



XII SEPOPE
20 a 23 de Maio 2012
May – 20th to 23rd – 2012
RIO DE JANEIRO (RJ) -
BRASIL

XII SIMPÓSIO DE ESPECIALISTAS EM PLANEJAMENTO DA OPERAÇÃO E EXPANSÃO ELÉTRICA

XII SYMPOSIUM OF SPECIALISTS IN ELECTRIC OPERATIONAL AND EXPANSION PLANNING

Redes Neurais Autoassociativas Aplicadas ao Diagnóstico de Falhas em Transformadores de Potência

V. MIRANDA	S. L. LIMA	A. R. G. CASTRO	O. R. SAAVEDRA
INESC TEC	UFMA	UFPA	UFMA
- INESC Tecnologia	Universidade	Universidade	Universidade
e Ciência	Federal do	Federal do	Federal do
e Universidade do	Maranhão	Pará	Maranhão
Porto			
Portugal	Brasil	Brasil	Brasil

SUMÁRIO

Os transformadores de potência cumprem um papel importante no fornecimento de energia elétrica, tornando necessário o monitoramento contínuo dos processos que possam provocar falhas de operação, que particularmente ocorrem no isolamento do equipamento. Os métodos previstos na IEC, IEEE e NBR para análise do gás dissolvido (AGD) não alcançam nível pleno de acerto, pois não consegue mapear com precisão as características de falhas à que cada conjunto pertence. Neste artigo é apresentada uma nova forma para diagnóstico de falhas em transformadores de potência baseado nos resultados obtidos através do AGD. Para isto, um conjunto de redes autoassociativas é treinado para identificar as condições de falha ou a condição normal. Contudo, devido ao pequeno número de dados obtidos para treino/teste foi usado o algoritmo *MeanShift* baseado na Teoria de Informação para a densificação dos conjuntos, permitindo que todos os dados reais fossem usados para o processo de validação. Quando uma nova entrada é apresentada, os modelos de redes autoassociativas em paralelo competem entre si e a rede que estiver mais bem sintonizada produz o menor erro, indicando assim, a falha. A precisão da rede para o diagnóstico de falhas tem obtido 100 % de acerto com esta arquitetura, no qual todos os dados reais foram usados.

PALAVRA-CHAVE

AGD, Diagnóstico de falhas, Método de Rogers modificado, Teoria da extensão, Transformadores de potência.

1. Introdução

O diagnóstico de falhas incipientes em transformadores de potência baseado em AGD [1] é uma técnica que tem sido bastante explorada, devido o alto custo relacionado a uma falha do equipamento. Este problema tem sido pesquisado e tratado através de várias normas, dentre as quais se destaca a IEC 60599 [2] e o artigo [3] que inclui a base de dados reais IEC TC10 de casos de falhas.

Baseado na AGD, tem sido proposta uma diversidade de técnicas para o diagnóstico de falhas, como sistemas especialistas [4], sistemas *fuzzy* [5], redes neurais artificiais (RNA) [6][7], redes wavelet [8], sistemas neuro-fuzzy [9], redes neurais RBF (*Radial Basis Function*) [10], máquina de suporte vetorial (SVM – *Support Vector Machines*) [11], mapas auto-organizáveis ou redes neurais de Kohonen [12].

Estes modelos supracitados utilizam as relações entre os gases (quocientes) para realizar o diagnóstico de falhas incipientes. Contudo, em alguns trabalhos os tipos de falhas são bastante limitados, enquanto que em outros a validade dos resultados é questionável, ou seja, as poucas amostras utilizadas não permitem observar uma boa generalização do método.

Outro problema abordado é a identificação de falha em transformadores com e sem OLTC (*On-load Tap Changers*), cuja ação causa a contaminação do óleo. Para estes casos existem poucas publicações que tratam do assunto, principalmente relacionando como um modelo de falha. Este tipo de questão é discutido na IEC 60599.

Neste artigo é descrito uma nova proposta para o problema de detecção e identificação de falhas em transformadores de potência através do uso de redes autoassociativas, o qual possibilitou um nível de acerto de 100 % com a base de dados de falhas que foi utilizada. Esta nova proposta permite indicar se o transformador encontra-se em estado normal ou em estado de falha e o tipo da falha.

O diagnóstico de falhas clássico, usando redes neurais, baseia-se em uma única rede que discrimina todos os tipos de falhas. A ideia apresentada neste artigo é assumir que os vetores que representam a concentração de gases dissolvidos se organizam em diferentes conjuntos (*clusters*). A determinação da condição normal/falha e o tipo da falha são realizados por um conjunto de redes autoassociativas que são treinadas para capturar as características de cada conjunto (*manifold*). Logo, quando as redes forem ativadas com uma nova entrada, aquela que estiver mais bem sintonizada terá o menor erro, enquanto que as demais deverão apresentar um maior erro entre entrada e saída.

