue , 24-27 Oct. 2004 Page(s): 425 - 428 vol.1.
- [13] NAJAFI, M.; CULP, C.; LANGARI, R.. Performance Study of Enhanced Auto-Associative Neural Networks For Sensor Fault Detection. Energy Systems Laboratory, 2004
- [14] PINTO, J. O. P.; PINTO, A. M. A. C; TATIBANA, G. S.; SANCHES, R. O.; CARRASCO, B. N.; FLORA, N.; HINES , J. W.. Uma Nova Estratégia de Modelagem para Monitoramento de Instrumentos e Verificação de Calibração Usando Redes Neurais Artificiais. Anais do 3º Congresso Brasileiro de P&D em Petróleo e Gás., 2005
- [15] PEREIRA, J.M. D.; POSTOLACHE, O.; GIRÃO, P. S.. Using a Dual-Channel FDC Device and ANN Techniques to Improve Measurements Accuracy. Sensors & Transducers Magazine (S&T e-Digest), Vol.62, Issue 12, December 2005, pp.462-472
- [16] RIVERA, J.; CARRILLO, M.; CHACÓN, M.; HERRERA, G.; BOJORQUEZ, G.. Self-Calibration and Optimal Response in Intelligent Sensors Design Based on Artificial Neural Networks. sensors ISSN 1424-8220, 7, 1509-1529, 2007
- [17] ELMAN, J. L.. Finding Structure in Time. Cognitive Science, 14, 179-211. 1990.

## V CONGRESSO BRASILEIRO DE METROLOGIA

Metrologia para a competitividade em áreas estratégicas  
9 a 13 de novembro de 2009. Salvador, Bahia – Brasil.

### AUTO-AJUSTE DE SENSORES COM POUCOS PONTOS UTILIZANDO REDES NEURAIAS

*Marcos A. A. de Oliveira*<sup>1</sup>, *Jorge L. M. do Amaral*<sup>2</sup>, *José F. M. do Amaral*<sup>3</sup>

<sup>1</sup> UERJ / Laboratórios B.Braun S.A., Rio de Janeiro, Brasil, [marcos.oliveira@bbraun.com](mailto:marcos.oliveira@bbraun.com)

<sup>2</sup> UERJ, Rio de Janeiro, Brasil, [jamaral@uerj.br](mailto:jamaral@uerj.br)

<sup>3</sup> UERJ, Rio de Janeiro, Brasil, [franco@uerj.br](mailto:franco@uerj.br)

**Sumário:** Este trabalho propõe a criação de um algoritmo de auto-ajuste para sensores inteligentes a partir do uso de Redes Neurais Artificiais com poucos pontos (3 e 4). Através de dados gerados em uma calibração, ou simplesmente, submetendo o sensor a uma grandeza materializada e informado o valor verdadeiro convencional (V.V.C.) da medição, o algoritmo aprende a corrigir os desvios encontrados. A título de exemplo foi utilizado um sensor do tipo Pt-100. O desafio é fazer uma rede neural aprender uma curva com poucos pontos, como os gerados em uma calibração tradicional, a partir do trabalho “*Algoritmo para Auto-Ajuste de Sensores Utilizando Redes Neurais*” [1].

**Palavras-chave:** Rede Neural, Calibração, Ajuste, Auto-ajuste, sensores inteligentes.

#### 1. INFORMAÇÕES BÁSICAS

O avanço da micro-eletrônica permitiu o desenvolvimento de sensores inteligentes, isto é, sensores com microcontroladores ou microprocessadores embarcados dotados de *softwares* específicos. Uma funcionalidade muito útil, que pode ser agregada a um sensor inteligente é a capacidade de se auto-ajustar, ou seja, de minimizar os erros sistemáticos de medição sem ajuda de nenhum dispositivo externo. O ajuste (de um instrumento de medição) é a operação destinada a fazer com que um instrumento de medição tenha desempenho compatível com o seu uso [2]. O ajuste pode ser: automático, semi-automático ou manual [2]. O termo auto-ajuste também é conhecido como auto-calibração, ou ainda em Inglês *Auto-Calibration* ou *Self-Calibration*. Todavia o termo auto-calibração está em desacordo com o VIM (Vocabulário Internacional de Metrologia). Nos instrumentos que a sua curva de calibração não é linear, e/ou sua deriva é elevada em relação ao uso pretendido, ou ainda quando o número grandezas e faixas de indicação são muito elevados, o ajuste pode gerar um custo indesejável. A capacidade de auto-ajuste em um sensor é uma característica interessante a fim de facilitar a manutenção do seu estado metrológico, podendo ser até fundamental em alguns casos como medidores de pH, por exemplo.

