

# Medidor de Vazão Termal Inteligente

**Alessandro de Almeida**  
**ale.bm@hotmail.com**  
**AEDB**

**Alexandre de Carvalho Pereira**  
**potter.a@gmail.com**  
**AEDB**

**Ricardo Alves Moreira dos Reis**  
**potter.a@gmail.com**  
**AEDB**

**Resumo:** Este artigo descreve o desenvolvimento de um medidor de vazão baseado no princípio de convecção forçada (termal) não-intrusivo inteligente. O medidor utiliza dois sensores comerciais do tipo LM35, um aquecido, que é responsável pela medição da velocidade de escoamento, e o outro utilizado como referência de temperatura do sensor aquecido. Ao se variar a quantidade de fluxo passante pelo medidor, a diferença de temperatura também varia de forma inversamente proporcional. Uma Rede Neural Artificial é treinada para identificar um padrão que correlacione a vazão através da diferença de temperatura entre o sensor aquecido e o não aquecido.

**Palavras Chave:** RNA - não intrusivo - medidor - vazão -

# MEDIDOR DE VAZÃO TERMAL INTELIGENTE

Alessandro de Almeida  
Alexandre de Carvalho Pereira  
Ricardo Alves Moreira dos Reis

Associação Educacional Dom Bosco – AEDB  
Faculdade de Engenharia de Resende

ale.bm@hotmail.com  
potter.a@gmail.com  
kurtalves@gmail.com

**Resumo:** Este artigo descreve o desenvolvimento de um medidor de vazão baseado no princípio de convecção forçada (termal) não-intrusivo inteligente. O medidor utiliza dois sensores comerciais do tipo LM35, um aquecido, que é responsável pela medição da velocidade de escoamento, e o outro utilizado como referência de temperatura do sensor aquecido. Ao se variar a quantidade de fluxo passante pelo medidor, a diferença de temperatura também varia de forma inversamente proporcional. Uma Rede Neural Artificial é treinada para identificar um padrão que correlacione a vazão através da diferença de temperatura entre o sensor aquecido e o não aquecido.

**Palavras Chaves:** RNA, não intrusivo medidor, vazão.

**Abstract:** This article describes the development of a flow meter based on the principle of forced convection (thermal) non-intrusive smart. The meter uses two commercial-type sensors LM35, a heated, which is responsible for measuring the flow velocity, and the other used as a reference temperature of the heated sensor. By varying the amount of flow passing through the meter, the difference in temperature also varies inversely. An Artificial Neural Network is trained to identify a pattern that correlates to flow through the temperature difference between heated sensor and unheated.

**Key Words:** RNA, non-intrusive meter, flow.

## 1 INTRODUÇÃO

Com avanço da micro-eletrônica 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, os circuitos de condicionamento de sinal, um dispositivo

contendo um processador e uma memória não-volátil, a fim de introduzir a inteligência necessária.

Com o grande crescimento de funcionalidades e formas de interfaceamento com as redes industriais fez com que o IEEE produzisse uma família de normas IEEE 1451 (“Standart 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.

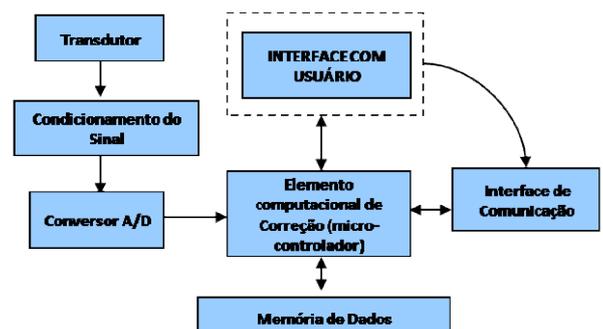


Figura 1 - Conceito básico de sensor inteligente

## 2 MEDIDOR DE VAZÃO TERMAL

Um dos métodos mais simples de medição térmica de fluxo de massa é feito através de um anemômetro de filme ou fio quente, normalmente utilizado para caracterização rápida das condições de variação de fluxo. Um fio é aquecido eletricamente e posicionado na trajetória do fluxo. A transferência de calor do fio ao fluido P é dada por:

$$P = (a + b \cdot v^{0,5}) \cdot (Tf - T\infty)$$

Onde:

