

Alocação Inteligente de Bits para Compressão de Sinais de Distúrbios Elétricos no contexto Smart Grid

Jorge A. A. Cormane, Marcus V. Chaffim e Francisco A. de O. Nascimento

Resumo — Neste trabalho é apresentado um método de compressão para sinais de distúrbios elétricos em ambientes Smart Grid. A proposta é um algoritmo híbrido que combina técnicas de compressão de dados com e sem perdas, aliadas a uma estratégia de alocação de bits para os coeficientes da transformada *wavelet* por meio de redes de Kohonen. Sinais reais foram usados no treinamento da rede neural e na avaliação do algoritmo. Os resultados mostram bom desempenho com respeito a métricas que avaliam a precisão da forma de onda reconstruída com relação a redução da quantidade de memória necessária para representar a informação codificada.

Palavras-Chave — *Compressão de dados, Alocação de bits, Smart Grid, Sinais de distúrbios.*

Abstract— In this work a compression method for electrical disturbances signals in a Smart Grid environment is presented. The proposed algorithm consists of a hybrid technique that combines lossy and lossless data compression techniques, with a bit allocation strategy in wavelet transform domain based on Kohonen's networks. The neural network training and the evaluation of the algorithm used real signals. The results show that the proposed algorithm performed well with respect to objective measures that assess the accuracy of the reconstructed waveform and the reduction of memory necessary for representing the coded information.

Keywords — *Data compression, Bit allocation, Smart Grids, Disturbance waveform.*

I. INTRODUÇÃO

O aumento da demanda por energia elétrica e o crescente número de interligações entre os sistemas elétricos de potência tornam a operação uma missão cada vez mais complexa. O conceito de rede inteligente, ou *Smart Grid*, é adotado com a intenção de melhorar o padrão de operação dos sistemas elétricos de potência. Para chamar uma rede elétrica de inteligente, é necessário acrescentar certo grau de inteligência em todas as áreas envolvidas (geração, transmissão, distribuição, etc) [1, 2].

As novas condições operacionais sugeridas no ambiente das redes inteligentes apontam o intercâmbio de informações entre as áreas do sistema elétrico de potência, fazendo com que seja indispensável digitalizar, transmitir e armazenar as informações coletadas pelos equipamentos que o monitoram continuamente. Nesse sentido, prevê-se o tráfego de dados pelos canais de comunicação, levando em consideração que as tecnologias de supervisão fornecem cada vez mais informação [3]. Para atender simultaneamente exigências como espaço em memória e tempo de alocação de canal de comunicação, são incorporadas tecnologias da informação e da comunicação na infraestrutura dos sistemas elétricos de potência.

A compressão de dados para sinais de distúrbios elétricos apresenta exigências específicas derivadas da operação das redes elétricas e da natureza dos fenômenos que nelas ocorrem. No segmento de redes de energia elétrica, a fidelidade da forma de onda reconstruída após o processo de codificação constitui o parâmetro mais importante, isto é, a taxa de bits utilizada para representar a informação pode variar para se ajustar à fidelidade exigida. Neste caso, é preciso preservar a representação original da forma de onda a ser codificada, mesmo que a informação não consiga ser transmitida em tempo real (quando a quantidade de bits gerados na unidade de tempo é maior que a largura de banda do canal).

Após avaliar a literatura científica que trata da compressão de sinais em sistemas de potência, agrupamos as técnicas em cinco categorias de acordo com a abordagem utilizada: (1) Codificação por transformadas com limiarização no espaço transformado [4-15]. Nessas técnicas, o sinal é segmentado em janelas. Em cada janela é aplicada uma transformada ortogonal. Ao vetor de coeficientes transformados é aplicado um processo de limiarização no qual os coeficientes que possuem amplitude inferior ao limiar são iguais a zero. (2) Codificação com identificação e parametrização de componentes estacionárias e não estacionárias [16-18]. Neste caso a parte estacionária do sinal é suprimida na codificação e sintetizada novamente na decodificação. (3) Na técnica chamada de *Matching Pursuit*, o sinal é decomposto de forma iterativa usando uma base de representação dedicada [19]. (4) Codificação por transformadas com aplicação da codificação de entropia no espaço transformado [20-22]. (5) Codificação com sistemas *neuro-fuzzy* [23].

