

# SISTEMAS DE DETECÇÃO DE VAZAMENTOS EM DUTOS USANDO REDES NEURAIAS E MÁQUINAS DE VETOR DE SUPORTE

RODRIGO S. MARTINS, VICTOR J. L. DUARTE, ANDRÉ L. MAITELLI, ANDRÉS O. SALAZAR, ADRIÃO D. D. NETO

*Laboratório de Avaliação de Medição em Petróleo, Departamento de Engenharia de Computação e Automação,  
Universidade Federal do Rio Grande do Norte*

*Caixa Postal 1524 - Campus Universitário Lagoa Nova*

*CEP 59072-970 Natal - RN - Brasil*

*E-mails: [rodrigoss@dca.ufrn.br](mailto:rodrigoss@dca.ufrn.br), [victor@dca.ufrn.br](mailto:victor@dca.ufrn.br), [maitelli@dca.ufrn.br](mailto:maitelli@dca.ufrn.br),  
[andres@dca.ufrn.br](mailto:andres@dca.ufrn.br), [adriao@dca.ufrn.br](mailto:adriao@dca.ufrn.br)*

**Abstract**— The leaks detection in pipes of Petroleum has been studied thoroughly and several solutions are applied in specific cases. However not was found the solution that is adapted the several conditions in real pipe of petroleum, where there are a high cost in the migration of solutions and even to make unfeasible of the same ones. The found solutions are particular and limited to the place where they were studied. In this paper was looked for to get the solution for this problem taking a pipe that possesses much peculiar characteristics and solving the leak problems of him. Thus for extrapolation an solution less complex could be approached easily or adapted. The pipe of 12" of diameter and 40 Km of the extension is not pressurized and the unevenness the one that is submitted does with that there is break of column. There is also the presence of slugs besides the common transients of bombs, valves, among others.

**Keywords**— Neural Network Artificial (NNA), Support Vector Machine (SVM), Digital Signal Processing (DSP), Wavelet Transform, Leak Detection.

**Resumo**— A detecção de vazamentos em dutos de Petróleo tem sido amplamente estudada e várias soluções são aplicadas em casos específicos. No entanto longe de uma solução que se adequa as varias condições encontradas em dutos reais de transporte de petróleo, onde se tem alto custo na migração de soluções e até mesmo a inviabilização dos mesmos, o que se encontra são soluções particulares e limitadas ao local onde foram estudadas. Neste trabalho foi buscado vencer essa problemática tomando um duto que possui características bastante peculiares e resolvendo os problemas dele e que por extrapolação soluções menos complexas poderiam ser facilmente abordadas ou adaptadas. O duto de 12" possui 40 Km de extensão, não é pressurizado e o desnível a que está submetido faz com que haja quebra de coluna do fluido. Há neste também a presença de golfadas além dos transientes comuns como bombas, válvulas, entre outras.

**Palavras-chave**— Redes Neurais Artificiais (RNA), Máquina de Vetor de Suporte (SVM), Processamento Digital de Sinais (DSP), Transformada Wavelet, Detecção de Vazamentos.

## 1 Introdução

A comparação de duas tecnologias é um instrumento que permite o avanço destas no campo científico. Não quer dizer que uma é melhor que a outra, mas que uma pode servir de referencial ou complemento para outra. Assim sendo, neste trabalho tentar-se-á fazer comparações de duas tecnologias bem recentes no campo da inteligência computacional, as redes neurais e as SVM (*Support Vector Machine*). Estas duas ferramentas serão utilizadas como classificador de padrões entre classes com e sem vazamentos de sinais de pressão reais, onde os vazamentos são simulados em campo por abertura de válvulas. Os sinais utilizados na comparação dos métodos são os mesmos, que quantitativamente falando é considerado pouco, mas são o suficiente para revelar comportamentos e treinar ambas as redes a detectar vazamentos em dutos de petróleo. Foi utilizado também um processamento digital de sinal (DSP).