Tf = temperatura do fio;

T = temperatura do fluido;

v é a velocidade do fluido;

a e b as constantes obtidas da calibração do anemômetro;

Essa razão de transferência de calor P também pode ser determinada pela expressão abaixo:

$$P = i^2 \cdot Rf = i^2 \cdot R0[1 + \alpha(Tf - T0)]$$

Onde:

i = corrente elétrica;

R0 = resistência do fio à temperatura T0;

Rf = resistência do fio a temperatura de referência Tf;

$\alpha$  = coeficiente de temperatura de resistência.

Para utilização do anemômetro, o fio quente deve ser conectado a um circuito do tipo ponte. Esse tipo de medidor assim como os demais não é intrusivo.

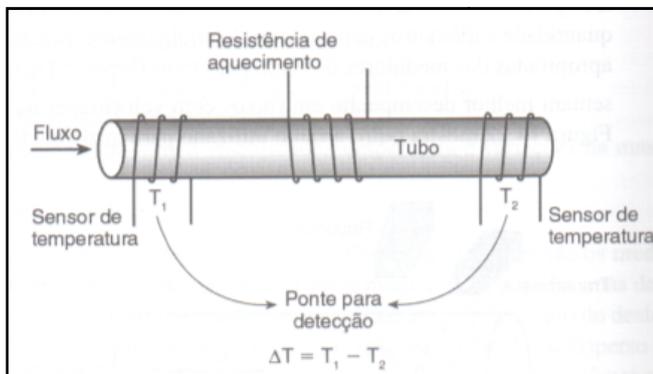


Figura 2 - Anemômetro de fio quente

### 2.1 COMPARAÇÃO ENTRE OS MEDIDORES DE VAZÃO.

A tabela 1 mostra as características básicas de medidores de fluxo onde o medidor desenvolvido está representado pelo medidor de fluxo do tipo Massa Térmica.

Tabela 1 – Características básicas para seleção de medidores de fluxo

Medidor de Fluxo	Escolha	Perda de Pressão	Precisão Típica (%)	Contato com o Líquido
Turbina	Líquidos limpo e viscosos	Alta	+/- 0,5	Invasivo
Eletromagnéticos	Líquidos condutivos, limpos e sujos	Nenhuma	+/- 0,5	Não invasivo
Ultra-Sônico	Líquidos sujos e viscosos	Nenhuma	+/- 5 do fundo de escala	Não invasivo
Massa Térmica	Líquidos limpos, sujos e viscosos	Nenhuma	+/- 1 do fundo de escala	Não invasivo
Vórtice	Líquidos limpos e sujos	Média	+/-1	Invasivo
Placa de Orifício	Líquidos limpos	Média	+/- +/- 4 do fundo de escala	Invasivo
Tubo de Venturi	Líquidos limpos, sujos e viscosos	Baixa	+/-1 do fundo de escala	Invasivo

## 3 REDES NEURAIS ARTIFICIAIS

As principais características das Redes Neurais Artificiais (RNA's) 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 (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 3 mostra a arquitetura de uma rede neural genérica com uma camada, em que p1, p2, p3,..., pR representam os elementos do vetor de treinamento P da rede (Coelho, 2001). O bloco somatório realiza a soma ponderada das entradas p1, p2, p3,..., pR com os pesos Wij, normalmente conhecida, sob a forma matricial, como NET = W • 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).