A pesquisa bibliográfica realizada mostrou várias possibilidades de uso de rede neurais em sensores inteligentes como: Predição da deriva (variação dos erros sistemáticos ao longo do tempo) de instrumentos entre

calibrações utilizando redes neurais para previsão de séries temporais [11], técnicas de auto-ajuste (*self-calibration*) [12] [16], detecção de falhas [13], monitoramento e verificação de calibração [14], linearizar as características de um transdutor ou para compensar os distúrbios causados por outras grandezas de influência [15].

#### 2. TERMÔMETROS DE RESISTÊNCIA

Os termômetros de resistência (termoresistências) são considerados sensores de alta exatidão e boa repetibilidade de leitura, também são conhecidos como RTD que é abreviação inglesa de “*Resistance Temperature Detector*”.

O elemento sensor mais utilizado é a platina, preferencialmente com o mais alto grau de pureza e encapsulados em bulbos de cerâmica ou vidro [3]. O primeiro a usar o termômetro de platina foi *William Siemens* em 1871. No entanto, a termometria de precisão com platina só foi iniciada com a publicação do trabalho de *Hugh Callendar* em 1887.

Atualmente a termoresistência de Platina mais utilizada na indústria é do tipo Pt-100, cujo sufixo numérico corresponde a sua resistência elétrica quando submetida a uma temperatura de 0°C.

#### 3. REDES NEURAIAS ARTIFICIAIS

As principais características das Redes Neurais Artificiais (RNAs) são sua habilidade de aprender certo conteúdo e a capacidade de generalizar, adaptando-se a situações que jamais fizeram parte do conjunto de treinamento.

Enquanto sistemas de softwares convencionais são programados através de um grande número de instruções e regras, a rede neural absorve o conhecimento através da apresentação de exemplos básicos em seu treinamento [6].

Uma rede neural consiste em uma ou várias unidades processadoras básicas interligadas dispostas em uma ou mais camadas. Cada camada pode conter diversos elementos processadores. A conexão entre as unidades processadoras é feita através do peso sináptico, que define a influência entre as unidades processadoras interligadas [6]. Os pesos sinápticos, conhecidos como parâmetros internos, têm seu valor atualizado durante o processo de treinamento. Cada unidade processadora executa uma operação simples sobre a informação recebida da entrada ou de outro processador [9].

O resultado é então transmitido para outros processadores que, por sua vez, repetem a operação. O processo de atualização dinâmica dos pesos é feito de forma paralela e distribuídamente por toda a rede.

Quando as saídas diferem dos alvos por um valor inferior à tolerância de erro pré-estabelecida, está concluído o processo de aprendizagem. Neste ponto pode-se dizer que a rede está devidamente treinada e a matriz de pesos, que será usada na fase de execução, retém o conhecimento que a rede foi capaz de absorver durante a fase de aprendizado [8].

A Figura 1 mostra a arquitetura de uma rede neural genérica com uma camada, onde  $p_1, p_2, p_2, p_3, \dots, p_R$  representam os elementos do vetor de treinamento P da rede [7]. O bloco somatório realiza a soma ponderada das entradas  $p_1, p_2, p_3, \dots, p_R$  com os pesos  $W_{ij}$ , normalmente conhecida, sob a forma matricial, como  $NET = W \cdot P$

A saída  $a = F(NET)$  é o resultado da aplicação da soma ponderada NET na função de ativação F, que pode ser linear ou não [6].