Neste artigo também é introduzida uma novidade para superar o problema da falta de dados de treinamento, com a densificação do conjunto de dados através do algoritmo *Mean Shift* baseado na Teoria da Informação. Uma vez que os dados de AGD registrados na IEC TC10 são poucos, qualquer procedimento de validação teria que ser baseado em poucas amostras de casos. Com o novo procedimento chamado de ‘truque de densificação’, dados virtuais são criados de forma a serem compatíveis com o *cluster* original. Estes dados virtuais podem ser usados no treinamento das redes neurais com mais eficiência e precisão e os dados reais (*cluster* original) podem ser todos aproveitados no procedimento de validação.

2. Redes autoassociativas

As redes neurais autoassociativas, ou simplesmente *autoencoders*, são um tipo especial de rede neural *feedforward* treinada de forma a representar, na saída, os dados de entrada da rede. Um *autoencoder* com o treinamento apropriado é capaz de armazenar nos pesos a informação sobre um *manifold* não-linear. Uma vez treinada, a rede pode ser usada como máquina de reconhecimento de padrão, ou seja, uma vez que a composição do novo vetor de dados seja compatível com o *manifold* que foi aprendido, a rede irá reproduzir na saída um vetor com um pequeno erro relacionado à entrada. Da mesma forma, se o vetor de entrada for diferente do padrão de dados usados para treinar a rede, o *autoencoder* reproduzirá na saída um resultado bastante diferente da entrada, logo, o erro será maior.

O conceito de *autoencoder* é definido como uma rede que possui entrada e saída iguais, ou seja, com n neurônios e uma camada escondida com um distinto número de m neurônios. As primeiras aplicações deste tipo de rede neural estavam voltadas para a compressão de dados, portanto é comum encontrar na literatura redes com $m < n$ neurônios. Assim, da entrada para a camada escondida o *autoencoder*

faz uma eficiente compressão do espaço S para o espaço S' . Os dados comprimidos são armazenados em um pequeno vetor, cujas componentes são os valores da saída para os neurônios da camada escondida. Na transição da camada escondida para a camada de saída da rede é feita a descompressão e a informação armazenada é recuperada. Na é ilustrado o caso onde a dimensão de S é maior que S' , ou seja, $n > m$.




Figura 1 – A função f armazena dados da compressão e f^{-1} da descompressão.

As características obtidas na compressão/descompressão tem sido usadas para construir máquinas de compressão de dados [13][14][15][16]. Da mesma forma, a propriedade que um ponto sobre o manifold será corretamente projetado de trás para frente pelo treinamento do *autoencoder*, e um ponto fora do manifold não será corretamente projetado, produzindo um erro (ϵ) maior entre entrada e saída, também tem sido usado como padrão de reconhecimento e classificação e como um processo de detecção de novidade [17].

Para o treinamento das redes autoassociativas, os métodos usados são semelhantes a uma rede clássica *feedforward*, com algoritmo de retropropagação do erro (*backpropagation*) e gradiente descendente. Uma vez que o objetivo do treinamento é apenas otimizar a função de custo, pode-se adotar para isso o mínimo erro quadrático (*Minimum Square Error*) como em (1), no qual, se X é o vetor de entrada e Y o vetor de saída, em N amostras têm-se:

$$\text{MSE} : \min \epsilon = \frac{1}{N} \sum_{k=1}^N \|X_k - Y_k\|^2 \quad (1)$$

Os *autoencoders* possuem grande capacidade teórica em comprimir de dados com alta dimensão (milhares de entradas e dezenas de milhares de pesos a serem sintonizados), porém a prática tem mostrado que uma boa convergência é difícil, exigindo muitas tentativas, cuidado na escolha dos pesos iniciais e muitas épocas de treinamento. Alguns trabalhos têm proposto um treinamento incremental principalmente nos casos em que se utilizam redes autoassociativas com múltiplas camadas escondidas como em [13].