Uma dificuldade de se fazer um método de detecção de vazamento é conseguir montar um “descriptor” que caracterize o vazamento em qualquer situa-

ção. O processamento de sinal tem seu papel no uso da transformada *wavelet* que será usada para extrair esses descritores, que são tão somente características do sinal no domínio da frequência que permitem visualizar características que no domínio do tempo não era possível.

## 2 Transformada Wavelet

A transformada *wavelet* será utilizada como ferramenta de análise na extração de atributos que caracterizem os padrões de vazamento presente em um sinal de pressão.

A *wavelet* tem a capacidade de extrair informação de forma que se possa analisar blocos de informação em detalhes ou em escala, e assim retirar informações outrora não visíveis no domínio do tempo. Pode-se resumir a transformada *wavelet*, sob um conceito chamado de análise de multiresolução, em dois filtros (passa-baixa e passa-alta). Assim podemos obter o resultado da transformada como uma função  $f(t)$  pode ser escrita como:

$$f(t) = \sum_k c_{j_0}(k) \varphi_{j_0,k}(t) + \sum_k \sum_{j=j_0}^{J-1} d_j(k) \psi_{j,k}(t) \quad (1)$$

Onde  $\varphi$  e  $\psi$  são funções de base ortogonais que caracterizam famílias de wavelets ou wavelets-mãe. O termos  $c_j$  e  $d_j$  são coeficientes que podem ser calculados por:

$$c_j(k) = \sum_m h_0(m-2k) c_{j+1}(m) \quad (3)$$

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

onde  $h_0$  e  $h_1$  são coeficientes de base para filtros, [1]. Pode-se melhor entender a estrutura do banco de filtros, [2], pela Figura 1, onde  $\downarrow 2$  é chamado de operador de decimação, que tem uma função simples de descartar metade dos dados, sem perda de informação por causa do efeito aliasing que mistura a perda de informação com componentes da frequência.




Figura 1– Banco de Filtros

### 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, [1]. Esta estrutura pode exercer várias funções que podem ser aprendidas por experimentos, tais como: classificação de padrões, compressão de imagens, filtragem, etc. Nesse trabalho iremos discutir as redes MLP (*multilayer perceptron*), que tem a sua estrutura mais simples chamada de neurônio referenciando o modelo biológico (Figura 2).




Figura 2 - Modelo de neurônio

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, [1]:

$$y_k = \varphi\left(\sum_{j=1}^m w_{kj} x_j + b_k\right) \quad (4)$$

Em que  $\varphi(\cdot)$  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 MLP (*Multilayer Perceptron*) é constituída de várias camadas interconectadas: a primeira chamada de entrada que se conecta com outras mais internas, chamada de ocultas ou escondidas e a última desta se conecta a de saída (Figura 3). O treinamento da rede consiste em determinar os valores dos ganhos sinápticos que minimizem o erro médio quadrático. Existem diferentes algoritmos de treinamento e dentre eles o mais utilizado o algoritmo da *backpropagation*, [1], que foi o escolhido neste trabalho.




Figura 3- Modelo de rede MLP

### 4 SVM

A máquina de vetor de suporte (SVM – *Support Vector Machine*) proposta por Vapnik,[4] pode ser usada no reconhecimento de padrões, como é o caso do problema exposto neste artigo. A idéia principal de uma máquina de vetor de suporte é criar um hiperplano de separação como superfície de decisão, de modo que a separação entre seus exemplos positivos e negativos sejam máxima [1].

Embora as máquinas não incorporem conhecimento do domínio do problema, como fazem as redes neurais, elas possuem um bom desempenho na generalização da classificação de padrões utilizando o chamado *método de minimização estrutural de risco* que depende de um termo chamado dimensão de Vapnik-Chervonenkis (V-C), que pode ser definido

como um índice escalar que mede a complexidade intrínseca de uma classe de funções, [3].