Neste trabalho é proposta uma abordagem híbrida que se inicia com a aplicação da transformada *wavelet* discreta (TWD) sobre cada janela do sinal. A seguir há a alocação dinâmica de bits utilizando mapas auto-organizáveis de Kohonen (SOM, na sigla em inglês), que aprendem os padrões espectrais dos fenômenos estudados e especificam a quantidade de bits necessária para a quantização dos coeficientes transformados. O vetor de coeficientes é então quantizado e comprimido sem perdas por meio de codificação aritmética. Os resultados de simulações com eventos reais mostram um bom desempenho do algoritmo proposto.

II. ALGORITMO PROPOSTO

A Figura 1 apresenta em diagrama de blocos o algoritmo proposto. O sinal coletado é segmentado em janelas de tamanho N amostras, denotadas como $x[n]$, sendo N uma potência inteira de dois. Como transformada ortogonal, foi escolhida a TWD com função de base *Daubechies-8* pela boa representação tempo-frequência de sinais submetidos a mudanças abruptas da faixa dinâmica, para diferentes resoluções [24]. Para cada segmento aplica-se a TWD até o último nível de resolução, o qual está determinado pelo tamanho da janela e pode ser calculado com a expressão $\log_2(N)$.

Jorge A. A. Cormane e Marcus V. Chaffim, Faculdade do Gama, Universidade de Brasília, Brasília-DF, Brasil. E-mails: jcormane@unb.br, chaffim@unb.br.

Francisco A. de O. Nascimento, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília-DF, Brasil. E-mail: assis@unb.br.

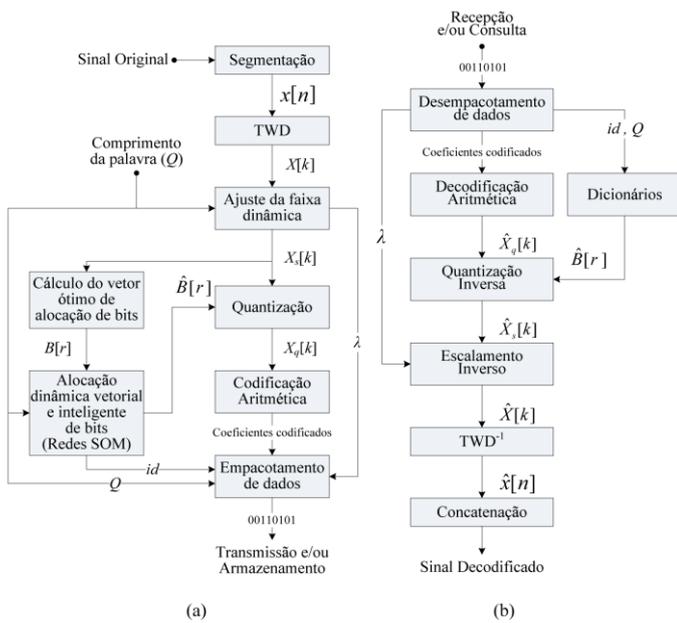


Fig. 1. Diagrama de blocos do algoritmo proposto: (a) Codificador. (b) Decodificador.

Para a descrição do algoritmo a partir deste ponto, assume-se que os processos sejam executados para cada segmento $x[n]$ do sinal original. Após o cálculo dos coeficientes transformados, $X[k]$, são definidos os limites da representação numérica dos coeficientes pelo fator de ajuste de λ em (1).

$$\lambda = \frac{2^Q}{\max\{|X[k]|\}}, \quad k = \{0, 1, \dots, N-1\}. \quad (1)$$

O parâmetro Q , em bits, especificado pelo usuário, representa o maior comprimento da palavra que será usado para obter a representação em ponto fixo (números inteiros) dos coeficientes transformados. Ele encontra-se definido para $2 \leq Q \leq Q_o - 1$, onde o valor Q_o é o comprimento da palavra binária do equipamento de medição. O fator λ permite ajustar a faixa dinâmica dos $X[k]$ para o intervalo $[-2^Q, 2^{Q-1}]$, o que torna possível regular a relação taxa-distorção e, portanto, controlar a qualidade da reconstrução do sinal. A sequência dos coeficientes escalonados, $X_s[k]$, é descrita em (2).

$$X_s[k] = \lfloor \lambda X[k] \rfloor, \quad \text{onde } k = \{0, 1, \dots, N-1\}. \quad (2)$$

A sequência $X_s[k]$ é dividida uniformemente em M sub-bandas a fim de especificar a quantidade de bits necessária para a representação dos coeficientes em cada sub-banda. O vetor de alocação de bits resultante, \mathbf{B} , representado como a sequência $B[r]$ em (3), possui dimensão corresponde ao total de sub-bandas. Cada componente de $B[r]$ indica o comprimento da palavra digital necessário para representar em ponto fixo os coeficientes $X_s[k]$ da r -ésima sub-banda.