3. Algoritmo *Mean Shift* e densificação de *clusters*

O algoritmo *Mean Shift* é baseado na Teoria da Informação [18][19] e foi introduzido como uma forma de capturar a estrutura dominante em um conjunto de dados, presente em uma função densidade de probabilidade (fdp). A entropia quadrática de Renyi [20] é dada por

$$H(X) = -\log \int_{-\infty}^{+\infty} p^2(x) dx \quad (2)$$

na qual a fdp de X (variável aleatória) é estimada pela técnica de janelas de Parzen [21]:

$$\hat{p}(X) = \frac{1}{N} \sum_{i=1}^N G_{\sigma}(x - x_i) \quad (3)$$

sendo $G_{\sigma}(t) = e^{-\frac{t^2}{2\sigma^2}}$ o *kernel* gaussiano com largura $\sigma > 0$. Observa-se que fazendo (3) em (2) obtém-se

$$H(X) = -\log V(X) \quad (4)$$

em que V representa o potencial de informação da fdp de X , tendo $\sigma' = \sqrt{2}\sigma$:

$$V(X) = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N G_{\sigma'}(x_i - x_j) \quad (5)$$

Derivando (5) em relação a um ponto qualquer x_i obtém-se a quantidade de força de informação exercida por todas as partículas em x_i [22][23][24].

A entropia cruzada definida em (6) permite obter a informação mútua entre duas fdp, assim como definir o potencial de informação em (7).

$$H(X, X_0) = -\log V(X, X_0) \quad (6)$$

$$V(X, X_0) = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N G_{\sigma'}(x_i - x_{0j}) \quad (7)$$

Outro conceito importante é o de distância entre duas pdf p e q , sendo obtido através da definição de Cauchy-Schwartz

$$D_{CS}(X, X_0) = \log \left(\frac{\left(\int p^2(x) dx \right) \left(\int q^2(x) dx \right)}{\left(\int p(x)q(x) dx \right)} \right) \quad (8)$$

A distância de Cauchy-Schwarz pode exprimir-se em função das entropias própria e cruzada

$$D_{CS}(X, X_0) = -[H(X) + H(X_0) - 2H(X, X_0)] \quad (9)$$

O objetivo do algoritmo *Mean Shift* é encontrar um conjunto X que capture a estrutura de informação de um conjunto X_0 . Isto é realizado pelo duplo critério de minimização da entropia da fdp de X , enquanto se mantém a distância de Cauchy-Schwartz fixa em algum valor de k . Em (10) é definida uma formulação de um Lagrangeano $J(X)$ agrupando o objetivo e a restrição, no qual o coeficiente de Lagrange, tomado como um parâmetro λ fixo, representa um *trade-off* entre objetivo e restrição.

$$J(X) = \min H(X) + \lambda [D_{CS}(X, X_0) - k] \quad (10)$$

Ou seja, a solução é um compromisso entre a minimização da entropia e a conservação de uma certa separação entre X e X_0 .

Calculando a diferencial de $J(X)$ em relação a cada ponto x_i é possível definir uma regra que permite a transformação de X_0 dentro de outro conjunto em cada iteração $t+1$, fazendo uso da informação contida em cada fdp de X na iteração t , estimado em (3).

$$x_i^{t+1} = \frac{c_1 \sum_{j=1}^N G_{\sigma'}(\|x_i^t - x_j^t\|) x_j^t + c_2 \sum_{j=1}^N G_{\sigma'}(\|x_i^t - x_{0j}\|) x_{0j}}{c_1 \sum_{j=1}^N G_{\sigma'}(\|x_i^t - x_j^t\|) + c_2 \sum_{j=1}^N G_{\sigma'}(\|x_i^t - x_{0j}\|)}$$

$$\text{no qual } c_1 = \frac{(1-\lambda)}{V(X)} \text{ and } c_2 = \frac{2\lambda}{V(X, X_0)} \quad (11)$$

Esta regra funciona como se as partículas de informação, em um campo de informação potencial, se movessem sob influência da força de informação que é a derivada de (5).

Quando se faz $\lambda = 1$ em (11), o algoritmo gera as modas da fdp de X . Quanto λ é um valor entre 1 e 2, o algoritmo tende a criar x pontos que convergem para a curva principal dos dados. Para valores maiores que 2 para λ , os pontos gerados estarão concentrados ao redor da região de maior densidade da fdp. Além disso, cada geração de pontos x_i^t descreve a fdp $p(X^t)$ que retém a informação $p(X_0)$.

Cada ponto x_i^t ao longo de t iterações descreve um caminho de x_{i0} para a moda da fdp $p(X_0)$ ou para a curva principal do *cluster* de dados ou ainda para a região de alta densidade, dependendo do valor de λ que foi adotado. Pelo caminho, há uma sucessão de pontos $X_0, X^1, \dots, X^t$, que podem ser direcionados para perto ou para longe da moda, dependendo dos pontos seguirem na direção da força de informação $\partial V / \partial X$ como em (5), ou em direção contrária.

