

Estimação de Harmônicos e Interharmônicos baseada na Análise de Componentes Independentes de Canal Único

Marcelo A. A. Lima, Augusto S. Cerqueira, Patrick Santos de Oliveira, Danton D. Ferreira e Carlos A. Duque

Resumo—A Transformada Discreta de Fourier (TDF) é uma das ferramentas mais usadas para análise espectral. Entretanto, a estimação de harmônicos baseada na TDF é imprecisa quando a frequência do sistema de potência desvia do seu valor nominal. Ademais, um interharmônico pode não ser distinguível quando a resolução de frequência da TDF não é um divisor inteiro da frequência do interharmônico. Este trabalho propõe a aplicação da Análise de Componentes Independentes de Canal Único (SCICA - *Single Channel Independent Component Analysis*) para estimar de maneira não-supervisionada harmônicos e interharmônicos de um sinal do sistema de potência. A operação da SCICA é equivalente a um banco de filtros lineares adaptativos os quais podem separar de maneira não-supervisionada os harmônicos e interharmônicos do sinal. Será mostrado que o algoritmo SCICA obtém resultados mais precisos para estimação de frequências harmônicas e interharmônicas arbitrárias do que a TDF.

Palavras-Chave—Análise de componentes independentes de canal único, Separação cega de fontes, Filtros adaptativos, Harmônicos e interharmônicos, Qualidade da energia elétrica.

Abstract—The Discrete Fourier Transform (DFT) is one of the most used tools for spectral analysis. However, the DFT-based harmonic estimation is inaccurate when the power system frequency deviates from its nominal value. Also, an interharmonic may be not distinguishable when the DFT frequency resolution does not match the interharmonic frequency. This paper proposes the application of Single Channel Independent Component Analysis (SCICA) to blindly estimate harmonics and interharmonics of a power system signal. The SCICA operation is equivalent to an adaptive linear filter bank which can blindly separate the harmonics and interharmonics of the signal. It will be shown that the SCICA algorithm obtains more accurate results for estimation of arbitrary harmonic and interharmonic frequencies than the DFT.

Keywords—Single Channel Independent Component Analysis, Blind source separation, Adaptive filters, Harmonics and interharmonics, Power quality.

I. INTRODUÇÃO

Devido ao difundido uso de cargas não lineares, como fornos a arco elétricos e outros dispositivos de eletrônica de potência, os problemas de qualidade da energia associados com harmônicos e interharmônicos estão se tornando cada

vez mais presentes. Neste contexto, o desenvolvimento de métodos mais precisos de extração/estimação de harmônicos e interharmônicos para fins de proteção, análise e controle tem sido abordado por diversos autores [1], [2], [3], [4].

É difícil estimar interharmônicos com exatidão, devido ao fato das frequências não serem múltiplas inteiras da frequência fundamental do sistema elétrico. Ademais, a frequência fundamental do sistema elétrico também pode variar em relação ao seu valor nominal devido ao desbalanço de potência entre a geração de energia e a demanda de carga. Esses problemas podem levar a imprecisões devido aos efeitos *leakage* e *picket-fence* quando a TDF (Transformada Discreta de Fourier) é aplicada diretamente para análise espectral [2].

O cálculo exato de harmônicos/interharmônicos baseado na TDF sob condições de variação da frequência do sistema elétrico é ainda uma questão pendente. Sabe-se que a melhor solução para se anular o vazamento espectral é selecionar uma largura de janela que cubra um período ou múltiplo inteiro do período do sinal. Isso é geralmente considerado ser muito desafiador porque as frequências interharmônicas são imprevisíveis e a frequência do sistema de potência pode também ser variante no tempo [1].

Várias técnicas de estimação de harmônicos e interharmônicos do sistema elétrico não baseadas diretamente na TDF foram propostas nos anos recentes. Essas técnicas incluem: estimação dos parâmetros do sinal por técnica de invariância rotacional (ESPRIT), métodos baseados em Prony, Elemento linear adaptativo (ADALINE), filtro de Kalman, métodos baseados em PLL, e Redes Neurais Artificiais (RNA) [3].