Figura 1 - Arquitetura Genérica de uma Rede Neural Artificial.

As MLP (*Multi Layer Perceptron*) são redes em que os neurônios são dispostos em múltiplas camadas e consegue representar funções não linearmente separáveis, ver figura 2.




Figura 2 – Rede MLP

O *backpropagation* é um dos algoritmos de Rede Neural mais utilizados em aplicações práticas de previsão, de classificação e de reconhecimento de padrões em geral. Toda função limitada contínua por partes pode ser aproximada com um erro arbitrariamente pequeno por uma rede de camada escondida.

Uma importante característica das Redes Neurais é a sua capacidade de generalizar o seu conhecimento a partir de exemplos de treinamento. Isto permite que a rede seja capaz de lidar com ruídos e distorções, e também responder

corretamente a novos padrões, isto é, padrões que não foram apresentados no treinamento.

Para que a rede tenha uma boa capacidade de generalização, utiliza-se o treinamento com validação cruzada (*cross validation*), evitando o super treinamento (*overfitting*), que diminui a capacidade de generalização.

Para se utilizar essa técnica, devem-se dividir os padrões em dois conjuntos:

Treinamento: padrões utilizados para modificar os pesos;

Teste: padrões utilizados para testar o desempenho do modelo final.

A seguir, a rede é treinada com os padrões de treinamento, observando o erro obtido pela rede quando os padrões de teste são apresentados.

### 3.1 Redes Recorrentes

As redes recorrentes possuem laços de realimentação, ou seja, a saída de um neurônio pode ser entrada para outro de uma camada precedente ou, no caso de auto-realimentação, para o próprio neurônio [9]. A rede de *Elman* é uma estrutura de rede neural com características recorrentes [17], isto é, pode apresentar uma ou mais malhas de realimentação, fazendo com que suas conexões permitam à rede memorizar as informações atuais na camada de contexto no momento seguinte à seqüência investigada, ver figura 4.

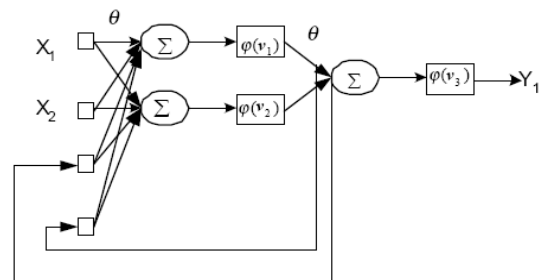


Figura 4 – Rede Elman

Foi utilizado o algoritmo de treinamento *Leave-One-Out* que é um caso especial de validação cruzada. O que é computacionalmente dispendioso e freqüentemente é usado em amostras pequenas. Para uma amostra de tamanho  $n$  ( $n > 2$ ), uma hipótese é induzida utilizando  $(n-1)$  exemplos; a hipótese é então testada no único exemplo remanescente. Esse processo é repetido  $n$  vezes, cada vez induzindo uma hipótese deixando de considerar um único exemplo [10].

## 4. ALGORITMOS PARA AUTO-AJUSTE

Para esse trabalho foi escolhida uma topologia utilizando os polinômios para termoresistências e um rede neural *Elman*. Nesta topologia, durante a fase de treinamento, os erros que os pontos de calibração possuem em relação ao polinômio padronizado, são apresentados para o treinamento da rede neural. Durante a fase de utilização o valor de entrada é apresentado ao polinômio e à rede neural simultaneamente e à saída do sistema é o somatório da saída de ambas, conforme figura 5