Esta característica é usada neste artigo como um novo processo para a densificação de *clusters* X_0 , através da recuperação dos pontos em cada iteração e o uso destes pontos como dados virtuais, porém compatíveis com a fdp original em certas das suas propriedades.

4. Diagnóstico com AGD em Transformadores de Potência

4.1. Modelos anteriores

A presença de gases dissolvidos no óleo de transformadores de potência é um fenômeno bem conhecido, sendo usado para monitorar a condição de isolamento do equipamento. A AGD é uma técnica poderosa que permite monitorar o estado do equipamento (normal ou falha), bem como a detecção de falhas incipientes.

Na Tabela I é apresentada a classificação dos tipos de falhas, descrita na Norma IEC 60599 [2]. As regras da Norma representam um importante avanço, apesar do fato de quando aplicadas para o conjunto de dados de falhas em transformadores da IEC TC10 [3] ainda ocorra um número de classificações equivocadas e um número de padrões não classificados (falhas não identificadas).

Tabela I: regras para diagnóstico de falhas - IEC 60559

Casos	Tipo de falha	$\frac{C_2H_2}{C_2H_4}$	$\frac{CH_4}{H_2}$	$\frac{C_2H_4}{C_2H_6}$
PD	Descarga parcial	NS	<0.1	<0.2
DL	Descarga de baixa energia	>1	0.1-0.5	>1
DH	Descarga de alta energia	0.6-2.5	0.1-1	>2
T1	Falha térmica – $T < 300^\circ C$	NS	>1 mas NS	<1
T2	Falha térmica $300^\circ C < T < 700^\circ C$	<0.1	>1	1-4
T3	Falha térmica – $T > 300^\circ C$	<0.2	>1	>4

Os seis tipos de falhas listadas na Tabela I estão associados com uma diversidade de casos contidos na base de dados. Este conjunto de dados publicados juntos com [3] incluem também a condição de não-falha, ou seja, o transformador em condição normal (valores típicos de operação), correspondendo a transformadores com e sem OLTC. Contudo, a maioria das pesquisas concentra esforços principalmente na discriminação do tipo de falhas identificadas na Tabela I e ignora a possível distinção entre casos normais.

A Figura 2 mostra como a Norma IEC 60599 tem dificuldades em identificar corretamente os modos de falha, por causa da definição "intervalar" usada. As zonas definidas para cada falha nem sequer são contíguas, pelo que podem aparecer casos fora das "caixas", classificados como não-identificados. Além disso, as superfícies de separação entre grupos são planos, o que não corresponde a uma correta separação dos dados reais e leva a diagnósticos equivocados.




Figura 2 – Zonas definidas pela Norma IEC 60599

Na Tabela II é apresentado um sumário com a dimensão dos conjuntos de dados usados e os resultados publicados por diferentes autores (N é a identificação para condição normal). Esta tabela não é exaustiva de todos os trabalhos publicados mas permite visualizar a evolução do estado da arte no diagnóstico com AGD. Nestes trabalhos foram usados tipos diferentes de conjuntos de dados, logo a análise apenas do percentual de acerto é uma medida que deve ser avaliada com cuidado. Pode ver-se que os casos reclamando maior taxa de acerto são dos que têm menor número de amostras para teste ou menor número de falhas identificadas, permitindo o questionamento da qualidade dos resultados ou da sua capacidade de generalização.

O trabalho reportado agora neste artigo é uma extensão de resultados preliminares anteriores [34][35], mantendo a precisão de 100 % de acerto, além de permitir a distinção entre estado normal e de falha e entre transformadores com e sem OLTC.

Tabela II: dados e resultados em outras publicações

Modelo	Ano	No. amostras		% de acerto		No. falhas
		Total	Teste	Treino	Teste	
[6] Y Zhang et al	1996	40	(?)	(?)	95	3+N
[4] Wang	1998	188 + 22	60	99.3 - 100	93.3 - 96.7	5+N
[25] HT Yang, CC Liao	1999	561	280	93.88	94.9	4+N
[26] Guardado et al	2001	69	33	100	100	5+N
[7] YC Huang et al	2003	220 + 600	0	95.12	---	4+N
[27] Castro, Miranda	2005	431	139	100	97.8	3
[9] Miranda, Castro	2005	318	88	100	99.4	5
[28] G Lv et al	2005	75	25	100	100	3+N
[29] WH Tang et al	2008	168	(?)	(?)	80	3+N
[30] LX Dong et al	2008	220	60	(?)	88.3	3+N
[31] MH Wang et al	2009	21	0	100	---	8+N
[32] SW Fei, XB Zhang	2009	142	(?)	(?)	94.2	3+N
[33] NAM Isa et al	2011	160	40	100	100	3+N
[34] [35] Castro, Miranda, S. Lima	2011	318	88	100	100	5
[36] K Bacha et al	2012	94	30	(?)	90	6+N

4.2. Treinamento das redes e uso do truque de densificação

Para treinamento das redes neurais dispôs-se de um banco de dados IEC TC10 [3] e de dados suplementares fornecidos por empresas concessionárias do setor elétrico. As amostras contêm informações sobre a concentração de gases dissolvidos (H_2 , CH_4 , C_2H_2 , C_2H_4 , C_2H_6) e desta forma é verificado a condição do transformador. A Tabela III indica o número de casos disponíveis para cada modo de falha do transformador.