$$B[r] = \lceil \log_2(\max\{|X_s[k]|\}) \rceil, \quad \text{onde} \quad (3)$$

$$k = \left\{ \frac{N}{M}r, \frac{N}{M}r + 1, \dots, \frac{N}{M}r + \frac{N}{M}r - 1 \right\} \text{ e}$$

$$r = \{0, 1, \dots, M-1\}.$$

A Figura 2 apresenta um exemplo do cálculo do vetor \mathbf{B} para uma janela de 1024 amostras ($N=1024$), dividida em oito sub-bandas ($M=8$) de 128 amostras ($N/M=128$) e um comprimento máximo de palavra de 8 bits ($Q=8$).

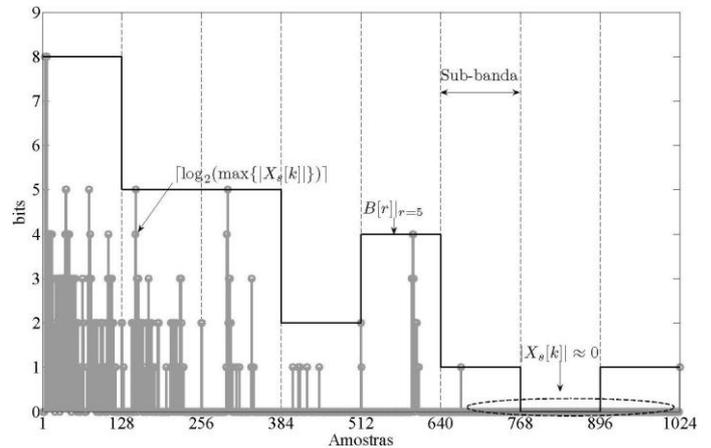


Fig. 2. Exemplo ilustrativo do cálculo do vetor de alocação de bits.

As linhas pontilhadas verticais indicam os limites das 8 sub-bandas. As barras verticais de cor cinza expõem a quantidade de bits necessária para representar cada coeficiente de $X_s[k]$ como número inteiro $\lceil \log_2(\max\{|X_s[k]|\}) \rceil$. As linhas contínuas horizontais correspondem à $B[r]$, que representa o envoltório do espectro. Este envoltório é quantidade de bits que o coeficiente de maior amplitude de cada sub-banda necessita para ser representado. A sequência de zeros nas três últimas sub-bandas corresponde aos coeficientes de amplitude próxima de zero ($|X_s[k]| \approx 0$). Assim, o vetor de alocação de bits do exemplo é a sequência $B[r] = [8, 5, 5, 2, 4, 1, 0, 1]$.

A. Alocação inteligente de bits

Depois de calcular o vetor \mathbf{B} , tem início a seleção da rede SOM de acordo com o parâmetro Q . Foram construídas e treinadas redes SOM para cada valor de Q , com o objetivo de manter a coerência entre a quantização e os limites da faixa dinâmica, ajustados previamente. Neste caso, assume-se que os sinais coletados foram digitalizados com um conversor analógico-digital de 16 bits ($Q_o=16$). Portanto, foram construídas e treinadas um total de 14 redes SOM.

A sequência $B[r]$ é utilizada como padrão de entrada da rede SOM selecionada. Como saída, são obtidos a sequência $\hat{B}[r]$ (que corresponde ao vetor $\hat{\mathbf{B}}$, a melhor estimativa de \mathbf{B}) e o índice da sua posição (id) dentro do da rede. O parâmetro Q é especificado como uma entrada do algoritmo, como mostra a Figura 3. A rede neural determina o neurônio cujos pesos sinápticos estão associados à melhor estimativa de $B[r]$. Em outras palavras, o índice do neurônio selecionado fornece a posição da sequência $\hat{B}[r]$ que apresenta o melhor casamento com $B[r]$ dentro da rede SOM.

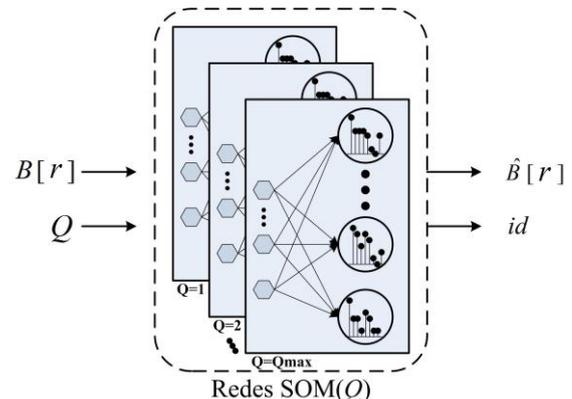


Fig. 3. Exemplo ilustrativo da operação da rede SOM.

