

Análise de Componentes Independentes para Extração Cega de Ruídos Gaussianos dos Sinais de Descargas Parciais em Equipamentos de Alta Tensão

Walter M. Cuenca^{1,2}, Alain F. Levy¹, José M. Seixas², Sandoval Carneiro Jr²

¹CEPEL/ACET, PO Box 68007 CEP 21941-590 Rio de Janeiro – Brasil

²COPPE/EE/UFRJ C. P. 68504, CEP 21945-970 Rio de Janeiro – Brasil

{martin, alain}@cepel.br, seixas@lps.ufrj.br, sandoval@dee.ufrj.br

Abstract

In this paper is presented an approach for the problem of noise removal from partial discharges (PD) signals, using recent and well established concepts of Blind Source Separation (BSS) and Independent Component Analysis (ICA). It is showed that the ICA methods can be applied to PD signals characterization, arriving to a satisfactory solution for separation and/or elimination of noise from original signals. The original signals can be some defects coming from aged stator bars windings or from several other kinds of defects coming from insulated systems inside power transformers and hydrogenerators, among others.

1. Introdução

O atual cenário do mercado elétrico em vários países, desregulamentação e privatização, trouxe novos desafios, visando maior utilidade e redução nos custos de manutenção dos equipamentos. Neste cenário complexo, ressurgem conceitos como: condição de monitoração, administração do tempo de vida de equipamentos e qualidade de informação. Os níveis de manutenção se tornaram indicadores de reestruturação e qualidade gerencial nas empresas concessionárias de energia elétrica. A redução da manutenção a níveis ótimos deve ser uma busca contínua em cada empresa. Para este propósito, administrar o tempo de vida e o tempo entre manutenções dos equipamentos de alta tensão (geradores, transformadores, etc.) devem ser imposições para novas condições de serviço.

Essas novas condições somadas ao forte crescimento da demanda fazem com que os equipamentos de potência trabalhem com sobrecarga por longos períodos de tempo, aumentando os riscos de falha, degradando seus materiais isolantes, causando a perda acelerada de suas propriedades elétricas e mecânicas. Estes e outros fatores contribuem para uma possível formação de descargas parciais (PD).

As PD são sucessões de descargas elétricas incompletas, rápidas e intermitentes, da ordem de nanosegundo (ver Figura 1 (a)), que ocorrem pela proximidade entre duas partes condutoras de eletricidade e um meio isolante, pelo efeito de ionização em cavidades gasosas no interior dos materiais isolantes sólidos e lí-

quidos. Tais descargas também podem ocorrer na zona de contato de isolantes sólidos (dielétricos) e superfícies metálicas submetidas à elevada tensão elétrica [1-4].

A detecção de PD é um dos meios altamente solicitados para testar a confiabilidade dos equipamentos de alta tensão, como geradores. Medição de PD é uma das mais importantes ferramentas para detectar imperfeições nos isolamentos, sendo indicador de formação de cavidades gasosas na isolação do enrolamento.

A realização de uma medição de PD nos geradores e transformadores é dificultada por ruídos externos e internos no equipamento, além da complexidade de seus circuitos, altamente indutivos e/ou capacitivos. Estas características afetam os sinais de PD, contribuindo na sua deformação e atenuação. Os ruídos se propagam facilmente através dos equipamentos por condução e/ou irradiação tendo, às vezes, amplitudes maiores que os sinais de PD [2] e [4].

Novas ferramentas e técnicas vêm sendo adaptadas para tratar a informação obtida de uma medição de PD, algumas sofisticadas fornecendo novas e melhores formas de representações da PD, como nas Figuras 1 (b) e (c). Entre as técnicas mais solicitadas está o reconhecimento de padrões de PD, feito a partir de modelos experimentais descritos em [1] e [5].

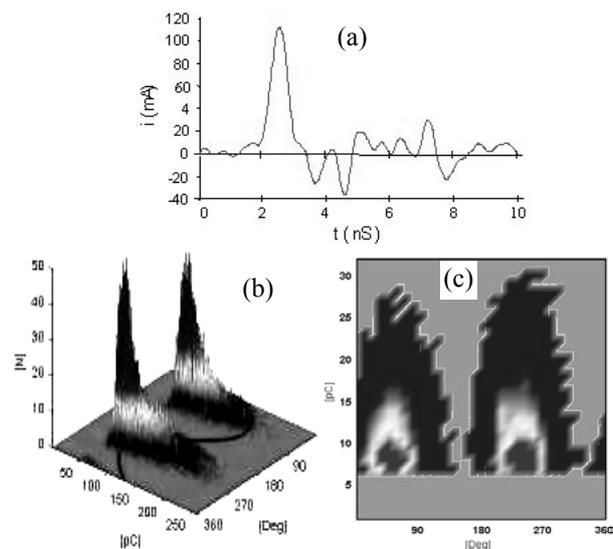


Figura 1: Sinais de PD: (a) Pulsos intermitentes medidos em UHF, (b) PD em 3-D (detalhes descritos mais à frente) e (c) mapa característico de PD.