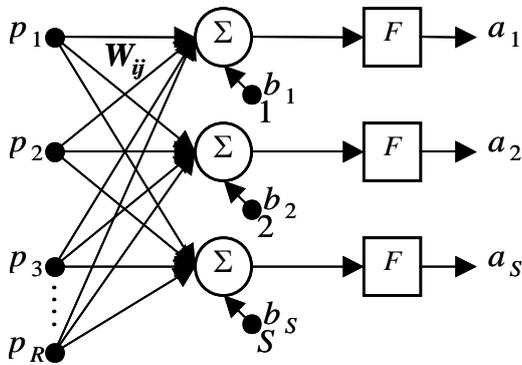


Figura 3 - Rede Neural Genérica

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 de erro (BP) é baseado no método do gradiente descendente, 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:

$$\Delta w^{(n)} = -2\eta e^{(n)} \frac{\partial e^{(n)}}{\partial W}$$

$$\Delta b^{(n)} = -2\eta e^{(n)} \frac{\partial e^{(n)}}{\partial b}$$

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

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

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

#### 4 COSTRUÇÃO DO MEDIDOR DE VAZÃO TERMAL

Dois tubos de cobre de  $\frac{1}{2}$  com as mesmas características materiais e dimensionais foram preparados para utilização na montagem do medidor termal de vazão usando método de convecção forçada. Estes podem ser visualizados na figura



Figura 4: Tubos de cobre usados como medidor

Os tubos de cobre que suportarão os sensores deverão estar separados por um material isolante do tipo PVC. Este material isolante tem a função de evitar a propagação de calor entre os tubos proveniente da resistência de aquecimento posicionado em um dos tubos, evitando interferências nas medidas e impossibilitando que o sensor de referência sofra influência térmica oriunda do tubo aquecido. A montagem dos tubos pode ser vista na figura 5.



Figura 5 – Conjunto montado.

O conjunto de sensores de temperatura LM35 fixados e a resistência de aquecimento, constituída por um fio de cobre esmaltado de 30AWG com 67 espiras que forneceu uma energia térmica de 15 J/s aproximadamente, podendo ser visualizados na figura 6 o circuito utilizado para ligá-la e também pode ser visualizada a montagem da resistência e do LM35 no tubo.

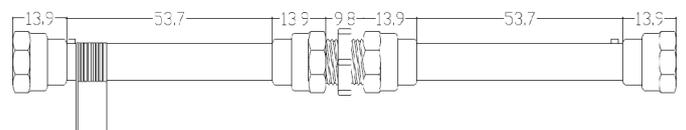


Figura 6: Resistência de aquecimento e sensores de temperatura LM35 instalados nas extremidades dos tubos.

Devido à sensibilidade dos sensores LM35 foi necessário a utilização de um isolante térmico para evitar interferências na variação de temperatura provocada pela temperatura ambiente. Entre os isoladores térmicos pesquisados foi utilizado uma manta de amianto que apresenta características de isolamento térmica satisfatória às necessidades do projeto, conforme ilustrado na figura 7.



Figura 7 – Isolamento térmico do medidor

Para a aquisição dos dados necessários, foi desenvolvida uma bancada de testes, conforme mostrado na figura 8, objetivando submeter o medidor termal a diversas condições de vazão e temperatura. O fluxo líquido é impulsionado por uma bomba de 3,3 bar, sendo acondicionado em uma caixa plástica que tem a função de condicionar o líquido impulsionado de forma a mantê-lo laminar.



Figura 8 – Planta do sistema

## 5 TREINAMENTO DA RNA

Inicialmente foram executados testes sistemáticos objetivando adquirir informações de vazão indicada pelo medidor de vazão tipo turbina e informações dos sensores de temperatura de modo a obter a diferença de temperatura entre a versão ativa e passiva do medidor de vazão termal. Para isso a bomba foi submetida a variações de tensão a fim de obter condições de vazão diferenciadas e por consequência uma variação da temperatura de saída do medidor.

Estes dados foram colhidos através da placa de aquisição da National Instruments (NI USB-6009) e processados pelo LabView de modo a criar um banco de dados. De posse desses dados foi possível realizar o treinamento da RNA utilizando o aplicativo Matlab que por sua vez ira gerar uma matriz que dará condições ao LabView indicar a vazão medida pelo medidor de vazão termal.