Neste contexto, a rede SOM executa as funções de um dicionário de vetores de código que contém os quantizadores das sub-bandas. Os coeficientes $X_s[k]$ de cada uma das sub-bandas são quantizados com cada elemento de $\hat{B}[r]$, sendo esses representados como um número inteiro no intervalo $[-2^{\hat{B}[r]-1}, 2^{\hat{B}[r]-1}]$. A quantização de $X_q[k]$, expressa em (4), ocorre pelo truncamento (descarte da parte fracionária) de $X_s[k]$ para sua representação em ponto fixo.

$$X_q[k] = \left\lfloor \frac{X_s[k]}{\lambda} \hat{B}[r] \right\rfloor. \quad (4)$$

Para este exemplo a sequência $\hat{B}[r]=[8,5,5,2,3,0,0,1]$ corresponde à estimativa da quantidade de bits especificada pela rede SOM, após receber o vetor $B[r]$ como entrada. Deste modo, os coeficientes da primeira sub-banda são quantizados com 8 bits, os coeficientes da segunda com 5 bits e assim sucessivamente. A alocação de bits dos coeficientes transformados é tanto melhor quanto mais próxima de N for a quantidade de sub-bandas. Contudo, o aumento de dimensionalidade do vetor \mathbf{B} gera o aumento na complexidade computacional durante o treinamento da rede neural.

Nota-se o aumento da quantidade de coeficientes que apresentam amplitude nula, apesar de ser alocada uma quantidade de bits para representá-los. Isto significa que durante o processo de adaptação do comprimento da palavra, a faixa dinâmica da sub-banda que contém o coeficiente com maior energia permanece fixa, enquanto as faixas dinâmicas das outras sub-bandas sofrem novos ajustes da representação, o que acarreta a anulação dos coeficientes de menor energia. A redundância da sequência de zeros é minimizada pela codificação de entropia com codificador aritmético.

Os coeficientes codificados, o valor do parâmetro (Q), o fator de escala (λ) e o índice do dicionário (id) também são comprimidos pelo método de codificação de entropia. O empacotamento dos dados é realizado a cada segmento de sinal, gerando um bloco de dados. Os blocos são concatenados de forma a gerar um arquivo de dados compactado. A informação lateral de cada segmento de sinal compactado utiliza no máximo 32 bits (4 bytes), dos quais até 12 bits são necessários para representar o id , 16 bits para quantizar o parâmetro λ e 4 bits para representar o Q empregado.

B. Algoritmo de decodificação

O diagrama de blocos que descreve o decodificador é mostrado na Figura 1(b). Primeiramente é realizado o desempacotamento dos dados de cada segmento do sinal comprimido. Em seguida, a decodificação de entropia é aplicada obtendo-se os coeficientes quantizados $X_q[k]$. O parâmetro Q e o índice do dicionário (id), que informa o vetor $\hat{B}[r]$, são utilizados para realizar a quantização inversa. Aplica-se o fator de escala λ para o escalonamento inverso, obtendo-se $\hat{X}[k]$. Finalmente, é aplicada a TWD inversa. O sinal decodificado é obtido pela concatenação sucessiva de janelas de comprimento igual a N amostras.

III. TREINAMENTO DO MAPA AUTO-ORGANIZÁVEL DE KOHONEN

O mapa auto-organizável de Kohonen é uma rede neural artificial (RNA) com arquitetura auto-organizável que realiza um mapeamento não linear de um espaço, preservando as relações de vizinhança dos dados de entrada [25, 26].

O treinamento não supervisionado do SOM garante a formação de classes ou agrupamentos a partir da detecção das similaridades entre as entradas, reduzindo a quantidade de padrões necessários para representar os sinais compactados, e melhorando o desempenho do algoritmo.

A quantidade de mapas, seu tamanho e quantidade de dados de treinamento são influenciados pelo parâmetro Q . O aumento do valor de Q , torna maior a variação da faixa dinâmica dos coeficientes e, por tanto, faz com que os valores das componentes de $B[r]$ incrementem sua variação. Os mapas possuem uma topologia retangular (duas dimensões), devido ao fato de que o resultado final não difere quando comparado com outras topologias. Contudo, a topologia retangular apresentou o menor tempo de operação durante o treinamento, fazendo ele atrativo para executar as simulações. Em razão disto, construíram-se um total de 14 mapas para atender todas as possibilidades geradas pelo parâmetro Q . A quantidade de bits necessária para representar os índices transmitidos ao decodificador é calculada para cada mapa dependendo do seu tamanho.