Os procedimentos de medição e calibração do equipamento estão descritos nas referências [3-5]. O ICM converte os sinais elétricos em sinais digitais na forma de mapas desenvolvidos na fase da tensão aplicada [5], os quais têm a particularidade de relacionar a amplitude, ângulo de fase e taxa de repetição ($\phi, q, [N]$) mostrado de forma bidimensional na Figura 1 (c). Neste caso, a $c [N]$ é codificada em cores normalizadas (16 cores), as amplitudes (q) (vertical '[pC]') são picos máximos dos pulsos de descargas atingidos a partir de janelas ajustadas em 20 μ s de duração e (ϕ) (horizontal '[Deg]') é o ângulo de fase da tensão onde se desenvolvem as descargas. O instrumento de medição "ICM System", da Power Diagnostix Systems, foi um dos utilizados para todas as atividades experimentais realizadas. Este instrumento emprega a técnica de medição de carga aparente, especificada na norma IEC 270 e IEEE P1434 [5].

1.1. Modelos Experimentais

A Figura 2 (a) mostra a composição do enrolamento estático do gerador onde cada fase é composta por um conjunto de barras semelhantes às da Figura 2 (b).

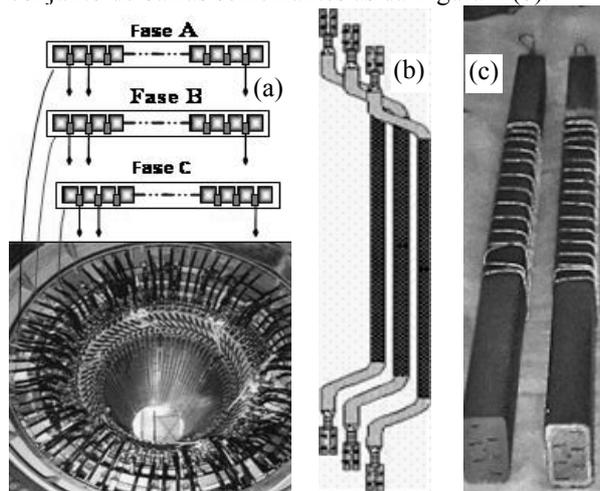


Figura 2: Enrolamentos e barras: (a) enrolamentos estáticos do gerador, (b) barras de enrolamentos e (c) barras com defeitos implantados para ensaios de PD.

Foram preparadas algumas amostras de barras, de aproximadamente um metro de comprimento cada, nas quais foram reproduzidos defeitos característicos, conhecidos na literatura [4] e [6], similares aos encontrados naturalmente em geradores e motores defeituosos com descargas em estágios mais avançados. A finalidade destas amostras é reproduzir PD localizadas com conhecimento a priori, com a vantagem que estas sejam provavelmente o mais próximo da realidade, sendo imunes a algumas interferências existentes numa subestação, onde existem acoplamentos de equipamentos vizinhos em operação que dificultam a obtenção do sinal real [6]. Alguns destes modelos são mostrados na Figura 2 (c).

O Centro de Pesquisas de Energia Elétrica (CEPEL), analisou oito fontes de sinais de PD provenientes dos ensaios e medições rotineiras em geradores da usina Itaipu [6]. Destas, três são fontes características (Tabela 1 '*') e as outras são diversas combinações no posicionamento dos capacitores de acoplamento (ver Figura 3.), nível de tensão aplicada, faixas de frequência de medição e posicionamento das barras defeituosas ao longo da fase C.