Tabela III: grupo de amostras reais para treinamento e validação

	Condição falha/normal	Nº de amostras (real)
T1	Falha térmica – $T < 300^\circ C$	77
T2	Falha térmica – $T > 300^\circ C$	71
PD	Descarga parcial	30
DL	Descarga de baixa energia	37
DH	Descarga de alta energia	103
H0	Estado normal (sem OLTC)	20
H1	Estado normal (com OLTC)	14
	TOTAL	352

Para treinamento de uma rede neural para cada modo de falha, a maior parte dos conjuntos de dados tem dimensão excessivamente reduzida. Por isso, enriqueceu-se cada conjunto com 200 dados virtuais, gerados pelo algoritmo de *Mean Shift* em sucessivas iterações, tendo sido produzidos 1400 novos pontos virtuais.

A Figura 2 mostra, como exemplo, a projeção 2-D do *cluster* em 3-D do processo de densificação de dados gerado pelo *Mean Shift* para a falha do tipo T2 (falha térmica), representado em amarelo pelo conjunto original e em vermelho pelos novos pontos virtuais. Há um óbvio povoamento do *cluster*, e graças ao *Mean Shift* esse povoamento conserva certas propriedades da fdp que descreve o *cluster*.

Também se pode ver na mesma figura, numa visualização 3D, o efeito conseguido na densificação do *cluster* da falha do tipo DH (falha por descarga de alta energia).




Figura 2 – Esquerda: densificação do cluster da falha T2 – projeção 2D dos resultados e sucessivas iterações. Direita: densificação do cluster da falha DH – visualização 3D. Parâmetros: $\lambda=1$ e $\sigma=0.1$.

Este truque de densificação permite ter dados suficientes para o treinamento da rede neural. Os dados virtuais foram usados para formar o conjunto de treinamento da rede neural e todos os dados reais

puderam ser incluídos no conjunto de teste e aproveitados para validar o modelo. Trata-se de um procedimento geral, não é específico do problema de diagnóstico em transformadores – é um recurso para todo o tipo de problema em que se tem escassez de dados e é válido desde que os dados existentes, embora poucos, sejam representativos. Por causa da lógica do *Mean Shift*, em cada sucessiva iteração é criado um conjunto de dados que tem a mesma propriedade comum com os dados originais X_0 , pelo que o somatório dos sucessivos conjuntos $X_1, X_2, \dots, X$ induz uma fdp com ainda a mesma propriedade. O treinamento de uma rede neural com esta união de conjuntos torna muito mais efetivo o processo e, além disso, preserva todos os dados reais X_0 para validar o modelo neural.

5. Diagnóstico com redes autoassociativas

Todo o *autoencoder* é treinado para armazenar na matriz de pesos as características de um modo de falha. Depois, os sete *autoencoders* (dois para condição normal com e sem OLTC e cinco para os outros tipos de falhas) são colocados em paralelo para competir entre si, conforme a Figura 3. Desta forma, quando as redes forem ativadas por uma nova amostra (não classificada), apenas o *autoencoder* que estiver mais bem sintonizado apresentará um erro pequeno, enquanto os demais mostrarão um erro grande entre entrada e saída. Isso permite identificar a que cluster pertence o novo vetor e, assim, classificar o tipo de falha. É uma arquitetura competitiva entre redes autoassociativas.




Figura 3 – Arquitetura completa do sistema de diagnóstico com competição entre os *autoencoder*.

O sistema proposto utiliza *autoencoders* com a arquitetura 3-15-3, com mais neurônios na camada escondida e função de ativação sigmóide. Para a validação das redes autoassociativas, o erro foi calculado através de (1). A função de ativação usada entre a camada de entrada e a camada escondida foi do tipo sigmóide e linear para a camada de saída. Foi usado como algoritmo de treinamento o Levenberg-Marquardt implementado em Matlab, com o cuidado de evitar cair em soluções triviais.

