

# IMPLEMENTAÇÃO DE TÉCNICAS INTELIGENTES PARA A DETECÇÃO DE VAZAMENTOS EM DUTOS EM REGIME DE ESCOAMENTO MULTIFÁSICO CRÍTICO

Rodrigo S. Martins, André L. Maitelli, Adrião D. D. Neto e Andres O. Salazar

DCA/UFRN

e-mail: rodrigom@dca.ufrn.br

## Resumo

Este trabalho consiste na utilização de técnicas de processamento de sinais e redes neurais artificiais para identificar vazamentos em dutos de regime multifásico. A grande dificuldade dos métodos tradicionais de detecção de vazamento (balanço de volume, análise pontual de pressão, etc) está em conseguir montar um perfil, que seja adequado aos encontrados em condições reais do transporte de óleo em dutos. Estas difíceis condições vão desde os desníveis de terreno que causam colunas ou vácuos ao longo dos dutos até a presença de multifases como água, gás e óleo, além de outros componentes como areia, que tendem a produzir escoamentos descontínuos e variações diversas. Para reduzir estas dificuldades, foi utilizada a transformada wavelet para mapear o sinal de pressão em diferentes planos de resolução permitindo com isto a extração dos descritores que caracterizassem padrões de vazamento e com os mesmos treinar uma rede neural perceptron de múltiplas camadas (multilayer perceptron - MLP) para aprender a classificar estes padrões e informar quando estes são referentes a um vazamento. Nos testes foram utilizados sinais de regime e transiente, onde foi possível detectar vazamentos, também foram utilizados dutos com furos que variavam de 1/2" a 1" de diâmetro para simular os vazamentos. Foi possível detectar vazamentos com janelas de tempo de 2 min. Os resultados obtidos mostram que os descritores propostos com base em medidas estatísticas no domínio da transformada caracterizam os padrões de vazamento e possibilitam o treinamento do classificador neural para indicar a ocorrência ou não de vazamentos no duto.

## 1. Introdução

Este artigo se propõe ao desenvolvimento de uma técnica detecção de vazamentos em óleos dutos de escoamento multifásico utilizando técnicas de processamento de sinais com base na transformada wavelet e redes neurais artificiais para melhorar o método da análise pontual de pressão. O duto utilizado nos testes, é terrestre e será chamado de U-E. De perfil bastante complexo com uma extensão de 38 Km e diâmetro de 12" com medidores de vazão a 4,5 Km de ponto U, outro a 9 Km de ponto E e um terceiro a 1 Km do ponto E, como pode ser visto graficamente na Figura 1. A grande dificuldade em sintonizar sistemas de detecção vazamentos está em montar um perfil que possibilite a visualização ou percepção de vazamentos mesmo quando a presença de transientes como ligação

de bombas, entradas de gás, e golfadas devido a areia, etc.

O método utilizado foi buscar na transformada wavelet descritores estocásticos que pudessem ser assimilados por uma rede neural de modo a identificar estes vazamentos.




Figura 1. Perfil do duto

## 2. Transformada Wavelet

O objetivo da transformada wavelet é descrever uma função como uma combinação de funções de base (ou funções wavelets) e possibilitar uma melhor análise desta função ou sinal. As funções wavelets são oriundas de uma função denominada de wavelet mãe e são definidas a partir de escalonamentos e translações da wavelet mãe. Várias são as famílias dessas funções (Daubechies, Coiflets, etc). Um sinal representado como uma função no tempo pode ser expandida pela wavelet em coeficientes de escala em tempo e frequência. Segundo o princípio da incerteza de Heisenberg, não é possível saber exatamente qual frequência existe em um dado instante de tempo, mas apenas podemos saber quais bandas de frequência existem em determinados intervalos de tempo. A capacidade de análise de multiresolução e análise de características localizadas, fazem a referida transformada uma poderosa ferramenta na extração de informações e em particular nos transitórios de funções.

A transformada de wavelet contínua TWC de uma função é definida por:

$$TWC_f^w(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-\tau}{s}\right) dt$$
$$s, t \in \mathfrak{R}, s \neq 0$$

Onde  $f(t)$  é a função a ser analisada, os parâmetros  $\tau$  e  $s$  são chamados de coeficientes translação e escala, respectivamente.  $\psi(t)$  é a função wavelet mãe, sendo:

$$\psi_{s,\tau}(t) = |s|^{-1/2} \psi\left(\frac{t-\tau}{s}\right) \quad s, t \in \mathfrak{R}, s \neq 0$$

A análise chamada de multiresolução, consiste em usar bancos de filtros para fazer a análise e síntese do sinal.