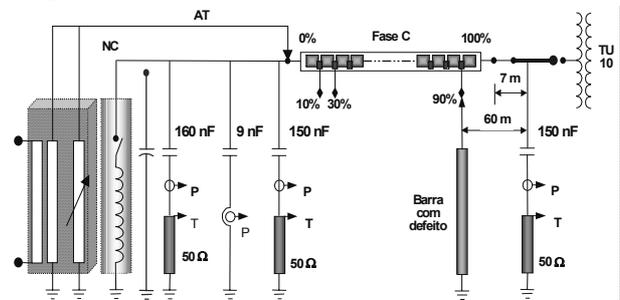


Figura 3: Estratégia e configuração das medições na fase C no gerador U10 na usina Itaipu. Onde: AT (alta tensão), NC (cubículo de neutro), P (acoplador de 9nF) e T (acoplador de 150nF-fase e 160nF-neutro) [6].

As medições de PD foram armazenadas na forma binária e representadas pela matriz $[P]$ ($\phi, q, [N]$) de dimensões $(n_0)^2$, sendo convenientemente transladada a uma resolução de dimensões $(m_0)^2$ (matriz $[R]$, $m_0 < n_0$). A redução de resolução tem a finalidade de diminuir o esforço computacional sem causar grandes perdas das características originais e pode ser expressa como: $[P] \rightarrow \Re^{n_0 \times n_0} \rightarrow [R] \rightarrow \Re^{m_0 \times m_0}$, $n_0 = 256$ e $m_0 = 32$. As fontes de sinais utilizadas neste artigo adotam os critérios assumidos acima e podem ser observadas na Figura 4.

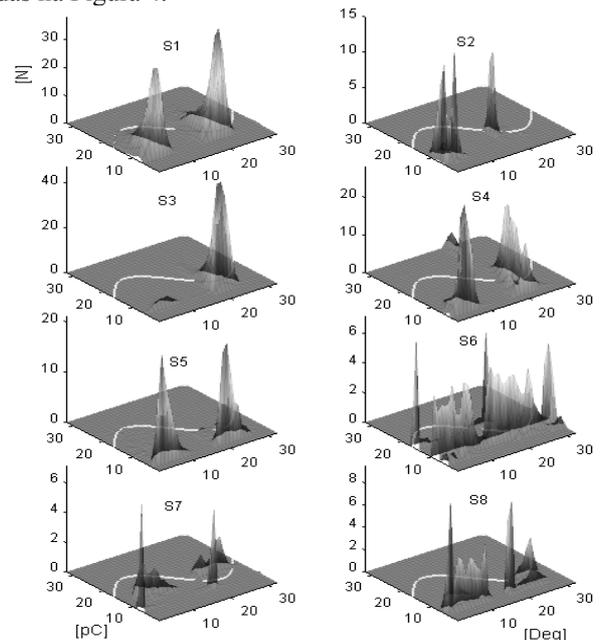


Figura 4: Fontes de PD provenientes das medições no gerador U10 da usina Itaipu (ver Tabela 1), onde "[N]"

é a taxa de acumulação, a amplitude da descarga "q" em [pC] e o ângulo de fase "φ" da tensão de referência [Deg].

Tabela 1: Fontes de sinais de PD

Sinal	Fonte de sinal (em 10,5kV)
S1	Sistema: capacitor de acoplamento/ barra. 150nF, conj.siemens + 9nF + barra + 2uF
S2	Barra 1 (slot)*
S3	Barra 2 (corona)*
S4	Barra 2 (corona na cabeça da bobina)
S5	Barra 3 (delaminacão)*
S6	tiristor fase B
S7	tiristor fase C
S8	tiristor neutro

1.2. Separação Cega de Fontes

O ruído em medições de PD sempre foi um obstáculo para se conhecer características típicas das fontes. Esforços empreendidos pela comunidade científica resultaram em métodos de eliminação, redução até modelagem de sinais de ruído. Muitos destes métodos têm como fundo tratamento estatístico e/ou filtragem de bandas [7-9]. Na última década, outras ferramentas foram reativadas e melhoradas tais como: filtros adaptativos baseados em wavelets, teoria de separação de fontes, teoria da informação, sistemas artificiais inteligentes e a análise estatística de ordens elevadas. Atualmente novos esforços vêm sendo ativados empregando sistemas híbridos para tratamentos de ruído. Os resultados, genericamente, foram bons o bastante para casos particulares e isolados. Por sua vez, a chamada separação cega de fontes (Blind Source Separation - BSS), junto com a Análise de Componentes Principais (ICA) abriram novos caminhos e sua aplicabilidade é crescente em diversos campos.