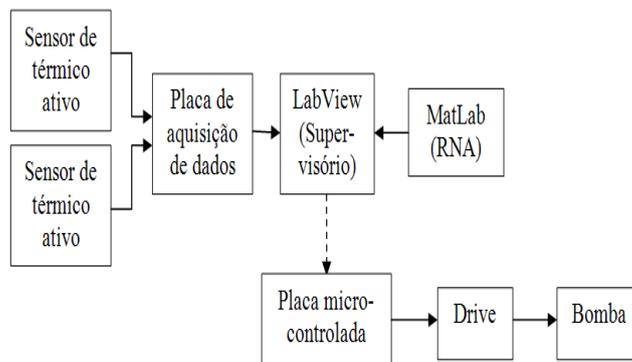


Figura 9 – Diagrama em blocos

Pode ser observado nos gráficos apresentados na figura 10 que a vazão é inversamente proporcional ao gráfico de delta t que segue a proporcionalidade do gráfico de temp. de saída.

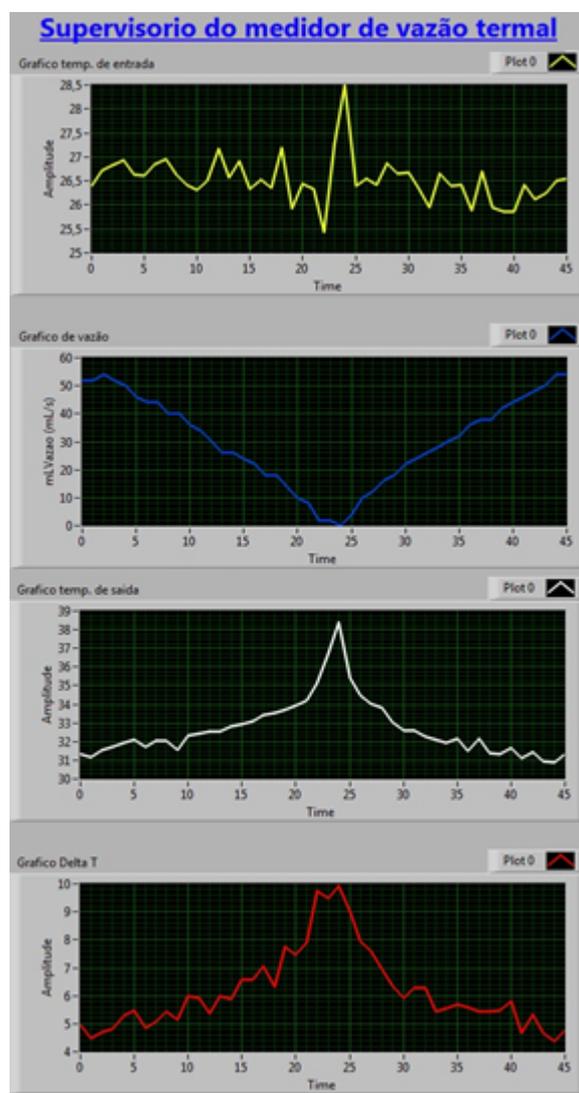


Figura 10 – Gráficos relacionando à variação de  $T$  com a variação de vazão

A figura 11 ilustra o gráfico de performance da RNA onde é indicada a curva de treinamento onde foram utilizados 70% dos dados, a curva validação onde foram utilizados 15% dos dados e a curva de teste onde foram utilizados 15% dos dados.