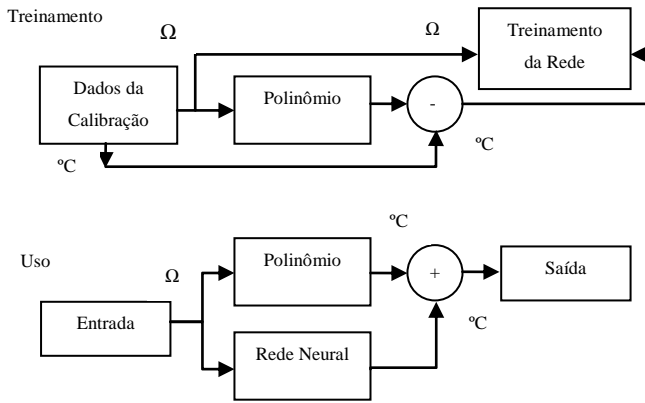


Figura 5 – Topologia do Algoritmo

A partir do *Leave-One-Out* a nossa rede foi treinada cinco (número de pontos disponíveis) vezes, deixando a cada treino um ponto diferente fora do treinamento, para testar o erro da rede. A rede que apresentou um menor erro em relação ao ponto de teste é automaticamente selecionada pelo algoritmo, ver figura 7.

Com o objetivo de aumentar a repetibilidade do sistema este procedimento foi repetido  $n$  vezes (tentativas) e o melhor resultado, em relação ao maior erro, em módulo, foi guardado, ver figura 6.

A fim de minimizar os erros, o próximo passo foi refinar a rede escolhida, treinando a mesma por  $x$  épocas, salvando este treinamento caso apresente erros menores que o anterior. Repetindo este procedimento por  $y$  vezes (refino) e ficando com o melhor resultado, como pode ser visto na figura 8.