O BSS tem se tornado uma das principais áreas de pesquisa em processamento de sinais, principalmente devido ao seu potencial crescente de aplicações para muitos problemas reais. Um bom número de algoritmos baseado em teoria ICA vem fornecendo soluções aos problemas BSS e vem sendo aplicados com sucesso em diversos campos, tais como: sistemas de comunicação, processamento de imagens, radar-sonar, processamento de sinais biomédicos e processamento de sinais de PD [7].

O propósito de um BSS é recuperar um conjunto de sinais fontes independentes (fontes), a partir de um conjunto de sinais misturados (observações), extraídos pelos sensores de medição. O termo cego indica que as fontes e a maneira como estas foram combinadas são desconhecidas. ICA é um método para resolver o problema BSS, que, além de decorrelatar os sinais (estatística de segunda ordem), também reduz a dependência de estatísticas de ordens superiores.

2. Apresentação do Problema

Cada matriz reduzida $[\mathbf{R}]_{32 \times 32}$ pode ser disposta na forma vetor observação $\mathbf{x}(k)$ de tal forma que:

$$\mathbf{x}(k) = [x_1(k), \dots, x_n(k)]^T \quad (1)$$

Onde, $n = 1024$ e k indica a k -ésima amostragem tal que,

$$\mathbf{x}_i(k) = \sum_{j=1}^N a_{ij} s_j(k) + \boldsymbol{\eta}_i(k), \quad 1 \leq i \leq 8 = N,$$

($N = 8$ é o número de observações), $\mathbf{X} = \mathbf{AS} + \boldsymbol{\eta}$ (2)

sendo \mathbf{A} uma matriz escalar $N \times N$ não singular, desconhecida mas invariante a transformações, \mathbf{X} composto por 8 vetores observações $\boldsymbol{\eta}(k)$ é o vetor ruído assumido de média nula e variância v_{ij} e, $s(k)$ é o vetor de fontes de sinais independentes composto de 1024 amostras,

$$s(k) = [s_1(k), \dots, s_m(k)]^T, \quad (m = 1024),$$

$$\text{Tal que, } \mathbf{S} = [s(1), \dots, s(8)]^T \quad (3)$$

O objetivo do ICA é estimar a matriz \mathbf{A} ou sua inversa, expressa como [7] e [8]:

$$\mathbf{y}(k+1) = \mathbf{W}_k \mathbf{x}(k+1), \quad \mathbf{W}_k = A_k^{-1} + \varepsilon A_k^{-1} A_k^{-T} A_k^{-1} \quad (4)$$

onde ε é um valor real (ex. $\varepsilon = v_{ij}$).

O ICA com restrições não-holonômicas, desenvolvido por Amari et al. [7] e Akuzawa [8 - 9], foi empregado em todos os ensaios laboratoriais deste artigo. Akuzawa mostra que o ICA, baseado em métodos de Newton, é robusto sob ruídos gaussianos. Neste caso, ele funciona melhor do que os métodos JADE [10] e FastICA [11]. Uma de suas características é a estabilidade global resultante da introdução de duas deformações. Sendo uma delas chamada deformação homotópica tipo ponto fixo na matriz de atualização [9]. Outra característica é que o método não requer pré-branqueamento, ou seja, poupa a metade dos graus de liberdade que naturalmente são utilizados nos métodos que precisam de branqueamento.

3. ICA pelo Método Quase-Newton

Este método utiliza cumulantes de quarta ordem de variáveis estocásticas, onde a média amostral denotada por $\langle \rangle$ e $\langle \rangle_c$ são cumulantes estimados a partir dos dados observados. Os cumulantes de quarta ordem $\langle y_1^3 y_2^1 \rangle_c$, $\langle y_1^2 y_2 y_3 \rangle_c$ e $\langle y_1^2 y_2^2 \rangle_c$ são chamados de tipo $_{(3,1)}$, tipo $_{(2,1,1)}$ e tipo $_{(2,2)}$ respectivamente [8].

O ICA baseado em quase-newton, num espaço de dimensão p , pode ser interpretado pela determinação de um ponto onde funções critério Q_p se tornam muitos pequenos para $1 \leq p \leq M$ ($M=3$) e $1 \leq i \neq j \leq N$ simultaneamente baseados em suas expansões de primeira ordem é escolhida como funções objetivo [9].