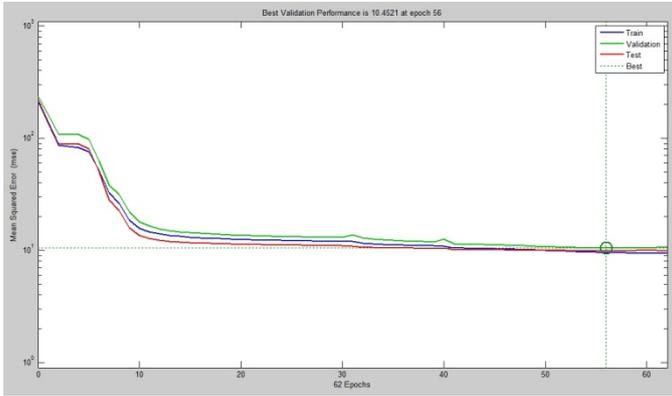


Figura 11 – Gráfico de performance da RNA

A figura 12 que segue, mostra o gráfico de comportamento da RNA.

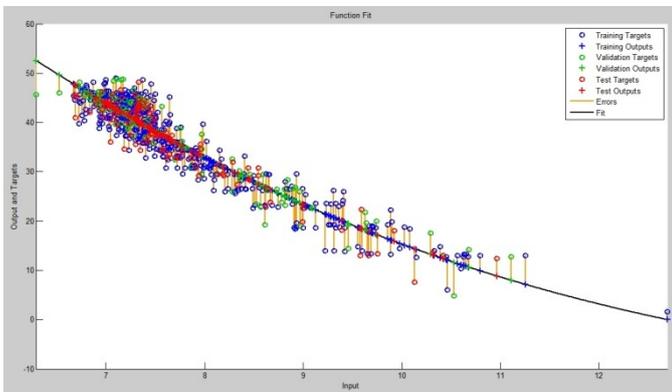


Figura 12 – Gráfico da função FIT

## 5.1 RESULTADOS DO MEDIDOR DE VAZÃO TERMAL INTELIGENTE

A figura 13 ilustra o gráfico da vazão obtido com as leituras do medidor de vazão termal inteligente que pode ser comparado com a figura 14 que ilustra o gráfico de vazão obtido com as leituras do medidor de vazão tipo turbina

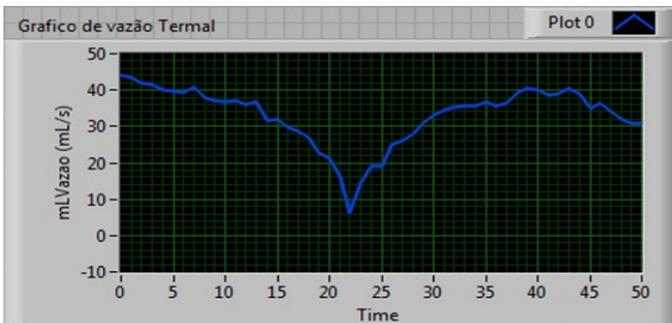


Figura 13 – Gráfico de vazão do medidor de vazão termal inteligente

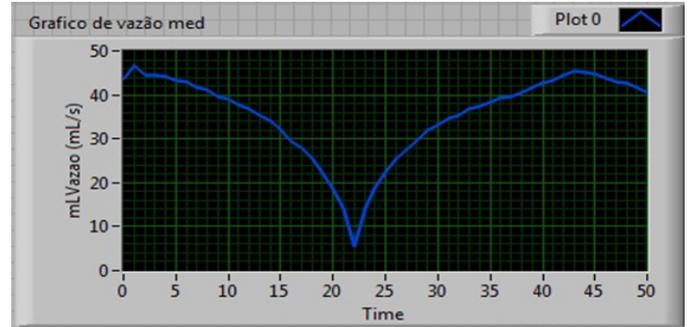


Figura 14 – Gráfico de vazão do medidor de vazão tipo turbina

A tabela 2 foi construída com objetivo de comparar os valores de vazão obtidos do medidor de vazão tipo turbina e do medidor de vazão termal inteligente