Da base de dados do EPRI [27], foram separados para treinamento das RNAs um total de 60 registros de tensão e 36 de corrente, o que corresponde a 70% do total dos registros. Considerando cada sinal monofásico como um sinal de treinamento, obtém-se um total de 180 sinais de tensão e 108 sinais de corrente. O restante (30%) dos registros foi utilizado como sinais de teste e validação. Os sinais de treinamento foram segmentados de forma que fosse detectada a maior quantidade de mudanças possíveis no sinal processado. De fato, a variabilidade dos dados de treinamento ajuda a melhorar a adaptabilidade do comprimento de palavra na presença de ocorrências. Para isso, foi utilizado um esquema de janela deslizante, onde o tamanho do passo de deslocamento da janela define a sensibilidade do esquema.

A partir destes segmentos de sinais são calculados os vetores \mathbf{B} para cada valor de Q , que são utilizados como entradas para o treinamento das redes SOM. Contudo, muitas repetições dentro de cada conjunto de vetores foram detectadas e descartadas. Ao final, para um valor de $Q=15$, por exemplo, obteve-se um conjunto de treinamento constituído de 6060 vetores.

Um máximo de 250 épocas e uma variação incremental dos pesos inferior a 10^{-6} foram estabelecidos como critérios de convergência no processo de treinamento. Na maioria dos casos as redes SOM atingiram o critério baseado na variação incremental dos pesos em torno de 60 épocas. Destaca-se que o tamanho do SOM é definido ao início do treinamento. Portanto, existe um compromisso entre o tamanho do dicionário e a qualidade do sinal reconstruído após a compactação.

IV. RESULTADOS DE SIMULAÇÃO

A técnica foi programada de forma a permitir codificar, ao mesmo tempo, os três sinais de tensão ou de corrente correspondentes a cada uma das fases de um sistema elétrico de potência trifásico. Os parâmetros utilizados nas simulações são definidos a seguir: janelas de comprimento de 1024 amostras ($N=1024$), 8 sub-bandas de 128 coeficientes por banda ($M=8$), o ajuste da faixa dinâmica para quantização foi especificado para comprimentos da palavra no intervalo $2 \leq Q[\text{bits}] \leq 15$.

Os critérios de avaliação objetivos utilizados para aferir o desempenho do algoritmo foram o ganho de compressão (GC), expresso em (5), onde O_s é a quantidade de bits usada para representar o sinal original e C_s a quantidade de bits resultantes após a compressão, e a relação sinal ruído (SNR), expressa em (6), na qual $x[n]$ e $\hat{x}[n]$ correspondem às sequências original e reconstruída, respectivamente.

$$GC = \frac{O_s}{C_s}, \tag{5}$$

$$SNR = 10 \log_{10} \left[\frac{\sum_{n=0}^{N-1} x^2[n]}{\sum_{n=0}^{N-1} (x[n] - \hat{x}[n])^2} \right], \text{ em [dB]}. \tag{6}$$

Os resultados das simulações mostraram que o comprimento da palavra usado para quantizar os coeficientes transformados (8 bits) pode ser muito menor que o comprimento da palavra utilizado para representar o sinal original (16 bits), sem provocar erro significativo no sinal reconstruído. Esta afirmação pode ser verificada pela relação sinal-ruído exibida na Tabela I, onde cada um dos sinais reconstruídos apresenta um valor de SNR > 40 dB.

Em outras palavras, o nível de energia do sinal desejado é quatro ordens de grandeza maior que o nível da energia do erro gerado na compressão. O aumento do ganho de compressão (GC > 16) revela uma redução na taxa de bits (TB < 1), o que se interpreta como uma diminuição superior a 94% da quantidade de memória necessária para armazenar o sinal codificado, quando comparado com o sinal original. Valores similares foram observados nos resultados obtidos com sinais presentes na base de dados.

Nas Figuras 4 e 5, são mostrados três segmentos das formas de onda dos eventos na tensão e na corrente antes e depois da compressão, respectivamente.