Este trabalho modela o problema da estimação de harmônicos e interharmônicos como uma tarefa de separação cega de fontes e o resolve usando o algoritmo de Análise de Componentes Independentes de Canal Único (SCICA - *Single Channel Independent Component Analysis*) [5] a fim de estimar cegamente harmônicos e interharmônicos de um único sinal, sem necessitar de conhecimento prévio sobre a frequência fundamental do sistema elétrico e dos componentes harmônicos/interharmônicos. Em [6], uma abordagem similar foi proposta para estimar cegamente distúrbios individuais de Qualidade da Energia Elétrica (QEE) em um cenário de distúrbios múltiplos, sem prévio conhecimento das formas de onda dos distúrbios individuais nem como estão misturados.

A SCICA é um caso especial da ICA multicanal (*MICA - Multichannel Independent Component Analysis*) [7] aplicada a vetores de amostras atrasadas do mesmo sinal. Isso implica

Marcelo A. A. Lima, Augusto S. Cerqueira, Patrick Santos de Oliveira, Carlos A. Duque, Departamento de Circuitos Elétricos, Universidade Federal de Juiz de Fora, Juiz de Fora-MG, Brasil, E-mails: marcelo.lima@ufjf.edu.br, augusto.santiago@ufjf.edu.br, patrick.oliveira@ifmg.edu.br, carlos.duque@ufjf.edu.br. Danton D. Ferreira, Departamento de Engenharia, Universidade Federal de Lavras, Lavras-MG, Brasil, danton@deg.ufla.br.

que múltiplos componentes estimados pela ICA podem ser associados com uma fonte única independente. Assim, um estágio de pós-processamento é necessário para agrupar os componentes associados com a mesma fonte. A aplicação da SCICA resulta em um conjunto de filtros lineares em que os coeficientes são derivados da estimação da ICA. Como os componentes harmônicos/interharmônicos são estatisticamente independentes e espectralmente não sobrepostos entre si, o método pode identificar cegamente, separar e reconstruir os componentes de frequência individuais do modelo de sinal de componentes múltiplas.

Este trabalho é organizado da seguinte forma: A Seção II apresenta brevemente uma revisão sobre a análise de harmônicos/interharmônicos baseada na TDF, a Seção III apresenta a ICA, a Seção IV apresenta em mais detalhes o algoritmo SCICA, a Seção V propõe a aplicação da SCICA para decompor cegamente um sinal em seus componentes harmônicos e interharmônicos e comparar os resultados com os obtidos pela TDF. Finalmente, a Seção VI apresenta as conclusões sobre este trabalho.

II. ANÁLISE DE HARMÔNICOS/INTERHARMÔNICOS BASEADA NA TDF

Para um sinal elétrico contínuo no tempo $x(t)$, a forma discreta no tempo $x[n]$ de comprimento finito N amostrado no intervalo de tempo Δt pode ser representado com H componentes senoidais com ruído como:

$$x[n] = \sum_{h=1}^H a_h \cos(\omega_h n \Delta t + \phi_h) + w[n], \quad (1)$$

onde a_h é a amplitude, ϕ_h é o ângulo de fase inicial, $\omega_h = 2\pi f_h$ é a frequência angular harmônica ou interharmônica, f_h é a frequência harmônica ou interharmônica em Hertz, e $w[n]$ representa a adição de ruído branco. Alternativamente, o modelo em (1) pode também ser expressado na forma complexa:

$$x[n] = \sum_{h=1}^{2H} A_h e^{jn\omega_h \Delta t} + w[n], \quad (2)$$

onde $A_h = a_h e^{j\phi_h}/2$ é a amplitude complexa.

A exatidão da TDF é altamente dependente da variação de frequência do sistema elétrico quando a frequência de amostragem é fixada. Em adição, o efeito "picked-fence" pode levar a estimação imprecisa devido à resolução insuficiente quando o sinal contém interharmônicos. A resolução da frequência Δf_{DFT} na TDF é o mínimo intervalo distinguível no espectro de frequência, o qual é definido como:

$$\Delta f_{DFT} = \frac{f_s}{N} = \frac{1}{T_w}, \quad (3)$$

onde N é o número de pontos amostrados do sinal na frequência de amostragem f_s e T_w é a duração da janela de observação. Para fornecer uma resolução de frequência adequada, o padrão 61000-4-7 da Comissão Eletrotécnica Internacional (IEC - *International Electrotechnical Commission*) recomenda uma janela de análise de 200 ms para obter uma resolução de frequência da TDF de 5 Hz [8]. Entretanto,

este valor é geralmente incapaz de decompor corretamente os interharmônicos com frequências que não são múltiplas inteiras da resolução da frequência.