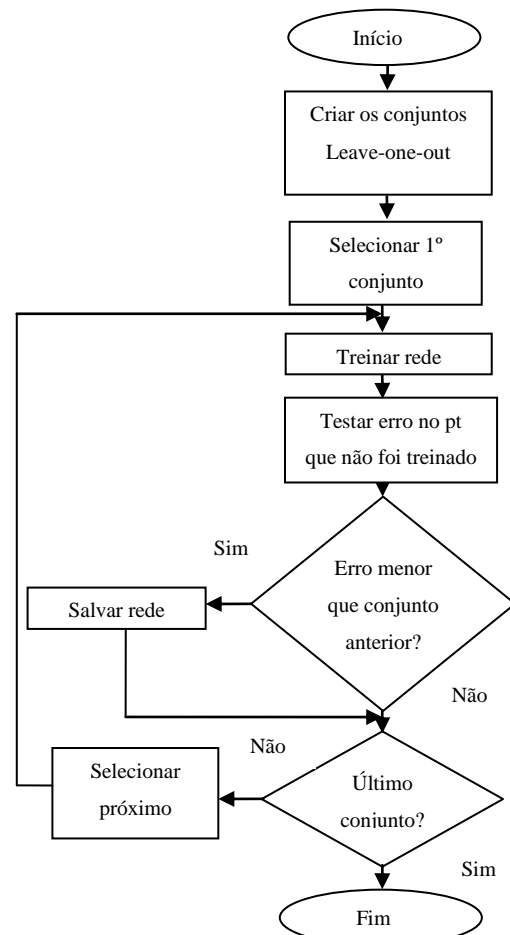


Figura 7 – Fluxograma Leave-one-out

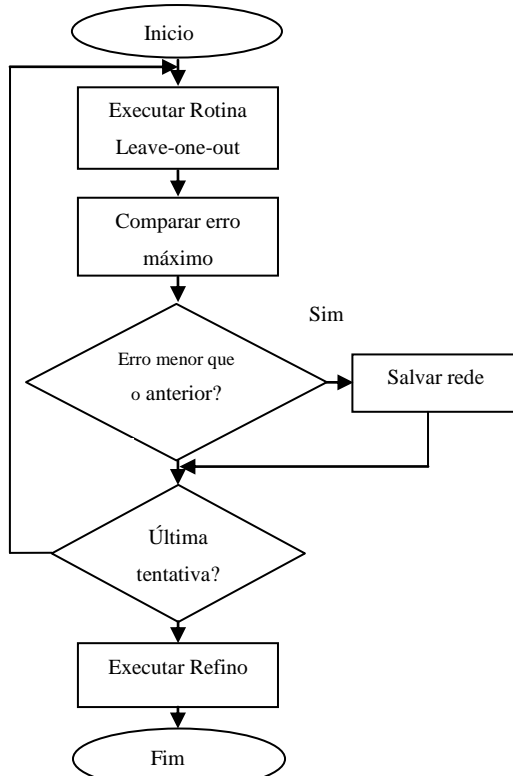


Figura 6 – Fluxograma Geral

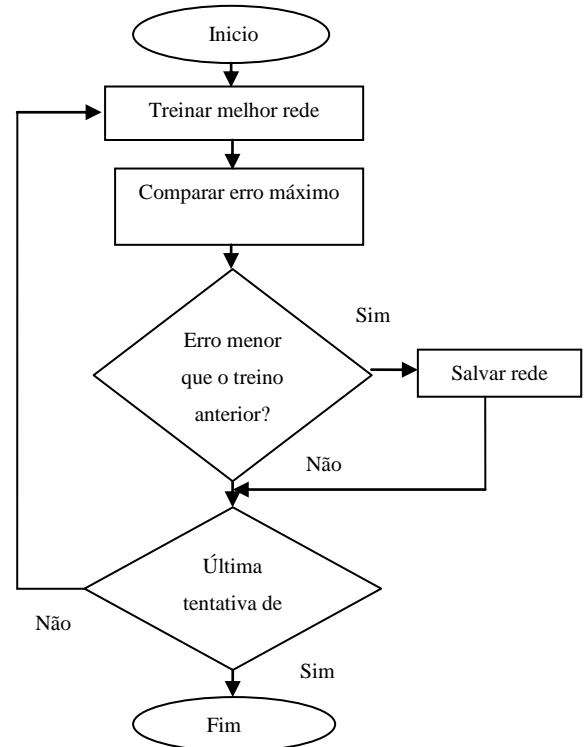


Figura 8 – Fluxograma de Refino

#### 4. EXPERIMENTOS

Neste trabalho, os pontos da curva resistência x temperatura, foram retirados de uma calibração feita em um laboratório da RBC (Rede Brasileira de Calibração) em um Pt-100 padrão (IsoTech T100) com uma incerteza máxima na faixa calibrada de 0,11°C, calibração em 05 pontos na faixa de -20 a 300 °C.

Para o projeto da rede *Elman* e o treinamento, foram utilizados os dados da tabela 1:

Tabela 1. Parâmetros da Rede

Parâmetro	Valor
Taxa de aprendizado	0,1
Número máximo de épocas de aprendizado (Leave-one-out)	1000
Número máximo de épocas de aprendizado (Refino)	20 x 500 (20 épocas com 500 testes intermediários)
Objetivo de erro (máximo absoluto)	0
Números de neurônios na camada de saída	1
Função de ativação da camada escondida	Tansig (Sigmóide Tangente Hiperbólica)
Função de ativação da camada de saída	Purelin (linear)
Método de treinamento	Traingdx (Gradiente de descida com momento e adaptativo)
Números neurônios na camada escondida	11

Outro grande desafio para esse algoritmo foi torná-lo repetitivo, desta forma, melhorar o seu grau de concordância entre os resultados de edições sucessivas de um mesmo mensurando efetuadas sob as mesmas condições de medição [2]. Os ajustes de tentativas (repetições do *leave-one-out*), refino (repetições da rotina de refino) e épocas (quantidade de épocas de treinamento em cada refino), que foram mais decisivos na evolução da repetitividade e redução do erro máximo, podem ser vistos na figura 9. Sendo então escolhido os valores de 20 tentativas de *leave-one-out* com 500 repetições de refino e 20 épocas de aprendizagem para cada refino. Com este ajuste conseguimos com 5 repetições, uma média de erros máximos de 0,0024 °C com um desvio padrão de 0,0007 °C.




Figura 9 – Repetitividade

Após execução dos algoritmos propostos implementados no *Matlab*®, obtivemos os resultados apresentados nas figuras 10 e 11. Na figura 10 podemos ver o erro em relação polinômio, esse erro corrigido pela rede neural (0,0026°C), e a correção final com o refinamento da rede (0,0022 °C). Na figura 11 podemos ver a curva de correção da rede e da rede refinada em toda a faixa ajustada, com intervalo de simulação de 1 ohm, a fim de comprovar a ausência de *over-fitting*.