Uma percepção central na construção do algoritmo de aprendizagem das SVM é chamado de vetor de suporte e seu produto pelo vetor  $x$  retirado do espaço de entrada. O vetor de suporte é um array de pontos no domínio do problema que permite informar se um padrão pertence ou não a um determinada classe.

A Figura 4 mostra de forma gráfica o hiperplano ótimo de separação ótimo e o vetor de suporte.

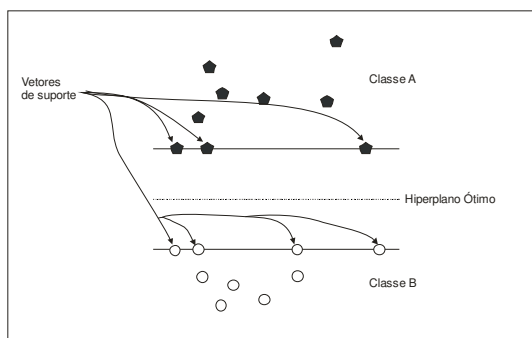


Figura 4 – Visualização gráfica da SVM.

Assim, dado um vetor  $x$  retirado do espaço de entrada de dimensão  $m_0$  e um conjunto de transformações não lineares do espaço de entrada para o espaço de características de dimensão  $m_1$  representado por:  $\{\varphi_j(x)\}_{j=1}^{m_1}$ . Pode-se definir um hiperplano atuando como superfície de decisão, conforme equação (5),

$$\sum_{j=1}^{m_1} w_j \varphi_j(x) + b = 0 \quad (5)$$

Onde  $\{w_j\}_{j=1}^{m_1}$  representa um conjunto de pesos lineares que conecta o espaço de características com o espaço de saída,  $b$  é o bias. Assim podemos também definir o produto interno  $\varphi^T(x_i)\varphi(x)$  que representa o produto interno de dois vetores induzidos no espaço de características pelo vetor de entrada  $x$ . Podemos representar o núcleo do produto como  $k(x, x_i)$  que é uma função simétrica a definida por  $k(x_i, x)$ . Desta forma pode-se construir o hiperplano ótimo no espaço de características sem considerar o próprio espaço de características de forma explícita, [1].

A exigência sobre o núcleo  $k(x_i, x)$  é que ele satisfaça o teorema de Mercer. Entretanto existe liberdade em como ele é escolhido. A três tipos comuns de máquinas de vetor de suporte que podem ser a máquina de aprendizado polinomial, a rede de fun-

ção base radial e o perceptron de duas camadas. Esse Kernels são mostrados na Tabela 1, [6].

Tabela 1 – Tabela de Kernel

Tipo de Kernel	Função $K(x_i, x_j)$	Parâmetros
Polinomial	$(\delta(x_i, x_j) + k)^d$	$\delta, k$ e $d$
Gaussiano	$\exp(-\sigma \ x_i - x_j\ ^2)$	$\sigma$
Sigmoidal	$\tanh(\delta(x_i, x_j) + k)$	$\delta$ e $k$

## 5 Redes Neurais versus SVM

Como os modelos matemáticos com capacidade de aproximação universal, como as redes neurais artificiais, não são dotados de algoritmos de treinamento capazes de maximizar a capacidade de generalização de uma forma sistemática, o que pode levar a um sobre-ajuste do modelo aos dados [3], ou seja, pode-se ainda, chegar a um mínimo local que não satisfaça as condições gerais de generalização de todo o sistema. As SVM, no entanto, tem um conceito diferente de minimização com um elemento superior aos erros de generalização, buscando no aprendizado estatístico a minimização que se chama de principio da minimização do risco estrutural e não diretamente o erro em si, ou seja, uma medida estatística que aproxime a probabilidade de classificação incorreta.

Outro ponto interessante a destacar é que as redes neurais incorporam em si conhecimentos sobre o domínio do problema. Essa não é a realidade das SVM, no entanto ela “armazena” nos vetores de suporte um valor de separação das classes do problema. Assim, uma planta que sofreu alterações, mas seu comportamento permaneça inalterado, poderia na sua classificação, apresentar erros quando usado uma RNA, mas não com uma SVM.