Verifica-se que não há discrepância visual alguma entre os sinais originais e os sinais reconstruídos. Para evidenciar as alterações nas formas de onda causadas pela perda de informação, se faz necessário calcular a distorção entre o sinal original e o sinal reconstruído. Verifica-se, em ambos os casos, que o maior nível de distorção se apresenta onde os sinais experimentam mudanças bruscas de comportamento, o que em termos do domínio da transformada se traduz em uma maior atividade na faixa dinâmica do espectro causada pela variação da energia do sinal.

Nas Figuras 6 e 7, são mostrados os resultados da técnica de compressão em termos da SNR versus GC para o conjunto de sinais de teste que não foram utilizados no treinamento (linhas sólidas cinzas).

A variação do GC é alcançada modificando-se o parâmetro λ definido na equação (1). À medida que se diminui o valor de Q, o fator de compressão aumenta, e como resultado desse aumento, a SNR diminui até sair da faixa de operação útil (SNR > 40 dB, 0 < GC < 32 ou 0 < TB < 1).

A partir desse ponto, qualquer pequeno aumento no fator de compressão ocasiona uma grande deterioração do sinal reconstruído após a decodificação. Consideradas as condições de digitalização dos sinais e o grau de distorção na forma de onda, observa-se nas figuras 6 e 7, que o desempenho da técnica para a maioria dos casos presentes no banco de dados,

TABELA I. MEDIÇÃO DE DESEMPENHO PARA N=1024, M=8, Q=8

	Sinais					
	V _A	V _B	V _C	I _A	I _B	I _C
GC	22,89:1	23,15:1	20,91:1	19,35:1	16,85:1	17,76:1
SNR	50,50	48,63	50,67	43,06	42,65	45,22
TB	0,699	0,691	0,765	0,827	0,949	0,901

TB = Taxa de bits/amostra.

mostra que ganhos de compressão altos são ainda obtidos com uma relação sinal-ruído alta.

Os resultados apresentados evidenciam que a alocação dinâmica vetorial e inteligente de bits associada com uma codificação de entropia eficiente pode ser muito vantajosa na compressão de sinais de distúrbios na faixa útil de operação.

Adicionalmente, pode ser verificado que a técnica de compressão apresentou melhor desempenho para o conjunto de sinais de tensão quando comparado ao conjunto de sinais de corrente. Isto acontece devido ao fato dos distúrbios de corrente exibirem grande variação na faixa dinâmica do sinal associada a uma grande distorção na forma de onda.

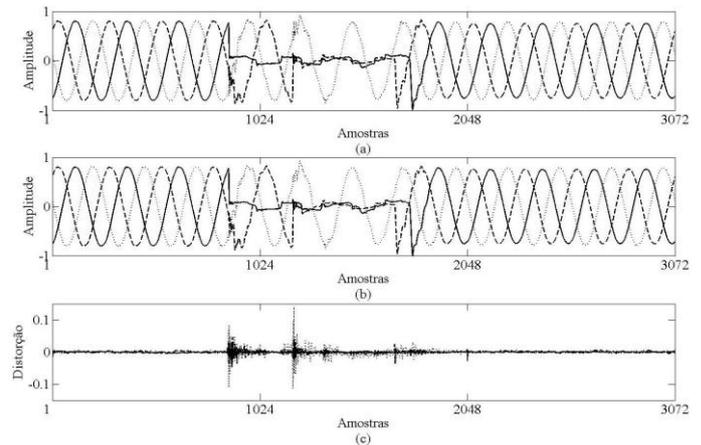


Fig. 4. Sinal trifásico de distúrbio de tensão: (a) original; (b) reconstruído; (c) distorção, neste caso ampliada 50 vezes.

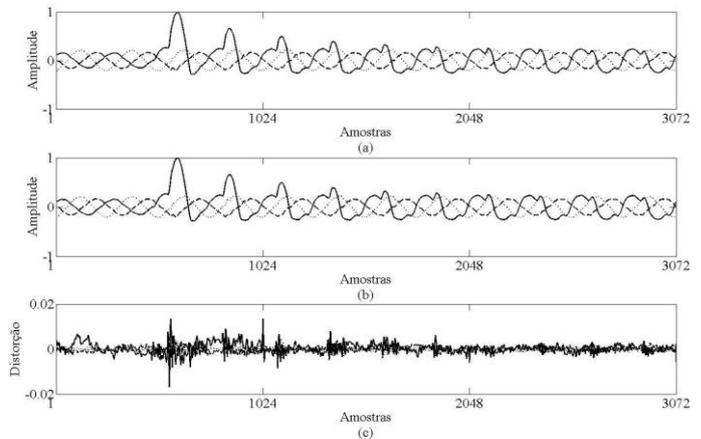


Fig. 5. Sinal trifásico de distúrbio de corrente. (a) original. (b) reconstruído. (c) distorção, neste caso ampliada 50 vezes.