Na Tabela IV estão os resultados da validação com os dados reais, após o treinamento (incluindo estado de falha ou normal) e a comparação com o uso da norma IEC 60559. É possível observar que a total discriminação foi alcançada em todos os dados reais, pois foram obtidos 100 % de acerto com todos os dados, incluindo a identificação para transformadores em estado normal com e sem OLTC.

Uma informação importante no novo sistema desenvolvido é notar que não houve erros ou má classificação dos dados (352 acertos em 352 casos). Esses resultados com 100 % de acerto não eram totalmente inesperados, pois já tinha sido apontado em [34]. Além disso, com o uso do truque de densificação baseado no algoritmo *Mean Shift* (teoria da informação), todos os casos reais foram absolutamente testados.

Tabela IV: comparação da precisão do diagnóstico na discriminação do tipo de falha

Modelo	% identificação de falhas		Nº total de casos não identificados ou casos com erro no diagnóstico
	Treinamento (virtual)	Teste (real)	
Miranda-Castro-Lima	100 %	100 %	0
IEC 60599	93.00%	95,28%	85 do total (15 nos dados reais)

O resultado comparativo da aplicação da IEC 60559 indica que o conjunto de validação não era fácil de diagnosticar e a forma retangular (como é induzido pela aplicação da norma) não é o caminho mais conveniente para encapsular ou representar os *clusters* associados com os diversos tipos de falhas.

O novo sistema apresenta superioridade em relação à IEC 60559, sendo melhor que os resultados abordados e sumarizados na Tabela II. Ainda em relação à IEC, o modelo do *autoencoder* foi capaz de resolver e identificar corretamente todos os casos considerados indecisos. O resultado ótimo de 100 % mostrado é de fato notável, e isto pode ser explicado pela capacidade do *autoencoder* em aprender um específico *manifold* de um específico conjunto ou *cluster* de dados.

6. Conclusão

O problema do diagnóstico de falhas em transformadores de potência, quando do uso de monitoramento dos gases dissolvidos no óleo, obtém um importante avanço com o trabalho apresentado neste artigo. O sistema proposto é composto de um conjunto de redes neurais autoassociativas competitivas, que tem conseguido obter 100 % de acerto no diagnóstico para ambos as condições, estado normal com e sem OLTC e estado de falha (térmica ou elétrica).

As novidades registradas nesse trabalho são três:

- Primeiro, uso de competitivas redes autoassociativas sensibilizadas para o cada tipo de falha;
- Segundo, a capacidade de reconhecimento do estado normal e a discriminação do tipo de falha, todos no mesmo sistema de diagnóstico;
- E por último, a ideia de usar o algoritmo *Mean Shift* baseado em teoria da informação, para densificar o *cluster* de dados, permitindo que os dados reais sejam todos usados para teste/validação do sistema.

O truque de densificação é de aplicação geral mas tem uma importância especial quando há poucos dados. Por exemplo, as redes autoassociativas adotadas neste trabalho necessitam a sintonização de 150 parâmetros (pesos) cada, mas muitos dos *clusters* de dados têm poucas amostras (14 no menor conjunto). O uso do truque de densificação permitiu o treinamento das redes com 1400 pontos virtuais, reservando os 352 casos reais para a validação do modelo.

A arquitetura usada, de redes competitivas, apresenta algumas vantagens sobre uma simples rede neural com o mesmo objetivo de diagnóstico. Porém, cada módulo pode ser treinado independente e, portanto, o conhecimento de um novo dado para um determinado tipo de falha somente terá impacto no re-treinamento de um único componente, enquanto o comportamento de todos os outros módulos permanecerá intacto. O fato de que será necessário um treinamento a mais da rede neural torna-se irrelevante, dado que este processo ocorre *off-line* e o tempo de treinamento envolvido é de apenas alguns poucos minutos.

Com a solução proposta, conseguiu-se, na verdade, uma precisão de diagnóstico notável e o trabalho tem um elevado potencial de utilidade para empresas concessionárias e fabricantes de transformadores.

Agradecimentos

Este trabalho é financiado por Fundos FEDER através do Programa Operacional Fatores de Competitividade – COMPETE e por Fundos Nacionais através da FCT – Fundação para a Ciência e a Tecnologia no âmbito do projeto LASCA PTDC/EEA-EEL/104278/2008 e do projeto GEMS PTDC/EEA-EEL/105261/2008, ambos financiados pelo FCT, Portugal.

Shigeaki Lima foi bolsista do CNPq (Brasil) durante a execução deste trabalho no INESC TEC, em Portugal.