Sabendo-se que o Kernel sigmoidal (comparado com MLP) possui alguns valores de seus Kernel que não satisfaz o teorema de Mercer [5] e que os Kernels polinomiais são lineares, o que não acontece no caso das MLP, onde a função de ativação sigmoidal é não-linear e trata problemas lineares e não lineares. Foi utilizado neste trabalho o Kernel RBF ou Gaussiano dado na Tabela 1.

## 6 Metodologia

A metodologia deste trabalho baseia-se em um estudo comparativo obtido por Martins, [7], acrescentando a SVM como avanço da ferramenta de inteligência computacional. A busca de novas tecnologias e novas aplicações são constantes quando está se trabalhando com ferramentas empíricas e estatísticas como são as redes neurais e SVM, buscando sempre resultados

práticos que melhor se adequem ao caso real, e nesse caso a indústria de petróleo.

As dificuldades encontradas no tratamento dos sinais de pressão e vazão não serão comentadas nesse trabalho, pois têm ampla divulgação técnico-científica, mas podemos justificar o seu uso prático com: baixos custos de implantação, baixos custos de equipamentos (como sensores e transmissores), baixos custos operacionais, baixos custos com manutenção, ou ainda a facilidade de implantação, baixa influência de ruídos, entre outros. Ainda que para seu uso de maneira eficaz, seja necessária a combinação com uso de outras técnicas como a de processamento de sinais para extrair características destes sinais. Estes sinais, embora lentos quanto à propagação no meio, se comparados com outros, como por exemplo ultra-sônicos, ainda são utilizáveis com aplicação de vários sensores ao longo do duto para vencer esta dificuldade. Com relação à informação ou conhecimento do vazamento em si, podem-se utilizar técnicas inteligentes para exprimir resultados semelhantes à apresentação a um especialista, ou seja, substitui-se a presença humana baseada no conhecimento “aprendido” com o problema.

Utilizando a transformada *wavelet* processa-se os sinais de pressão, buscando-se os coeficientes do filtro passa alta, em busca das altas resoluções que caracterizassem o vazamento. Esses dados são antecipadamente tratados por filtros de maneira que a extração de características de vazamento seja o menos possível influenciado por ruídos. Seguindo esse processo têm-se então os chamados descritores, que apontam para comportamento de vazamento. Após exaustivos testes foi possível avaliar o comportamento de várias famílias de *wavelets*, entre elas as de *Daubechies*, *Coiflets*, *Symlets*, tanto na análise como na síntese à procura da melhor solução ao problema. Tomou-se como referência a qualidade e o aspecto visual na reconstrução do sinal e da visualização do vazamento em níveis de detalhamento ou escala. Todas as técnicas foram testadas empiricamente e a que apresentou melhores resultados foi a de *Coiflets*, que a partir de então será considerada como padrão quando se referir ao processamento com transformada *wavelet*.

Em seguida, apresenta-se à rede neural e a SVM para obter como saída o indicador de presença ou não de vazamento, -1 e 1, respectivamente. Vale salientar que no caso das redes neurais uma saturação é feita na saída de forma que se for maior que 0 (zero) considera-se 1 (um), senão, se for menor que 0 (zero), considera-se -1 (menos um). Os dados são processados através de janelas, e essas foram “montadas” com 120 amostras, sendo esse número variável, ou seja, é apenas um referência ao número de amostras por segundo que neste caso foi de 1, muito embora o recebimento de dados permita uma taxa de amostragem de até 20 amostras por segundo. O tempo de 2 minutos numa janela de processamento pode ser considerado aceitável quando se refere a um alarme de

vazamento, mas faz-se constar que esse tempo não é um valor fixo, podendo o algoritmo detectar vazamentos a partir das primeiras amostras da janela.