Assume-se que existem $T=1024$ amostras dos sinais de PD de dimensão N , podendo ser denotados na forma geral por $\{(y^{(0)})_{it} \mid 1 \leq i \leq N, 1 \leq t \leq T\}$. Os valores médios foram subtraídos, tal que, $\sum_{t=1}^T (y^{(0)})_{it} = 0, \forall i$. O algoritmo de Azukawa é baseada na construção de uma seqüência de vetores $y^{(0)}, y^{(1)}, y^{(2)}, \dots$, que converge para um ponto ótimo $y^{(\infty)}$, onde cada componente torna-se mutuamente independente. O fluxo desta seqüência é especificado pelas matrizes $N \times N$ $\{\Delta^{(s)}; s = 0, 1, 2, \dots\}$, que descreve a quantidade de passos, então (4) é:

$$y^{(s+1)} = (\exp \Delta^{(s)}) y^{(s)} \quad (5)$$

para $s = 0$ $s=0$ temos $y_k^{(0)}$ é o k -ésimo dado das observações. Então para o fluxo de seqüência no n -ésimo passo o $y^{(n)}$ dependerá dos $\{\Delta^{(k)}\}_s$ e será da forma $y^{(n)} = e^{\Delta^{(n-1)}} e^{\Delta^{(n-2)}} \dots e^{\Delta^{(0)}} y^{(0)}$.

A forma compacta é:

$$y = B y^{(0)} \quad (6)$$

onde $B \in GL(N, \mathfrak{R})$ é um subconjunto do grupo linear de matrizes reais e não singular $N \times N$. Este também pode ser útil para sistemas ou problemas que necessitem de otimização que se dá através de B , assumindo M critérios, $\{Q_p \mid \mathfrak{R}^T x \mathfrak{R}^T \rightarrow \mathfrak{R} \quad 1 \leq p \leq M\}$ até que se torne invariante sob multiplicação no processo de atualização do fluxo de seqüência. O $\exp(\Delta^{(s)})$ é um *coset* de B e,

$$Q_p(y_i, y_j) = \left\langle y_i^p y_j^{4-p} \right\rangle_c \quad (7)$$

é função de cumulantes.

A gradiente não-holonômica é escolhida e deformada por ξ (tipicamente igual 2) tal como:

$$V = \begin{pmatrix} K_i & (3-\xi)R_{ij} \\ (3-\xi)R_{ij} & K_j \\ 2Q_{ij} & 2Q_{ji} \end{pmatrix} \quad (8)$$

onde $K_i = \left\langle y_i^4 \right\rangle_c, K_j = \left\langle y_j^4 \right\rangle_c$ e $R_{ij} = \left\langle y_i^2 y_j^2 \right\rangle_c$.

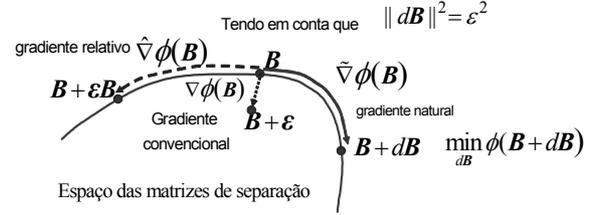
Para resolver (5), a quantidade de passos é determinado à maneira de Newton, tal que os Δ_{ij} e Δ_{ji} é determinado pela seguinte regra de atualização é dada por:

$$\begin{pmatrix} \Delta_{ji} \\ \Delta_{ij} \end{pmatrix} = -(V^T V)^{-1} V^T \begin{pmatrix} Q_{ij} \\ Q_{ji} \\ R_{ij} \end{pmatrix} \quad (9)$$

onde a matriz de transformação $(V^T V)^{-1} V^T$ é interpretada como uma inversa generalizada de V .

A Figura 5 mostra uma visão dos gradientes de B no espaço homogêneo na geometria diferencial, onde o gradiente baseado em restrições não-holonômicas é equivalente ao gradiente natural com considerações geométricas. Este deve lidar com mudanças rápidas e/ou intermitentes nas magnitudes das fontes de sinal.

$$\phi(B + dB) = \phi(B) + \langle \nabla \phi(B) \mid dB \rangle$$



$$\text{Relação de equivalência } \tilde{\nabla} \phi(B) = \hat{\nabla} \phi(B) B = \nabla \phi(B) B^T B$$

Figura 5: Espaço homogêneo das matrizes, dB é o espaço de tangentes, extraído de [12].