REFERÊNCIAS

- [1] ANSI/IEEE Std C57.104.1991, IEEE Guide of gases generated in oil-immersed Transformer, IEEE Power Engineering Society, 1992.
- [2] IEC Publication 60599, “Interpretation of the analysis of gases in transformers and other oil-filled electrical equipment in service”, March 1999.
- [3] M. Duval and A. Pablo, “Interpretation of Gas-in-oil Analysis using new IEC Publication 60599 and IEC TC10 Databases”, IEEE Electrical Insulation Magazine, vol. 17, no. 2, pp. 31–41, March/April 2001.
- [4] Z. Wang, Y. Liu, and P. J. Griffin, “A combined ANN and expert system tool for transformer fault diagnosis”, IEEE Transactions on Power delivery, vol.13, pp. 1224–1229, October 1998.
- [5] K. Tomsovic, M. Tapper and T. Ingvarsson, “A Fuzzy Information Approach to Integrating different Transformer Diagnostic Methods”, IEEE Transactions on Power Delivery, vol. 8, no. 3, pp. 1638–1644, July 1993.
- [6] Y. Zhang, X. Ding, Y. Liu and P. J. Griffin, “An Artificial Neural Approach to Transformer Fault Diagnosis”, IEEE Transactions on Power Delivery, vol. 11, no. 4, pp 1836–1841, Oct. 1996.
- [7] Y.-C. Huang. “Evolving Neural Nets for fault Diagnosis of Power Transformer”, IEEE Transactions on Power Delivery, vol. 18, no. 3, pp 843–848, July 2003.
- [8] L. Honglei, X. Dengming and C. Yazhu, “Wavelet ANN Based Transformer Fault Diagnosis Using Gas-in-Oil Analysis”, in *Proc. of the 6th International Conference on Properties and Applications of Dielectric Materials*, 2000, pp. 147–150
- [9] A. R. G. Castro and V. Miranda, “Improving the IEC Table for Transformer Failure Diagnosis with Knowledge Extraction from Neural Networks, IEEE Transactions on Power Delivery, vol. 20, pp. 2509–2516, Oct. 2005.
- [10] J. P. Lee, D. J. LEE, P. S. Ji, J.Y. Lim and S. S. Kim, “Diagnosis of Power Transformer Using Fuzzy Clustering and Radial Basis Function Neural Network”, 2006 International Joint Conference on Neural Networks, pp. 1398–1404, July 2006
- [11] D-H Liu, J.-P. Bian and X.-Y. Sun, “The Study of Fault Diagnosis Model of DGA for Oil-Immersed Transformer Based on Fuzzy Means Kernel Clustering and SVM Multi-Class Object Simplified Structure”, in *Proc. of the Seventh International Conference on Machine Learning and Cybernetics*, Kunming, July, 2008, pp. 12–15.
- [12] K. F. Thang and R. K. Aggarwal, “Analysis of Power Transformer Dissolved Gas Data Using the Self-Organizing Map”, IEEE Trans. on Power Delivery, vol. 18, no. 4, pp. 1241, Oct. 2003.
- [13] G. E. Hinton and R. R. Salakhutdinov, “Reducing the Dimensionality of Data with Neural Networks”, *Science*, Vol. 313, no. 5786, pp. 504 – 507, July 2006
- [14] G.W. Cottrell, P. Munro and D. Zipser, “Learning internal representations from gray-scale images: An example of extensional programming”, *Proceedings of the Ninth Annual Conference of the Cognitive Science Society*, Seattle (WA), USA, 1987
- [15] M.K. Fleming, G.W. Cottrell, “Categorization of faces using unsupervised feature extraction”, *Proceedings of IJCNN - International Joint Conference on Neural Networks*, vol. 2, pp. 65-70, San Diego (CA), USA, 17-21 Jun 1990
- [16] B. Golomb and T. Sejnowski, “Sex Recognition from Faces Using Neural Networks”, in A. Murray (ed.), in *Applications of Neural Networks*, pp. 71-92, Kluwer Academic Publishers, 1995
- [17] B. B. Thompson, R.J. Marks II, J.J. Choi, M.A. El-Sharkawi, M.Y. Huang and C. Bunje , “Implicit learning in autoencoder novelty assessment”, *Proceedings of the 2002 International Joint*