Para fins de treinamento e validação foi utilizada a técnica de validação cruzada, que consiste em separar os sinais de treinamento e outros de validação de modo que em cada validação um conjunto seja guardado que nunca tenha sido apresentado à rede. O quadro da Tabela 2 mostra esta idéia, onde T são as amostras de treinamento e V as amostras de validação.

T1	T2	T3	T4	V5
T1	T2	T3	V4	T5
T1	T2	V3	T4	T5
T1	V2	T3	T4	T5
V1	T2	T3	T4	T5

Tabela 2 – Validação Cruzada

Foram utilizadas 100 janelas com e sem vazamento, subdivididas aleatoriamente em cinco grupos de 40 padrões para assim fazer a validação cruzada, que é uma técnica de averiguação do aprendizado, quando existem poucos dados e é necessário garantir a generalização da rede. Os sinais utilizados neste treinamento, foram dados reais coletados em campo a partir de simulações de vazamentos com a abertura de válvulas de diâmetro de 1”, ½” e ¾” ao longo do duto U-E. Um exemplo de um sinal de pressão coletado junto a caixa de monitoração mais próxima de U pode ser visto na Figura 5.

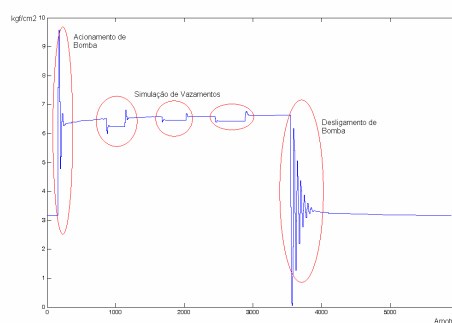


Figura 5 - Sinal de pressão coletado em campo com simulações de vazamento

Na Figura 6 temos um esquema gráfico do funcionamento do sistema após o treinamento da rede ou da SVM, onde o sinal original S é pré-processado por dois filtros: o primeiro da mediana, para remover os ruídos e um segundo de média, para remover o deslocamento da origem, ou os níveis DC, sem descaracterizar as informações presentes no sinal e facilitar a extração de características do sinal sem a influências dos ruídos, como pode ser visto na Figura 8. Nota-se

que o sinal filtrado tem sua amostragem aumentada devido a utilização de uma mediana com janela móvel e com intersecção entre elas. Em seguida é passado para o domínio da transformada através de um banco de filtros como mostra a Figura 1. Por fim faz-se uma autocorrelação em cada nível da transformada. E é apresentado a RNA e a SVM, para fazer os testes comparativos dos resultados.




Figura 6 – Metodologia de trabalho

Ambos os algoritmos aprendem a separar o que seria feito manualmente por um técnico, com conhecimento antecipado dos descritores e de seu comportamento no tempo.




Figura 7 – Visualização gráfica dos descritores




Figura 8 – Sinal de pressão normal e após filtragem com a mediana e a média

É possível observar, pela Figura 7, uma região de separação, onde ambos os algoritmos se prestarão a separar, plotando-se várias janelas dos descritores em sinais com e sem vazamento.

Para um melhor entendimento da estrutura da rede neural utilizada, pode-se citar de maneira sucinta a arquitetura, o algoritmo de treinamento, a função de ativação e comportamento da rede que são: MLP (*multilayer perceptron*), *backpropagation*, tangente sigmóide e classificador, respectivamente. No caso da SVM podemos citar o Kernel, e o parâmetro C que neste caso é Gaussiano e o valor de C usado foi

0,1 devido ao valor encontrado na amostragem do sinal.