Em termos matemáticos podemos descrever o banco de filtros como duas equações básicas:

Função de análise

$$f(t) = \sum_k c_j(k) 2^{j/2} \varphi(2^j t - k) + \sum_k d_j(k) 2^{j/2} \varphi(2^j t - k)$$

$$c_j(k) = \sum_m h_0(m - 2k) c_{j+1}$$

$$d_j(k) = \sum_m h_1(m - 2k) c_{j+1}$$

Função de síntese

$$c_{j+1}(k) = \sum_m c_j(m) h_0(k - 2m) + \sum_m d_j(m) h_1(k - 2m)$$

Onde  $h_0$  e  $h_1$  são coeficientes de base para filtros.

A transformada wavelet tem aplicação em várias áreas do conhecimento. No processamento de sinais ela pode ser utilizada como filtro, compressor de informação, extrator de características, etc. Neste trabalho ela será utilizada na extração de atributos que caracterizem os padrões de vazamento no sinal de pressão.

### 3. Redes Neurais

Podemos definir uma rede neural como um processador paralelo constituído de várias estruturas elementares de processamento denominadas de neurônios artificiais com elevada conectividade podendo desempenhar uma determinada função computacional, segundo Haykin (2001). Esta estrutura tem a capacidade de aprender através de experimentos e que podem em seguida serem testados e validados para o uso como uma determinada função, tais como classificar padrões não linearmente separáveis.

A estrutura mais simples da rede neural é chamada neurônio que tem uma associação ao modelo biológico (figura 2).




Figura 2. Modelo de neurônio

Como semelhança aos neurônios biológicos estas estruturas possuem ganhos ou pesos sinápticos que são os armazenadores de conhecimento e são os parâmetros livres da estrutura.

Em termos matemáticos a saída de cada neurônio é definida como sendo:

$$y_k = \varphi\left(\sum_{j=1}^m w_{kj} x_j + b_k\right)$$

Onde  $\varphi(.)$  é a função de ativação (limiar, linear, sigmóide) que representa a saída do neurônio com relação ao campo local induzido  $v$ ,  $w_{kj}$  são os pesos,  $x_j$  é a entrada,  $b_k$  é o bias que tem como efeito distanciar a saída da origem e  $y_k$  que é a saída do neurônio.

A disposição das conexões de neurônios é chamada arquitetura da rede e esta intimamente ligada ao algoritmo de aprendizagem. A arquitetura utilizada foi a MLP (Multilayer Perceptron) que são várias camadas interconectadas: a primeira chamada de entrada que se conecta com outras mais internas, chamada de ocultas ou escondida e a última desta se conecta a de saída (figura 3). O treinamento da rede consiste em determinar os valores dos ganhos sináptico que minimizem o erro médio quadrático. Existem diferentes algoritmos e dentre eles o mais utilizado o algoritmo da backpropagation, segundo Haykin (2001).




Figura 3. Modelo de rede MLP

## 4. Metodologia

Utilizando a transformada wavelet foi processado o sinal buscando os coeficientes do filtro passa alta em busca das altas resoluções que caracterizam o vazamento. Em seguida foi buscado extrair características nestes sinais para apresentar a rede neural e obter como saída o indicador de presença ou não de vazamento, sendo -1 e 1 respectivamente. Os dados são processados através de janela com um número de 120 amostras por janela. Para fins de treinamento foram utilizadas 100 janelas com e sem vazamento e subdivididas aleatoriamente em cinco grupos de quarenta padrões para fazer a validação cruzada. Os sinais utilizados em ambos os casos, são sinais de pressão e vazão do duto U-E (figura 4 e 5) e com simulação de vazamento com abertura de válvulas de diâmetro de 1'', 1/2'' e 3/4''. Os sinais foram registrados e processados sob forma de janelas deslizantes com superposição de cinquenta por cento (50%), que corresponde ao intervalo de tempo de seis segundos.