Tabela 2 – Demonstração de resultados

Tabela de comparação				
TEMPERATURA (°C)			Vazão (mL/s)	
Entrada	Saída	Variação	Turbina	Termal
26,411	33,401	6,99	43,604	43,956
26,535	33,58	7,045	46,605	43,311
26,861	34,032	7,171	44,604	41,859
26,948	34,134	7,186	44,404	41,679
26,958	34,299	7,341	44,204	39,918
27,005	34,352	7,347	43,204	39,851
27,098	34,479	7,381	42,804	39,471
27,317	34,588	7,27	41,804	40,721
27,302	34,821	7,519	41,004	37,946
27,353	34,949	7,596	39,604	37,102
27,412	35,045	7,632	39,004	36,708
27,526	35,115	7,589	37,604	37,177
27,698	35,395	7,697	36,804	36,011
27,811	35,427	7,616	35,404	36,885
27,666	35,778	8,112	34,003	31,691
27,78	35,872	8,092	32,203	31,896
27,897	36,186	8,29	29,403	29,928
27,823	36,239	8,416	27,803	28,698
27,975	36,583	8,608	25,603	26,878
27,884	36,935	9,051	22,402	22,883
28,043	37,28	9,236	18,802	21,299
27,986	37,888	9,902	14,201	16,013
28,038	39,457	11,419	5,601	6,176
28,266	38,38	10,114	14,001	14,457
28,112	37,624	9,512	18,602	19,037
27,992	37,489	9,497	22,402	19,154
28,146	36,959	8,813	25,403	24,991
28,152	36,847	8,695	27,603	26,067
28,053	36,548	8,496	29,403	27,934
28,051	36,246	8,195	31,803	30,858
28,172	36,155	7,983	33,203	33,007
28,054	35,885	7,832	34,803	34,584
28,166	35,925	7,759	35,404	35,353
28,005	35,742	7,737	36,804	35,585
27,965	35,705	7,74	37,404	35,557
27,935	35,571	7,636	38,404	36,673
27,805	35,54	7,736	39,204	35,6
27,742	35,422	7,68	39,604	36,198
27,974	35,384	7,41	40,604	39,147
28,013	35,308	7,294	41,804	40,447
27,968	35,296	7,328	42,604	40,063

## 6 CONCLUSÃO

Partindo do conceito de medidor termal por convecção forçada foi desenvolvido um medidor de vazão térmico com a característica principal de não ser intrusivo, isto é não ter contato com fluido e conseqüentemente evitar que o mesmo tenha alteração em sua pressão, possua boa precisão e baixo custo de implementação.

Mediante aos resultados encontrados foi verificado que o medidor se mostrou confiável em comparação a outro medidor normalizado incluso na linha de escoamento do fluido. É desejável, no futuro tornar todo hardware embarcado em um microcontrolador.

O medidor proposto vem de encontro, devido a sua característica não intrusiva, a satisfazer uma necessidade crescente de medidores de vazão que sejam extrínsecos.

## 7 REFERÊNCIAS BIBLIOGRÁFICAS

[1]-ZAMBRONI, Antonio Carlos. Introdução a Modelagem Análise e Simulação de Sistemas Dinâmicos, Editora Interciência, 2008.

[2]-ALBERTAZZ, Arnando G Jr. Fundamentos de Metrologia Científica e Industrial, Editora Manole, 2008.

[3]-AGUIRRE, Luis Antonio. Introdução à Identificação de Sistemas – Técnicas Lineares e Não-Lineares, Editora Ufm, 2007.

[4]-SIMÕES, Marcelo Godoy. SHAW, Ian S. Controle e Modelagem Fuzzy, Blucher, 2007

[5]-MORAES, Cícero Couto. Engenharia de Automação Industrial, LTC, 2007

[6]-PAZOS, Fernando. Automação de Sistemas & Robótica, Axcel Books, 2002

[7]-BALBINOT, Alexandre. Instrumentação e Fundamentos de Medidas, vol 2, LTC, 2007.

[8]-FIALHO, Arivelto Bustamante. Instrumentação Industrial: Conceitos Aplicações e Análises, Érica 2002.