III. ANÁLISE DE COMPONENTES INDEPENDENTES

A ICA de um vetor $\mathbf{x} = [x_1, x_2, \dots, x_M]^T$ consiste em determinar uma transformação linear $\mathbf{y} = \mathbf{W} \cdot \mathbf{x}$ que maximiza a independência estatística entre os elementos de um vetor $\mathbf{y} = [y_1, y_2, \dots, y_P]^T$ [7].

Assumindo que os elementos do vetor \mathbf{x} são modelados como combinações lineares dos elementos do vetor $\mathbf{s} = [s_1, s_2, \dots, s_P]^T$, isso pode ser escrito na forma matricial:

$$\mathbf{x} = \mathbf{A} \cdot \mathbf{s}, \quad (4)$$

onde os elementos de \mathbf{s} são mutuamente independentes e \mathbf{A} corresponde à matriz de misturas de dimensão $M \times P$.

Este modelo descreve como os dados observados x_m são gerados a partir de um processo de mistura de fontes s_p . Os componentes independentes s_p não são diretamente observados. Além disso, os coeficientes da matriz de misturas \mathbf{A} são assumidos desconhecidos. Portanto, existe conhecimento apenas dos dados observados x_m , e a matriz \mathbf{A} tal qual os componentes independentes s_p devem ser estimados a partir de \mathbf{x} [7].

Existem vários algoritmos para estimar a matriz de separação \mathbf{W} a partir das misturas usando certas propriedades estatísticas das fontes de sinais, como não gaussianidade, estrutura temporal, cumulantes cruzados e não estacionaridade. O trabalho em [7] apresenta um bom resumo destes algoritmos.

IV. ICA DE CANAL ÚNICO

Comparando a forma de (1) com (4), pode-se observar que o modelo de harmônico/interharmônico e o modelo de ICA são muito similares um ao outro. A principal diferença entre eles é que a saída de (4) é vetorial (múltiplos canais), enquanto que a saída de (1) é escalar (canal único). Para aplicar a ICA e estimar componentes harmônicos e interharmônicos, é necessário mudar o modelo de saída única (1) para o modelo de saída múltipla. Para tanto, o algoritmo SCICA é usado.

O algoritmo SCICA inicialmente faz um janelamento do sinal $x[n]$, obtendo uma sequência de M blocos contíguos \mathbf{x}' (cada um com tamanho K), da seguinte maneira:

$$\mathbf{x}'[m] = [x[m\tau] \quad x[m\tau + 1] \quad \dots \quad x[m\tau + K - 1]]^T, \quad (5)$$

onde $m = 1, 2, \dots, M$ é o índice do bloco, τ é uma constante de atraso de tempo discreto tipicamente igual a 1, e $K = N - M\tau + 1$ amostras. A fim de manter o comprimento original do sinal de entrada, um acréscimo de $M\tau - 1$ amostras igual a zero é inserido antes do primeiro elemento de cada bloco $\mathbf{x}'[m]$, da seguinte forma:

$$\mathbf{x}[m] = \overbrace{[0 \quad 0 \quad \dots \quad 0]}^{M\tau-1} \mathbf{x}'[m]^T. \quad (6)$$

Assim, uma matriz \mathbf{X} é formada como um conjunto de observações $\mathbf{x}[m]$, do modo a seguir:

$$\mathbf{X} = [\mathbf{x}[1] \quad \mathbf{x}[2] \quad \dots \quad \mathbf{x}[M]]^T. \quad (7)$$

Cada linha da matriz \mathbf{X} corresponderá a uma diferente observação. Então, um algoritmo ICA padrão (como o FastICA [7]) é aplicado na matriz \mathbf{X} para estimar as matrizes de mistura e de separação, \mathbf{A} e \mathbf{W} , respectivamente.