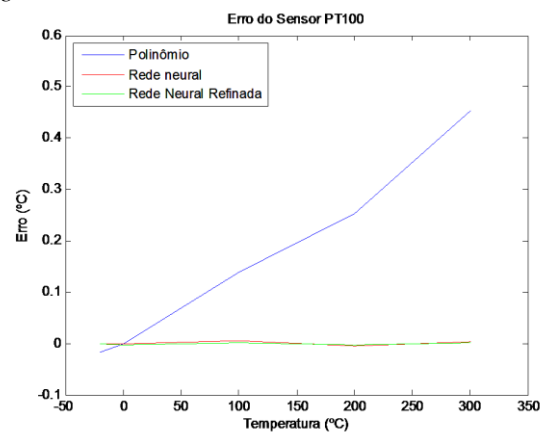


Figura 10 – Erros do Sistema

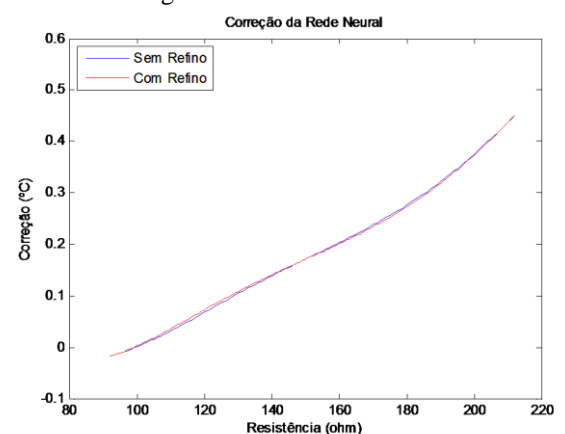


Figura 11 – Correção da Rede Neural

Foram feitas simulações no *Matlab*® com 4 e 3 pontos com as Redes Neurais. Usamos técnicas para retirar os pontos intermediários até restarem os pontos para análise, já que em alguns certificados apresentavam de 5 a 7 pontos de calibração. Porém, as Redes Neurais são limitadas em 3 pontos, impossibilitadas a menos pontos pela técnica de *Leave-One-Out*.



Com 4 pontos, as simulações foram rápidas e dinâmicas, fato que pode ser explicado por apresentar poucos pontos de calibração carregados no programa *Matlab*®. Com 3 pontos as simulações foram muito mais rápidas que com 4 pontos e os resultados mais consistentes. Na figura 12, podemos ver um teste de reprodutibilidade a partir do histórico das calibrações do nosso sensor, utilizando-se apenas 4 pontos das calibrações, ao mesmo tempo comparando-se com os ajustes obtidos com *software* comercial para *fit-curve* muito utilizado em metrologia o *TableCurve*®, com os mesmos pontos das calibrações. Na figura 13 podemos ver o mesmo teste porém com apenas 3 pontos retirados das calibrações, infelizmente não foi possível a comparação com o *TableCurve*®, porque o seu algoritmo não consegue gerar coeficientes com menos de 4 pontos.




Figura 5 – Reprodutibilidade com 4 pontos




Figura 6 – Reprodutibilidade com 3 pontos

## 5. CONCLUSÃO

Observando os resultados obtidos nas simulações no *Matlab*®, vimos que essa rede teve um excelente comportamento, convergindo para um resultado muito próximo da curva apresentada no aprendizado. A vantagem que este método pode apresentar em relação ao método estatístico tradicional, é a facilidade de implementação deste algoritmo em sistemas embarcados como: transmissores e termômetros, criando instrumentos auto-ajustáveis. Somando-se a isto, também a capacidade de absorver desvios de modelagem dos polinômios utilizados, devido à capacidade de generalização das redes neurais artificiais.

O próximo passo para aperfeiçoamento deste sistema seria: Implementar essa técnica em um microcontrolador e ou com um *software* com recursos específicos para instrumentação e controle como o *LabView*® e comparar os resultados com aqueles obtidos no *Matlab*®.