Figura 4. Sinal de pressão

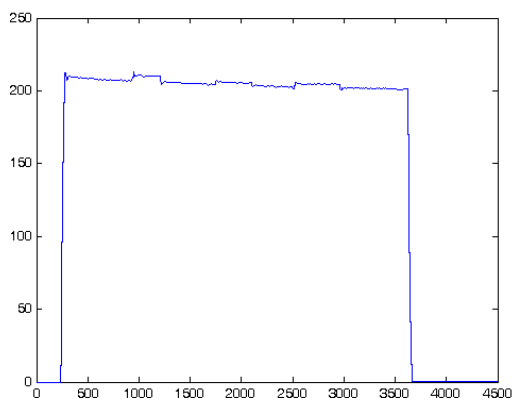


Figura 5. Sinal de vazão

O sinal original  $S$  é passado para o domínio da transformada através de um banco de filtros como

mostra a figura 6, sendo utilizada para este isto a wavelet de Coiflets de ordem 5, resultando em quatro sinais de detalhe  $d_1, d_2, d_3, d_4$ . A resultante desta transformação é obtida separadamente para o sinal de pressão e vazão e depois concatenados. Para cada sinal no domínio da wavelet, são extraídos os descritores. Cada descritor corresponde a uma medida de autocorrelação definida como:

$$r(k) = E[s_i(n)s_i(n-k)]; \quad k = 0, 1, 2, 3.$$




Figura 6. Metodologia de trabalho

Na figura 6 pode-se observar graficamente a metodologia, onde,  $Y$  é a saída do sistema. Na prática a rede neural é responsável por criar a hipersuperfície de separação entre as duas condições, vazamento e não vazamento. Não está apresentado na figura, mas antes da aplicação da transformada wavelet os sinais são pré-processados sendo retirada a média do sinal pra facilitar o treinamento da rede neural e em seguida é passado um filtro de mediana para reduzir o ruído sem descaracterizar as informações presentes no sinal.

A função de ativação utilizada em cada neurônio foi a tangente sigmóide, para que pudessemos usar a rede como classificador.

Um problema encontrado no duto estudado são os desligamentos de bombas que são sentidos pelos sensores de pressão e vazão como quedas bruscas e normalmente acentuadas nestes dois sinais, que poderiam ser causadores de alarmes falsos. Conforme podemos ver na figura 4 e 5 em dois transitórios inicial e final acentuado.

Com a impossibilidade física de obter sinais de simulações de vazamentos nestes pontos, para que fosse treinada uma rede pra reconhecer estes pontos, e para evitar alarmes falsos; inserimos uma base de regra apoiada pelo sinal de envio de ligamento e desligamento das bombas pra considerar o não processamento do sinal neste período. Os tempos médios destes transientes são de 2 min na ligação da bomba e de 8 min no desligamento.

A tabela 1 mostra que o uso combinado da transformada wavelet e de técnicas estatísticas como a variância ( $k=0$ ) e a autocorrelação ( $k=1,2,3$ ), caracteriza bem as situações de vazamento e não vazamento, mesmo em regime transiente. Os valores da tabela foram normalizados em  $10^{-3}$ .

Tabela 1. descritores de treinamento

	Vazamento				Sem vazamento			
	J <sub>1</sub>	J <sub>2</sub>	J <sub>3</sub>	J <sub>4</sub>	J <sub>1</sub>	J <sub>2</sub>	J <sub>3</sub>	J <sub>4</sub>
r(0)	0,9966	0,6448	0,3290	0,4244	0,0776	0,0540	0,0218	0,0137
r(1)	2,8006	1,2071	1,1848	0,8672	0,1421	0,1807	0,0867	0,0335
r(2)	7,0903	2,7140	3,0391	3,2559	0,4063	0,9072	0,3641	0,0786
r(3)	11,4826	6,5882	2,7650	4,3505	0,4996	3,3441	1,1245	0,1656

Para fins de treinamento e validação foi utilizada a técnica de validação cruzada, que consiste em separar os sinais de treinamento e outro de validação de modo que em cada validação um conjunto seja guardado que nunca tenha sido apresentado a rede. O quadro da figura 7 mostra a idéia de forma gráfica.

Treinamento	Treinamento	Treinamento	Treinamento	Validação
Treinamento	Treinamento	Treinamento	Validação	Treinamento
Treinamento	Treinamento	Validação	Treinamento	Treinamento
Treinamento	Validação	Treinamento	Treinamento	Treinamento
Validação	Treinamento	Treinamento	Treinamento	Treinamento

Figura 7. Validação Cruzada

Segundo Haykin o reconhecimento de padrões é realizado por uma rede de natureza estatística sendo representados pontos em espaço de decisão multidimensional. Por isso o critério de parada é um ponto decisivo no treinamento de uma rede neural numa aplicação deste tipo. O critério que normalmente se utiliza no treinamento de redes supervisionadas é o erro médio quadrático de cada época.