Como a ICA busca pela independência estatística da transformação linear $\mathbf{Y} = \mathbf{W}\mathbf{X}$, então para cada coluna k da matriz \mathbf{Y} ($k = 1, \dots, K$), e para $m = 1, \dots, M$, obtém-se:

$$\mathbf{y}[M\tau + k - 1] = \begin{bmatrix} \sum_{m=1}^M \mathbf{W}_{(1,m)} x[m\tau + k - 1] \\ \sum_{m=1}^M \mathbf{W}_{(2,m)} x[m\tau + k - 1] \\ \vdots \\ \sum_{m=1}^M \mathbf{W}_{(P,m)} x[m\tau + k - 1] \end{bmatrix}. \quad (8)$$

Substituindo $n = M\tau + k - 1$, obtém-se:

$$\mathbf{y}[n] = \begin{bmatrix} \sum_{m=0}^{M-1} \mathbf{W}_{(1,M-m)} x[n - m\tau] \\ \sum_{m=0}^{M-1} \mathbf{W}_{(2,M-m)} x[n - m\tau] \\ \vdots \\ \sum_{m=0}^{M-1} \mathbf{W}_{(P,M-m)} x[n - m\tau] \end{bmatrix}, \quad (9)$$

para $n = M\tau, M\tau + 1, \dots, M\tau + K - 1$ e $\mathbf{y}[n] = [y_1[n], y_2[n], \dots, y_P[n]]^T$. Portanto, para $\tau = 1$, cada componente independente estimado $y_p[n]$ é equivalente à versão filtrada de $x[n]$, onde $y_p[n] = w_p[-n] * x[n]$ e $w_p[-n]$ é um filtro de resposta ao impulso finita (FIR - *Finite Impulse Response*) [9] associado com o vetor linha $\mathbf{W}_{(p,:)}$. Em outras palavras, pode-se dizer que a matriz estimada \mathbf{W} é um banco de filtros de análise, que segmenta o sinal $x[n]$ em P bandas de frequência. No entanto, é de interesse transformar os sinais separados de volta ao domínio de observação original. Consequentemente, um banco de filtros de síntese é necessário para reconstruir o sinal $x[n]$. Na ICA padrão, para cada fonte os sinais separados podem ser transformados de volta ao domínio de observação pela aplicação de pares de operações de separações e misturas:

$$\mathbf{x}_s^{(p)} = \mathbf{A}_{(:,p)} \mathbf{W}_{(p,:)} \mathbf{x}, \quad (10)$$

onde $\mathbf{x}_s^{(p)}$ é a p -ésima fonte no domínio de observação. Uma boa propriedade de mapear as fontes de volta ao domínio de observação é que tem-se uma perfeita reconstrução:

$$\mathbf{x} = \sum_p \mathbf{x}_s^{(p)}. \quad (11)$$

Aplicando (10) em cada estimativa $y_p[n]$ em (9) para $\tau = 1$, obtém-se:

$$\mathbf{x}_s^{(p)}[n] = \mathbf{A}_{(:,p)} \sum_{m=0}^{M-1} \mathbf{W}_{(p,M-m)} x[n - m]. \quad (12)$$

Para estimar o escalar $x_s^{(p)}[n]$, em [5] é proposto o uso da técnica de “cycle-spinning” [10]. Basicamente, para cada linha do vetor $\mathbf{x}_s^{(p)}[n]$, o sinal $y_p[n]$ é transladado por um deslocamento à direita $j \in [0, M - 1]$, e as M estimativas são linearmente ponderadas para obter a estimativa $x_s^{(p)}[n]$. Então, a separação é dada por:

$$\begin{aligned} x_s^{(p)}[n] &= \frac{1}{M} \sum_{j=0}^{M-1} \mathbf{A}_{(j+1,p)} \sum_{m=0}^{M-1} \mathbf{W}_{(p,M-m)} x[n - m - j] \\ &= \frac{1}{M} a_p[n] * w_p[-n] * x[n], \end{aligned} \quad (13)$$

onde $a_p[n]$ é um filtro FIR associado com o vetor coluna $\mathbf{A}_{(:,p)}$. Pode ser visto agora que a estimativa é uma versão filtrada de $x[n]$ obtida por uma cascata de dois filtros, para os quais os coeficientes foram estimados cegamente pela ICA.