Tabela 3 - descritores de treinamento

	Vazamento			
	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
r(1)	2,8006	1,2071	1,1848	0,8672
r(2)	7,0903	2,7140	3,0391	3,2559
r(3)	11,482	6,5882	2,7650	4,3505
Sem vazamento				
r(0)	0,0776	0,0540	0,0218	0,0137
r(1)	0,1421	0,1807	0,0867	0,0335
r(2)	0,4063	0,9072	0,3641	0,0786
r(3)	0,4996	3,3441	1,1245	0,1656

A Tabela 3 mostra que o uso combinado da transformada *wavelet* e de técnicas estatísticas, tais como autocorrelação, caracterizam bem as situações de vazamento e não vazamento, mesmo em regime transiente. Onde para cada nível (0,1,2,3) da transformada é extraído a assinatura do vazamento a partir da autocorrelação e da energia do sinal. A entrada das redes é exemplificada nas janelas (J). Os valores da tabela foram normalizados em  $10^{-3}$ .

A SVM tem seu classificador baseado no vetor de suporte. Na Figura 9 pode-se ver o treinamento da SVM usada neste trabalho onde os “quadrados” e o “x” em vermelho são os vetores de suporte e a linha preta o hiperplano ótimo. Em azul e em verde são superfícies de classificação limite de cada classe.

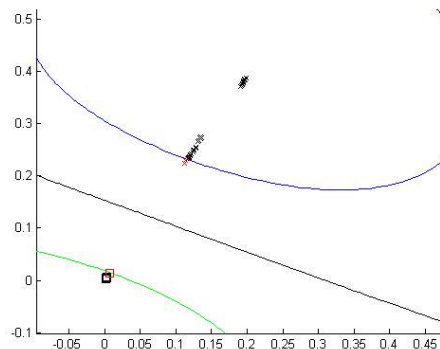


Figura 9 – Treinamento da SVM - Treinamento da SVM (azul/verde superfície de decisão das classes, Preto – espaço ótimo de separação e os pontos em vermelho são os vetores de suporte)

## 7 Resultados

Foram testadas diferentes arquiteturas para a rede neural e vários coeficiente C para SVM, sendo que a rede que apresentou melhores resultados, consistiu de 4 entradas, 16 neurônios na camada oculta e 1 neurônio na camada de saída, podendo ser esta, sintetizada por 4:16:1. A Tabela 4, mostra uma comparação entre os resultados de duas arquiteturas utilizadas. A

estrutura menor 4:8:1, que tem a vantagem de consumir menos processamento, teve melhor resultado no aprendizado de sinais sem vazamento, no entanto esse aprendizado ou sua generalização foi menor quando as amostras estavam com vazamento. Assim deu-se preferência a partir de então a utilização de uma estrutura maior 4:16:1, mas que apresentasse melhor generalização para os eventos com vazamento.

Tabela 4 - Comparação entre arquiteturas

Arquitetura / Época	% Acerto Sem Vazamento	% Acerto Com Vazamento
4:8:1 / 200	96	91
4:16:1 / 200	95	95

No caso da SVM como citado anteriormente o valor de  $C$  foi de 0,1, no entanto, a variação deste valor não pode ser um comparativo direto de alteração de arquitetura, mas sim no vetor de suporte. Assim sendo valores de  $C < 0,1$  fazem com que sejam criadas muitas superfícies de separação, como pode ser visto na Figura 10. E no caso de  $C > 0,1$  pode deixar a generalização comprometida, informando que as amostras de dados são equivalentes aos pontos do vetor de suporte, conforme Figura 11. Pode-se observar que o erro foi diminuído, para a situação de não apresentação de vazamento, sendo este considerado o pior caso de erro, onde o vazamento ocorreu 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 feita a média deles para os resultados abaixo:




Figura 10 - Superfície de separação com SVM treinada com  $C = 0,001$




Figura 11 - Superfície de separação da SVM com  $C=1000$

Outras arquiteturas foram testadas, mas as maiores não apresentaram melhoras quanto aos resultados e o tempo de processamento aumentou e no inverso, os resultados pioravam apesar da diminuição no tempo de processamento. No caso das SVM o tempo de treinamento é independente da escolha do  $C$ . É importante destacar que em cada janela é aplicada a transformada *wavelet* e extraídos os descritores. Na Tabela 5 e Tabela 7, temos a matriz de confusão onde é possível observar as situações de verdadeiro positivo e falso positivo em sinais coletados em campo.