## REFERÊNCIAS

- [1] OLIVEIRA, M. A. A. ; AMARAL, J. L. M. ; AMARAL, J. F. M.. Algoritmos para Auto-Ajuste de Sensores Utilizando Redes Neurais.
- [2] INMETRO, Vocabulário Internacional de Termos Fundamentais e Gerais de Metrologia, 4a edição, Rio de Janeiro, 2005.
- [3] NICHOLAS, J. V. and WHITE, D.R., Traceable Temperatures, JOHN WILEY & SONS, 1997
- [4] PRESTON-THOMAS, H., The International Temperature Scale of 1990 (ITS-90), Metrologia, Vol 27, No. 1, 1990, pp 3-10
- [5] ASTM E 1137-97, Standard Specification for Industrial Platinum Resistance Thermometers, 1997
- [6] BIONDI, L. N.;PACHECO, M. A. C.; VELLASCO, M. M. B. R.; PASSOS, E. P. L. e CHIGANER, L.. Sistema Híbrido de Apoio à Decisão para Detecção e Diagnóstico de Falhas em Redes Elétricas. Anais do III Simpósio Brasileiro de Redes Neurais, Recife, p. 197-204, 1996.
- [7] COELHO, P. H. G.. A Complex EKF - RTRL Neural Networks. Proceedings of the IJCNN'2001, New Jersey, IEEE Press, v.1, p. 120-125, 2001.
- [8] DAYHOFF, Judith E.. Neural Network Architectures: An Introduction. New York: Van Nostrand Reinhold, 1990.
- [9] HAYKIN, Simon. Neural Networks a Comprehensive Foundation, Englewood Cliffs: Macmillan College Publishing Company, 1994.
- [10] MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre Aprendizado de Máquina. Capítulo 4. In: REZENDE, S. O. Sistemas Inteligentes: Fundamentos e Aplicações. Barueri: Manole, 2002.
- [11] GOLOVKO, V.; SAVITSKY, J.; SACHENKO, A.; KOCHAN, V.; TURCHENKO, V.; LAOPOULOS, T.; GRANDINETTI, L.. Intelligent System for Prediction of Sensor Drift. International Conference on Neural Networks and Artificial Intelligence ICNNAI'99, 1999.
- [12] PATRA, J. C.; GOPALKRISHNAN, V.; ANG, E. L.; DAS, A.. Neural Network-Based Self-Calibration/ Compensation of Sensors Operating in Harsh Environments. Sensors, 2004. Proceedings of IEEE Volume , Issue , 24-27 Oct. 2004 Page(s): 425 - 428 vol.1.
- [13] NAJAFI, M.; CULP, C.; LANGARI, R.. Performance Study of Enhanced Auto-Associative Neural Networks For Sensor Fault Detection. Energy Systems Laboratory, 2004
- [14] PINTO, J. O. P.; PINTO, A. M. A. C; TATIBANA, G. S.; SANCHES, R. O.; CARRASCO, B. N.; FLORA, N.; HINES , J. W.. Uma Nova Estratégia de Modelagem para Monitoramento de Instrumentos e Verificação de Calibração Usando Redes Neurais Artificiais. Anais do 3º Congresso Brasileiro de P&D em Petróleo e Gás., 2005
- [15] PEREIRA, J.M. D.; POSTOLACHE, O.; GIRÃO, P. S.. Using a Dual-Channel FDC Device and ANN Techniques to Improve Measurements Accuracy. Sensors & Transducers Magazine (S&T e-Digest), Vol.62, Issue 12, December 2005, pp.462-472
- [16] RIVERA, J.; CARRILLO, M.; CHACÓN, M.; HERRERA, G.; BOJORQUEZ, G.. Self-Calibration and Optimal Response in Intelligent Sensors Design Based on Artificial Neural Networks. sensors ISSN 1424-8220, 7, 1509-1529, 2007
- [17] ELMAN, J. L.. Finding Structure in Time. Cognitive Science, 14, 179-211. 1990.