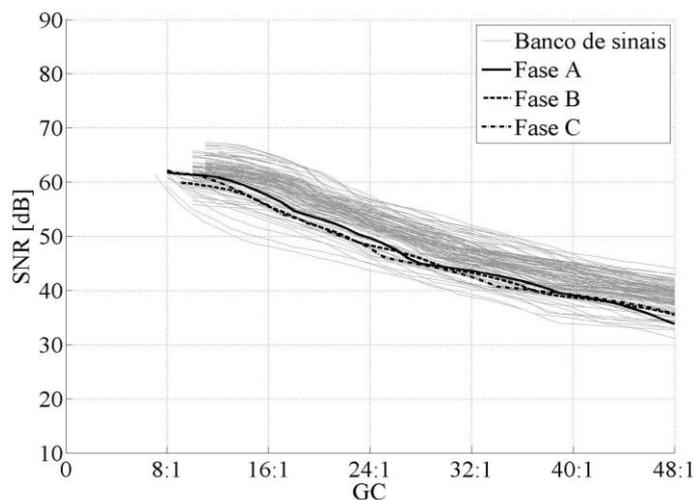


Fig. 6. Curvas de desempenho para os sinais de tensão.

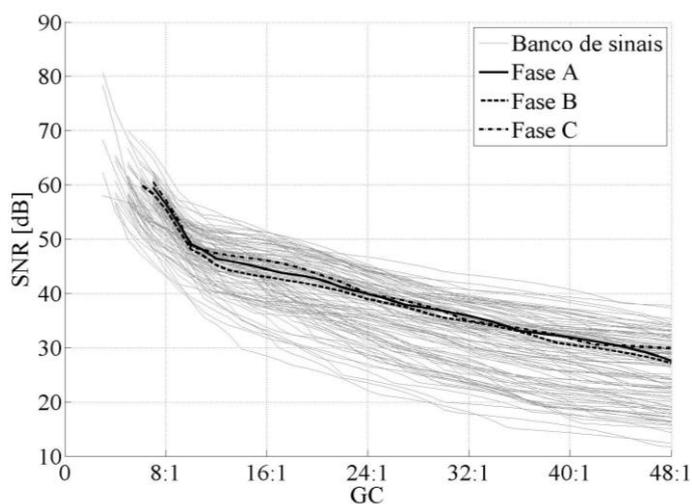


Fig. 7. Curvas de desempenho para os sinais de corrente.

V. CONCLUSÕES

Neste trabalho, apresentou-se uma técnica híbrida de compressão para formas de onda de distúrbios que focou-se basicamente na alocação dinâmica de bits no domínio da transformada. O processo de alocação de bits foi concebido de forma a se adaptar aos padrões espectrais encontrados nos sinais típicos de distúrbios que afetam os sistemas elétricos de potência. Os resultados de simulação da técnica indicam um bom desempenho com respeito às medidas objetivas.