- Conference on Neural Networks*, 2002, IEEE World Congress on Computational Intelligence, Honolulu (Hawaii), USA, pp. 2878-2883, May12-17, 2002.
- [18] Sudhir Rao, Allan de Medeiros Martins, Weifeng Liu, Jose C. Principe, "Information Theoretic Mean Shift Algorithm", *Intl. Work. on Neural Networks for Signal Processing*, Maynooth, Ireland, pp. -, 9 2006
 - [19] Sudhir Rao, Allan de Medeiros Martins, Jose C. Principe, "Mean shift: An information theoretic perspective", *Pattern Recognition Letters*, no. 30, pp. 222–230, 2009.
 - [20] A. Renyi, "Some Fundamental Questions of Information Theory", *Selected Papers of Alfred Renyi*, vol 2, pp. 526-552, Akademia Kiado, Budapest, 1976.
 - [21] E. Parzen, "On the estimation of a probability density function an the mode", *Annals Math Statistics*, vol 33, 1962.
 - [22] J. C. Principe and D. Xu "Information-theoretic learning using Renyi's quadratic entropy", in J.-F. Cardoso, C. Jutten, and P. Loubaton, editors, *Proceedings of the First International Workshop on Independent Component Analysis and Signal Separation*, Aussois, France, pp. 407- 412, 1999.
 - [23] D. Erdogmus and J. C. Principe, "Generalized Information Potential Criterion for Adaptive System Training", *IEEE Transactions on Neural Networks*, vol. 13, no. 5, September 2002, pp. 1035-1044
 - [24] R.A. Morejon, J.C. Principe, "Advanced search algorithms for information-theoretic learning with kernel-based estimators", *IEEE Transactions on Neural Networks*, vol. 15(4), pp. 874 - 884, July 2004
 - [25] H-T Yang and C-C Liao, "Adaptive Fuzzy Diagnosis System for Dissolved Gas analysis of Power Transformers", *IEEE Transactions on Power Delivery*, Vol 14, N°. 4, pp. 1342-1350, October 1999.
 - [26] J.L Guardado, J.L Naredo, P. Moreno, adn C.R. Fuerte, "A Comparative study of neural networks efficiency in power transformers diagnosis using dissolved gas analysis", *IEEE Transactions on Power delivery*, Vol. 16, pp 643-647, October 2001.
 - [27] A. Castro and V. Miranda, "Knowledge Discovery in Neural Networks with Application to Transformer Failure Diagnosis", *IEEE Transactions on Power Systems*, Vol. 20, no.2, pp. 717-724, May 2005
 - [28] G. Lv, H. Cheng, H. Zhai, L. Dong, "Fault diagnosis of power transformer based on multi-layer SVM classifier", *Electric Power Systems Research* , Volume 75 , Issue 1 , Pages 9-15, July 2005
 - [29] W. H. Tang, J. Y. Goulermas, Q. H. Wu, Z. J. Richardson and J. Fitch, "A Probabilistic Classifier for Transformer Dissolved Gas Analysis With a Particle Swarm Optimizer", *IEEE Transactions on Power Delivery*, Volume 23, Issue 2, pp. 751-759, April 2008
 - [30] L. Dong, D. Xiao, Y. Liang, Y. Liu, "Rough set and fuzzy wavelet neural network integrated with least square weighted fusion algorithm based fault diagnosis research for power transformers", *Electric Power Systems Research*, Volume 78, Issue 1, pp. 129-136, January 2008
 - [31] M.H. Wang, Y.F. Tseng, H.-C. Chen, K.H. Chao, "A novel clustering algorithm based on the extension theory and genetic algorithm", *Expert Systems With Applications* , Volume 36 , Issue 4 , pp. 8269-8276, May 2009
 - [32] S.W. Fei, X.B. Zhang, "Fault diagnosis of power transformer based on support vector machine with genetic algorithm", *Expert Systems with Applications*, Volume 36 , Issue 2, pp. 11352–11357, 2009
 - [33] N.A.M. Isa, W.M.F.W.Mamat, "Clustered-Hybrid Multilayer Perceptron network for pattern recognition application", *Applied Soft Computing Journal* , Volume 11 , Issue 1 , Pages 1457-1466, January 2011
 - [34] A. Castro, V. Miranda and S. Lima, "Transformer fault diagnosis based on autoassociative neural networks", *ISAP 2011, 16th International Conference on Intelligent Systems Applications to Power Systems* , Crete, Greece, Sep 2011
 - [35] A. Castro and V. Miranda, "Sistema Inteligente para Diagnóstico de Faltas Incipientes em Transformadores baseado em Redes Neurais Auto-Associativas" (in Portuguese), *Proceedings of SBSE 2010 – Simpósio Brasileiro de Sistemas Elétricos*, Belém (PA), Brasil, May 2010

- [36] K. Bacha, S. Souahlia, M. Gossa, "Power transformer fault diagnosis based on dissolved gas analysis by support vector machine", *Electric Power Systems Research*, Volume 83, Issue 1, pp. 73–79, February 2012 (on-line preview).