Tabela 5 - Matriz de confusão da MLP

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

Os dados da Tabela 5 foram obtidas a partir de amostras de vazamentos simulados em vários diâmetros. Se considerado o maior deles, esses índices chegam ao percentual de 100% (cem por cento) de acerto. Numericamente os percentuais de erro são considerados baixos e comparativamente ao sistema atualmente instalado, pode-se considerar um grande avanço. No caso das SVM, Tabela 6, esse resultado é ainda melhor, no entanto é importante ressaltar que os percentuais obtidos são para a amostragem de sinais diminutos que podem representar grande parte do comportamento do duto. No entanto variantes de vazamentos podem não ter sido treinados, mas que com a colocação do sistema em campo serão “guardados” como assinaturas de vazamento.

Tabela 6- Matriz de confusão da SVM

	Indicação do vazamento	Não indicação do vazamento
Ocorrência vazamento	100,00 %	0,00 %
Não ocorrência do vazamento	0,00 %	100,00 %

## 8 Conclusões

Foi possível fazer uma comparação entre as dois algoritmos RNA e SVM e constatar que as SVMs possuem maior robustez e maior acurácia. A alteração e treinamento não implicam em grandes alterações no projeto, exceto o treinamento da própria rede. A substituição da primeira pela segunda se faz facilmente, substituindo apenas a parte lógica da rede conforme a Figura 6.

Os resultados, vistos na Tabela 6, podem trazer a impressão de que o sistema não tem erros, mas embora os sinais tenham sido feitos em simulações de campo, o sistema com a SVM ainda não foi utilizado em campo para definir parâmetros como percentuais de acerto e alarmes falsos.

A quantidade e a qualidade dos dados disponíveis governam o desempenho de ambas as redes. A quantidade diz respeito ao número de amostras e a qualidade ao quanto essas amostras representam o conjunto como um todo. Assim elas tiveram um bom desempenho dado a quantidade de amostras diminuta, mas considerar-se-á as amostras de boa qualidade para assim validar o sistema.

Assim técnicas de aprendizado baseadas em dados amostrados e sua condição de tratar computacionalmente um conjunto de dados finito, conduz a uma amostragem esparsa do espaço de entrada. Esse problema do aprendizado tende a ser mal condicionado, ou seja, o processo de indução de modelos não possui solução única. No entanto quando as soluções admissíveis são semelhantes têm-se aumentada a capacidade de generalização, [3].

## Referências Bibliográficas

- [1] Haykin, Simon, Redes Neurais – Princípios e prática, 2a edição, Porto Alegre, 2001.
- [2] Vetterli, M. and Herley, C., *Wavelets And Filter Banks: theory and design.*, IEEE Transactions on Signal Processing, Vol. 40, No. 9, Sept 1992.
- [3] Lima, Clodoaldo Aparecido de M., Comitê de Máquinas: Uma Abordagem Unificada Empregando Máquinas de Vetores-Suporte. Campinas, SP: [s.n], 2004.
- [4] Vapnik, V. N, Principles of risk minimization for learning theory, Advances in Neural Information Processing Systems, vol.4, San Mateo, CA: Morgan Kaufmann, 1992.
- [5] Mercer, J., Functions of positive and negative type and their connection with theory of integral equations. Philophical Transactions of the Royal Society, 1909.
- [6] Lorena, A. C., Investigação de estratégias para a geração de máquinas de vetores de suporte multiclases. Instituto de Ciências Matemáticas e de Computação. USP, São Carlos, 2006.
- [7] Martins, Rodrigo S., et al. Implementação de técnicas inteligentes para detecção de vazamentos em dutos em regime de escoamento multifásico crítico. CBRN, 2005.