Em testes, foi obtido um erro oscilatório. Considerando que uma época é a apresentação de vários padrões de vazamento e não vazamento, não existe a garantia que o uma minimização deste erro numa determinada época significa que a rede aprendeu, pois ela pode ter apenas “decorado” as amostras atuais.

A técnica de validação cruzada como citada anteriormente diminui este risco da não generalização mas pode provocar instabilidade, de forma que o algoritmo não convirja, à medida que o erro de treinamento seja minimizado e o de validação não seja e este processo se repita indefinidamente.




Figura 8. Erro de várias épocas concatenado

Assim é possível planejar critérios de parada baseados na quantidade de épocas. Mas a falta de um valor que possa ser utilizado como garantia que houve aprendizado, não é uma solução trivial, foi utilizada a concatenação dos erros de várias épocas e a retirada da média e o mínimo, para resolver este problema. Onde o menor valor deste é considerado o peso de treinamento e em seguida validado. Na figura 8 e 9, pode-se observar o comportamento de ambos os erros.




Figura 9. Erro “estatístico”

## 6. Resultados

Foram testadas diferentes arquiteturas para rede neural sendo que a rede que apresentou melhores resultados, consistiu de quatro entradas, 16 neurônios na camada oculta e 1 neurônio na camada de saída, podendo ser, sintetizado por 4:16:1. A tabela 2, mostra uma comparação entre duas arquiteturas utilizadas. Pode-se observar que o erro foi diminuído, para situação de não apresentação de vazamento, sendo este considerado o pior caso de erro, onde o vazamento ocorreria na prática e o sistema não detectou, no caso contrário o alarme falso não implica em danos ambientais ou outro custo qualquer exceto o fato do operador ter que verificar a autenticidade do alarme. Para obtenção destes percentuais, o algoritmo foi rodado dez vezes e feito a média deles para os resultado abaixo:

Tabela 2. Comparação entre arquiteturas

Arquitetura / Época	% Acerto Sem Vazamento	% Acerto Com Vazamento
4:8:1 / 200	96	91
4:15:1 / 200	95	95

Outras arquiteturas foram testadas, mas as maiores não apresentaram melhoras quanto aos resultados e o tempo de processamento aumentava e no inverso, os resultados pioravam apesar da melhoria no

tempo de processamento. Importante destacar que em cada janela é aplicada a transformada wavelet e extraído os descritores. Na tabela 2, temos a matriz de confusão onde é possível observar as situações de verdadeiro positivo e falso positivo.

Tabela 2. Matriz de confusão

	Indicação do vazamento	Não indicação do vazamento
Ocorrência vazamento	95,2 %	4,98 %
Não ocorrência do vazamento	5,03 %	94,97 %

## 7. Conclusões

O sistema proposto se mostrou robusto para detectar vazamentos utilizando técnicas de processamento de sinais combinadas com técnicas inteligentes. O sistema pode ser adaptado também para usar sinais provenientes do monitoramento do duto por sensores diferentes dos de pressão, por exemplo podemos utilizar o sensor de ultra-som.

Como complementação deste trabalho pode-se utilizar máquinas de comitês (redes neurais especialistas) para aumentar mais ainda a confiabilidade na tomada de decisões.

## 7. Agradecimentos

A Petrobras através da UN-RNCE, na pessoa do Engenheiro Fabiano Azevedo.

## 8. Referências

- TORRENCE C, COMPO GP. A practical guide to wavelet analysis. B am Meteorol Soc., 1998.
- HAYKIN, SIMON, Redes Neurais – Princípios e prática, 2ª edição, Porto Alegre, 2001.
- MORETTIN , PEDRO A., Ondas e Ondaletas – Da análise de Fourier à análise de Ondaletas, São Paulo, 1999.
- FREITAS, R. D. G.; MAITELLI, A. L. & SALAZAR, A. O. An Wavelet Approach to Pipeline Leak Detection by Pressure Analysis. Proceedings of OMAE2004. 23rd International Conference on Offshore Mechanics and Arctic Engineering, pp.1-4, Vancouver, Canada, June 2004.