REFERÊNCIAS

- [1] Bose, A. Smart transmission grid applications and their supporting infrastructure. *IEEE Transactions on Smart Grid*, v. 1, n. 1, p. 11–19, June 2010.
- [2] Russell, B. D.; Benner, C. Intelligent systems for improved reliability and failure diagnosis in distribution systems. *IEEE Transactions on Smart Grid*, v. 1, n. 1, p. 48–56, June 2010.
- [3] Silva, K.; Souza, B.; Brito, N.; Danta, K.; Costa, F.; Silva, S. Detecção e classificação de faltas a partir da análise de registros oscilográficos via redes neurais artificiais e transformada wavelet. *Revista SBA: Controle & Automação*, v. 18, n. 2, p. 163–172, June 2007.
- [4] Nascimento, F. Data compression algorithm for transient recording system. In: *Proceedings of the IEEE International Symposium on Industrial Electronics*, 1997. ISIE'97. [S.l.: s.n.], 1997.
- [5] Wikinson, W.; Cox, M. Discrete wavelet analysis of power system transients. *IEEE Transactions on Power Systems*, v. 11, n. 4, p. 2038–2044, November 1996.
- [6] Santoso, S.; Powers, E.; Grady, W. Power quality disturbance data compression using wavelet transform methods. *IEEE Transactions on Power Delivery*, v. 12, n. 3, p. 1250–1257, July 1997.
- [7] Hsieh, C.; Huang, S.; Huang, C. Data reduction of power quality disturbances a wavelet transform approach. *Elsevier - Electric Power Systems Research*, v. 47, p. 79–86, 1998.
- [8] Littler, T.; Morrow, D. Wavelets for the analysis and compression of power system disturbances. *IEEE Transactions on Power Delivery*, v. 14, n. 2, p. 358–364, April 1999.
- [9] Hamid, E.; Kawasaki, Z. Wavelet-based data compression of power system disturbances using the minimum description length criterion. *IEEE Transactions on Power Delivery*, v. 17, n. 2, p. 460–466, April 2002.
- [10] Panda, G.; Dash, P. K.; Pradhan, A. K.; Meher, S. K. Data compression of power quality events using the slantlet transform. *IEEE Transactions on Power Delivery*, v. 17, n. 2, p. 662–667, April 2002.
- [11] Dash, P. K.; Panigrahi, B. K.; Sahoo, D. K.; Panda, G. Power quality disturbance data compression, detection, and classification using integrated spline-wavelet and transform. *IEEE Transactions on Power Delivery*, v. 18, n. 2, p. 595–600, November 2003.
- [12] Meher, S.; Pradhan, A.; Panda, G. An integrated data compression scheme for power quality events using spline wavelet and neural network. *Elsevier - Electric Power Systems Research*, v. 69, p. 213–220, 2004.
- [13] Gerek, O.; Ece, D. 2-d analysis and compression of power-quality event data. *IEEE Transactions on Power Delivery*, v. 19, n. 2, p. 791–798, April 2004.
- [14] Gerek, O.; Ece, D. Compression of power quality event data using 2d representation. *Elsevier - Electric Power Systems Research*, v. 78, p. 1047–1052, 2007.
- [15] Ning, J.; Wang, J.; Gao, W.; Liu, C. A wavelet-based data compression technique for smart grid. *IEEE Transactions on Smart Grid*, v. 2, n. 1, p. 212–218, March 2011.
- [16] Ribeiro, M.; Romano, J.; Duque, C. An improved method for signal processing and compression in power quality evaluation. *IEEE Transactions on Power Delivery*, v. 19, n. 2, p. 464–471, April 2004.
- [17] Ribeiro, M.; Park, S.; Romano, J.; Mitra, S. A novel mdl-based compression method for power quality applications. *IEEE Transactions on Power Delivery*, v. 22, n. 1, p. 27–36, January 2007.
- [18] Zhang, M.; Li, K.; Hu, Y. A high efficient compression method for power quality applications. *IEEE Transactions on Instrumentation and Measurement*, v. 6, n. 6, p. 1976–1985, July 2011.
- [19] Tcheou, M.; Lovisolo, L.; Silva, E. da; Rodrigues, M.; Diniz, P. Optimum ratedistortion dictionary selection for compression of atomic decompositions of electric disturbance signals. *IEEE Signal Processing Letters*, v. 14, n. 2, p. 81–84, February 2007.
- [20] Hsieh, C.; Huang, S. Disturbance data compression of a power system using the huffman coding approach with wavelet transform enhancement. In: *IEE Proceedings Generation, Transmission & Distribution*. [S.l.: s.n.], 2003.
- [21] Huang, S.; Jou, M. Application of arithmetic coding for electric power disturbance data compression with wavelet packet enhancement. *IEEE Transactions on Power Systems*, v. 19, n. 3, p. 1334–1341, August 2004.
- [22] Lorio, F.; Magnago, F. Analysis of data compression methods for power quality events. In: *Power Engineering Society General Meeting*. 2004.
- [23] Ibrahim, W.; Morcos, M. Novel data compression technique for power waveforms using adaptive fuzzy logic. *IEEE Transactions on Power Delivery*, v. 20, n. 3, p. 2136–2143, July 2005.
- [24] Mallat, S. *A wavelet tour of signal processing*. 2nd. ed.: Academic Press, 2001.
- [25] Kohonen, T. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, v. 43, p. 59–69, 1982.
- [26] Rzeszutek, R.; Androustos, D.; Kyan, M. Self-organizing maps for topic trend discovery. *IEEE Signal Processing Letters*, v. 17, n. 6, p. 12–31, June 2010.

EPRI. DOE/EPRI National Database Repository of Power System Events. 2011. Electric Power Research Institute, Inc. Disponível em: <<http://expertmonitoring.com/doelibrary/default.asp>>. Último acesso em 01/07/2011.