4. Separação de Fontes de Sinal e Ruído

Para sinais de PD, ICA pode ser aplicada com a finalidade de conseguir revelar características ocultas que podem ajudar a descobrir e descrever uma fonte real de PD. O resultado esperado, pós-tratamento iterativo sobre os sinais observados de PD, é identificar possíveis fontes estimadas independentes estatisticamente. O ruído aditivo, convenientemente assumido como gaussiano, desaparecerá pelo fato de que não foram utilizados critérios de segunda ordem.

4.1. Medições de Performance

Duas medições são utilizadas para avaliar o algoritmo ICA, a relação sinal-ruído (SNR) e crosstalk O SNR é um importante parâmetro utilizado para determinar a qualidade da informação. Também é um dos índices mais importantes para avaliar a performance dos algoritmos ICA. Ou seja, o SNR é uma medida de longo prazo para verificar a qualidade do sinal reconstruído.

Os crosstalk's são interferências ou acoplamentos mútuos entre observações, misturados até serem pré-processados numa batelada (grupo) de observações. Uma medição deste parâmetro indica o ruído remanescente indicado pelo SNR.

5. Resultados Experimentais

Os dados coletados na medição de PD representam os sinais observados, compostos pelo sinal fonte e o ruído aditivo. Estes foram praticados a partir de medições na fase C do gerador U10 na usina Itaipu [6].

A Figura 6 mostra oito sinais observados com 20% de ruído randômico, adicionado artificialmente para testar o ICA. Observa-se que, a maioria destes sinais estão mascarados pelo efeito do ruído, tornando-se difi-

o reconhecimento visual de pelo menos uma fonte original (Figura 4).

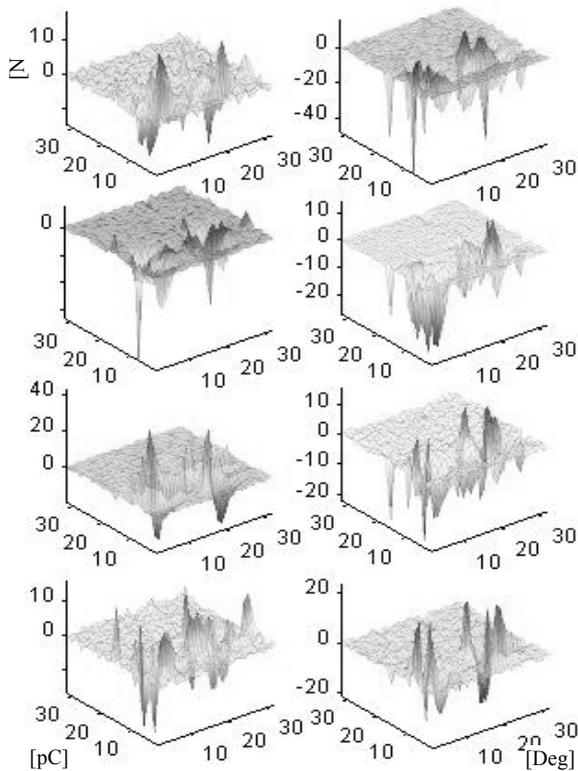


Figura 6: Sinais observados com 20% de ruído adicionados artificialmente.

5.1. ICA como Extrator de Sinais de Ruído

A Figura 7 mostra as fontes estimadas pelo ICA, onde os ruídos das observações foram cassados pelas características próprias do ICA devido a que este evita o uso das estatísticas de segunda ordem, desse fato se obtém uma estimativa boa das fontes originais. Sabe-se que, para qualquer método ICA é impossível manter uma ordem das fontes devido que as permutações das matrizes são livres assim como as escalas. Estas são as desvantagens dos métodos ICA que lidam com fontes desconhecidas e a maneira que estes foram combinadas, também são desconhecidos. Portanto, comparando as fontes estimadas com as fontes que lhes deu origem, verifica-se que todas as fontes foram recuperadas, sendo algumas destas corrigidas dos efeitos causados pelas componentes de ruído tipo gaussiano.

A performance do ICA foi realizada em função do parâmetro crosstalk-médio por efeito de normalização das fontes em função da variância e cumulante; a máxima variância das fontes estimadas e seu maior valor do quarto cumulante. O índice crosstalk indica a informação mútua remanescente (ver Tabela 2).