[9]-ALVES, José Luiz Loureiro. Instrumentação, Controle e Automação de Processos, LTC, 2005.

[10]-LIRA, Francisco Adval de. Metrologia na Indústria, Érica, 2007.

[11]-BEGA, Egídio Alberto. Instrumentação Industrial, Interciência, 2006.

[12]-HIME, Aguiar e Oliveira Junior. Inteligência Computacional Aplicada a Administração, Economia E Engenharia Em Matlab, THOMSON, 2007.

[13]-LUCAS, Diogo C. Algoritmos Genéticos: Uma Introdução – UFRGS

[14]-Portaria n.º 029 de março de 1995 do INMETRO – Instituto Nacional de Metrologia, Normalização e Qualidade Industrial, 1995.

[15]-<http://makebits.net/integrar-labview-e-arduino/>

[16]-<http://web.me.com/iklln6/automation/LabVIEW.html>

[17]<http://www.arduino.cc/playground/Main/DCMotorControl>

[18]-<http://andredrobotics.wordpress.com/tutoriais/arduino-motorshield/>

[19]-<http://www.uchobby.com/index.php/2007/09/23/arduino-temperature-controlled-pc-fan>

[20] OLIVEIRA, M. A. A. ; PINHEIRO, G. R. V. ; AMARAL, J. L. M. ; AMARAL, J. F. M. ; Desenvolvimento de um Anemômetro por Convecção Forçada. Anais do Primeiro Congresso Internacional de Metrologia Mecânica, Rio de Janeiro, 2008.

[21] B.Braun; FAD100 - Manual do Usuário rev. 04. Laboratórios B Braun S.A., 2008

[22] B.Braun; Service Manual Diapact CRRT, Edition, 3/97.

[23] GAMBRO DASCO; Sistema Prisma - Manual do Utilizador, 2002

[24] DAUGIRDAS J. T.; ING T. S.; Handbook of Dialysis, Editora Litle, Brown and Company, 1994

[25] COX, E. ; O'HAGAN, M.; The Fuzzy Systems Handbook, Academic Press, 1994.

[26] KOSKO, B. ; Fuzzy Engineering. Prentice-Hall, 1997.

[26] 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.

[27] 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.

[28] NAJAFI, M.; CULP, C.; LANGARI, R.. Performance Study of Enhanced Auto-Associative Neural Networks For Sensor Fault Detection. Energy Systems Laboratory, 2004

[29] 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

[30] 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

[31] 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

[32] Teruel, J.L.; Lucas, M. F.; Marcén, R.; Rodríguez, J.R.; Sánchez, J. L.; Rivera, M. Liaño, F.; Ortuño, J.. Differences between Blood Flow as Indicated by the Hemodialysis Blood Roller Pump and Blood Flow Measured by an Ultrasonic Sensor. *nephron Journals*, Vol. 85, No. 2, 2000

[33] 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.

[34] INMETRO, Vocabulário Internacional de Termos Fundamentais e Gerais de Metrologia, 4a edição, Rio de Janeiro, 2005.

[35] NICHOLAS, J. V. and WHITE, D.R., Traceable Temperatures, JOHN WILEY & SONS, 1997

[36] PRESTON-THOMAS, H., The International Temperature Scale of 1990 (ITS-90), *Metrologia*, Vol 27, No. 1, 1990, pp 3-10

[37] ASTM E 1137-97, Standard Specification for Industrial Platinum Resistance Thermometers, 1997

[38] 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.

[39] 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.

[40] DAYHOFF, Judith E.. Neural Network Architectures: An Introduction. New York: Van Nostrand Reinhold, 1990.

[41] HAYKIN, Simon. Neural Networks a Comprehensive Foundation, Englewood Cliffs: Macmillan College Publishing Company, 1994.

[42] 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.

[43] ELMAN, J. L.. Finding Structure in Time. *Cognitive Science*, 14, 179-211. 1990.