A Tabela 2 resume os casos realizados para este artigo, onde um sinal ruído artificial é adicionado aos sinais fonte para conseguir observações ruidosas. Sabe-se que, os sinais fonte originais, contem ruído desconhecido naturalmente adquirido no processo de medi-

ção. Partindo da idéia de que se misturamos duas fontes gaussianas teremos uma observação gaussiana impossível de ser separada. Então, estendendo a níveis de componentes, o alvo é eliminar componentes de sinais ruído naturais do mesmo tipo que os sinais de ruído injetados artificialmente. Dessa maneira supõe-se que o ruído artificial fará com que certos componentes do ruído natural sejam observados com maior energia. Assim o ICA eliminará automaticamente os componentes gaussianos das fontes sazonalizados por este artifício.

Quando não adicionamos ruído às fontes temos o caso para dados reais de PD, fontes são declaradas como observações. Assim o ICA nos conduzirá para o descobrimento de uma nova fonte estimada e desejada. Em outras palavras teremos o caso onde o ICA faz papel de filtro.

Tabela 2: Resumo dos parâmetros estatísticos e performance por crosstalks.

Crosstalk Por VAR.	Crosstalk Por CUM.	Mx. VAR.	Mx. 4to. CUM.	SNR (dB)	Ruído (%)
2,020	2,150	0,041	1,03 {3}	Inf	--
0,288	0,288	0,043	1,86 {6}	41,13	1
0,296	0,293	0,202	7,87 {7}	20,12	10
0,321	0,328	0,104	5,15 {8}	16,84	15
0,310	0,314	0,196	4,14 {5}	13,40	20
0,503	0,505	0,134	2,67 {7}	7,33	30
0,426	0,426	0,134	2,67 {7}	6,29	40
0,610	0,603	0,054	0,30 {6}	5,01	60

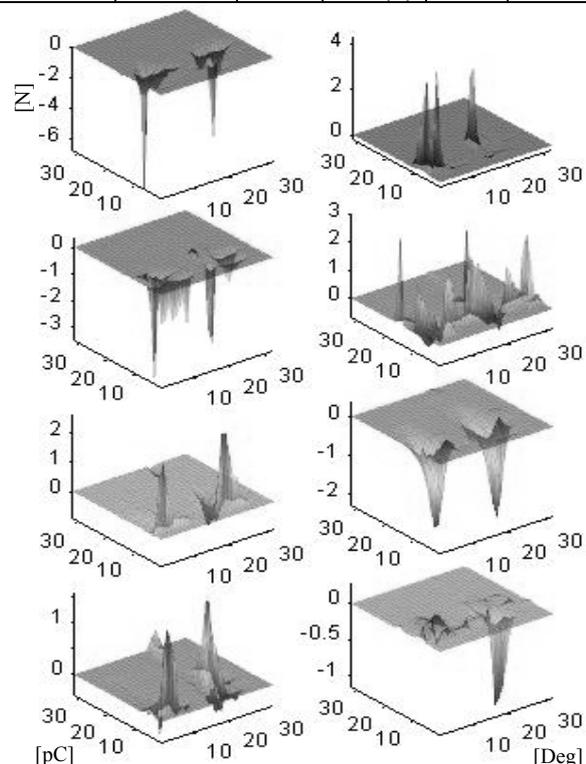


Figura 7: Fontes estimadas com SNR 13,40dB pelo ICA sem pré-branqueamento.

6. Conclusões

O método ICA pode ser utilizado na separação de sinais de ruído tipo gaussiano dos sinais de PD. Este método traz novas expectativas como: novo enfoque na recuperação de fontes mais próximos aos casos reais existentes numa medição de PD e sua aplicabilidade com propósitos de se conseguir revelar características ocultas que podem ajudar a descobrir e descrever uma fonte real de PD (caso sem ruído adicional). O BSS/ICA pode ser útil no pós-processamento dos dados e somar-se aos esforços empreendidos pelos métodos tradicionais utilizados na filtragem de sinais de PD, vistos nos circuitos de medição das normas [3] e [4]. Este método ICA não requer pré-branqueamento, sendo a complexidade numérica da ordem N^2 comparada por outros métodos ICA que são de ordem N^4 . Portanto, não é necessário tratar operações matriciais gigantescas, precisando apenas calcular uma matriz inversa generalizada de 3×2 que concentra os critérios-cumulantes (chamados genericamente de funções objetivo) com a condição de tender a zero quando o algoritmo converge.

A mais importante vantagem deste método, no processamento de sinais de PD, é sua robustez sob ruídos gaussianos. Caso o ruído seja colorido um pré-tratamento pode ser implementado.

Nos casos em que as observações foram pré-branqueadas, haverá a necessidade de realizar pós-processamento via pós-análise de fatores, semelhante ao que é feito através da Análise de Componentes Principais (PCA), devido ao fato que parte do ruído foi pré-processado tornando-se ruído gaussiano multidimensional.

A difusão deste método nos processos de medição, coleção de bancos de informação, monitoração e até diagnósticos de equipamentos pode trazer novos refinamentos e melhores performances baseada na qualidade da informação resultante.

Por outro lado essa técnica propicia a introdução de novos sistemas de medição no campo, os quais seriam inviáveis de outra forma, em decorrência da existência de ruídos eletromagnéticos intensos, desde que estes tenham alguma forma de independência com os sinais observados.

Agradecimentos

Os autores agradecem ao apoio do CNPq, FAPERJ, COPPE, ITAIPU e CEPEL a este projeto.

7. Referências

- [1] Huamán Cuenca, W. "Aplicação de Sistemas inteligentes no Reconhecimento de Padrões de PDs em Transformadores de Potência". *Tese de Mestrado, Programa de Engenharia Elétrica UFRJ-COPPE* 1998.
- [2] R. Bartnicas, "Corona Discharge Processes in Voids". In: R. Bartnicas, E. McMahon, *Engineering Dielectrics: Corona Measurement and Interpretation Vol. I, chapter 2, Philadelphia, ASTM STP 669, 1979.*
- [3] IEC Publication 270, "Partial Discharge Measurement" Second Edition, 1981.

- [4] IEEE P1434, "Guide to the Measurement of Partial Discharges in Rotating Machinery", *Electrical Machinery Committee of the IEEE Power Society, 1997.*
- [5] Levy, A. et al., "Utilização do Sistema de Descargas Parciais ICM System da Power Diagnostix Systems", *Procedimento Especifico CEPEL no. 3530-3007-070, jan. 1997.*
- [6] M. Latini, et al. "Medição de descargas Parciais em Hidrogerador da Usina de Itaipu - Uma Avaliação Experimental das Limitações, Dificuldades de Medição e Interpretação de resultados", *XV SNPTEE, Foz do Iguaçu - Paraná, 1999.*
- [7] S. Amari, T-P. Chen, and A. Cichocki, "Non-holonomic constraints in learning algorithms for blind source separation", preprint 1997.
- [8] T. Akuzawa, "Extended Quasi-Newton Method for the ICA", in *Proceedings of the International Workshop on Independent Component Analysis and Blind Signal Separation, 2000*, pp. 521-525.
- [9] T. Akuzawa and N. Murata, "Multiplicative Non-holonomic/newton-like algorithm", *Chaos, Solitons & Fractals*, vol. 12, pp. 785-793, 2001.
- [10] J-F. Cardoso and A. Souloumiac, "Blind Beamforming for non Gaussian Signals," in *IEE Proceedings -F*, vol. 140, pp. 362-370, 1993.
- [11] A. Hyvärinen, "A Fast Fixed-Point Algorithm for Independent Component Analysis," *Neural Computation*, vol. 9, pp. 1483-1492, 1997.
- [12] Francisco Javier González Serrano, "Aplicación de Técnicas de Separación Ciega de Fuentes al Procesado de Señal", *Universidad Carlos III, Curso_13_Nov.ppt*

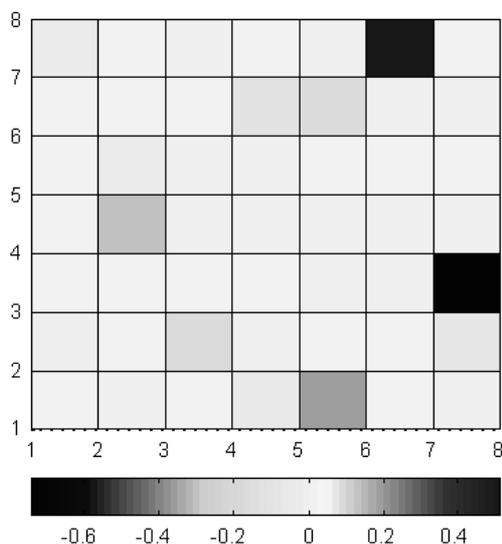


Figura 8: Estimativa resultante da matriz B após tratamento ICA não-holônômico.

A Figura 8 é a matriz de estimação B, serve para obter a reconstrução das fontes a partir das observações. Onde existe certa desassociação entre seus componentes mostrado pela cor dominante próximos a zero na escala de cores. Além de caracterizar a independência esta é não necessariamente ortogonal entre suas componentes.