Suponha que o sinal observado, $x[n]$, admita uma decomposição executada pela ICA quando aplicada a uma representação por meio de atrasos temporais. Representando a decomposição por uma soma de processos aleatórios mutuamente independentes, $x_c[n]$, tem-se:

$$x[n] = \sum_{c=1}^C x_c[n]. \quad (14)$$

Neste trabalho, a clusterização das estimativas de componentes independentes associadas a uma mesma fonte é proposta primeiro calculando-se a magnitude das funções de transferência para as bases estimadas da ICA: $|A_p(\omega)|^2$. Os P componentes individuais são então clusterizados em grupos γ_c , $c = 1, \dots, C$, baseado na similaridade de $|A_p(\omega)|^2$ usando o algoritmo de clusterização *k-means* [11]. Finalmente, o filtro de separação/reconstrução para cada fonte c é definido como:

$$f_c[n] = \frac{1}{M} \sum_{p \in \gamma_c} a_p[n] * w_p[-n], \quad (15)$$

e $x_c[n] = f_c[n] * x[n]$.

V. DECOMPOSIÇÃO DE HARMÔNICOS/INTERHARMÔNICOS BASEADA EM SCICA

Ao passo que qualquer algoritmo de ICA pode ser usado para estimar componentes independentes, grande economia de esforço computacional pode ser obtida usando um algoritmo que faça uso de pré-branqueamento, tal como o FastICA. Isso pode ser eficientemente implementado usando a Análise de Componentes Principais (PCA) [7], a qual provavelmente pode proporcionar redução da dimensão projetando para zero os valores de “bins” de frequência contendo baixa energia [5]. Se a PCA não puder reduzir a dimensão, a aplicação permanece apropriada porque ela reduz aproximadamente pela metade o número de parâmetros a serem estimados pela ICA [7].

O processo de estimação de harmônicos/interharmônicos baseado em SCICA pode ser resumido em:

- 1) Gerar a matriz \mathbf{X} a partir de $x[n]$ usando (5), (6) e (7), sequencialmente.
- 2) Aplicar o algoritmo FastICA (com pré-branqueamento executado pela PCA) à matriz \mathbf{X} para estimar a matriz de misturas \mathbf{A} e a matriz de separação \mathbf{W} .
- 3) Calcular a magnitude da função de transferência dos vetores base $a_p[n]$ e clusterizar em grupos γ_c , para $c = 1, \dots, C$, usando o algoritmo *k-means*.
- 4) Calcular os filtros de separação e reconstrução, $f_c[n]$, para cada fonte c usando (15), e filtrar $x[n]$ usando tais filtros para reconstruir as fontes.

A. Resultados

O exemplo abaixo ilustra a aplicação do método de decomposição proposto em um sinal $x[n]$ definido como:

$$\begin{aligned} x[n] = & 30\text{sen}(2\pi f_1 n\Delta t + \pi/6) + 380\text{sen}(2\pi f_2 n\Delta t) \\ & + 20\text{sen}(2\pi f_3 n\Delta t + \pi/3) + 45\text{sen}(2\pi f_4 n\Delta t + \pi/2) \quad (16) \\ & + 152\text{sen}(2\pi f_5 n\Delta t + \pi/3), \end{aligned}$$

onde $f_1 = 48,4$ Hz, $f_2 = 60,5$ Hz, $f_3 = 96,8$ Hz, $f_4 = 211,75$ Hz e $f_5 = 302,5$ Hz. Assumindo que a frequência nominal do sistema de potência é 60 Hz, então concluímos que o sinal acima apresenta um desvio de frequência. Em adição, existem quatro componentes interharmônicos. Seja a frequência de amostragem $f_s = 1000$ Hz e o comprimento da janela $N = 300$ amostras. De acordo com (3), neste caso a resolução de frequência da TDF é $\Delta f_{DFT} = 3,33$ Hz. Portanto, a TDF é incapaz de decompor corretamente os interharmônicos, já que eles não são múltiplos inteiros de Δf_{DFT} . Além disso, o desvio da frequência fundamental irá contribuir para o efeito de vazamento espectral.

Aplicando o algoritmo FastICA¹ a um conjunto de observações que são versões atrasadas de $x[n]$ gerado de acordo com (5), (6) e (7) para $M = 60$ blocos, $\tau = 1$ amostra e $N = 300$ amostras, resultou na estimação de componentes independentes mostrada na Fig. 1. Note que a PCA aplicada antes da ICA no algoritmo da FastICA reduziu a dimensão de 60 para apenas 10, promovendo grande redução de esforço computacional. O resultado da estimação de componentes independentes Fig. 1 foi obtido aplicando (13) ao sinal $x[n]$, onde suas escalas foram recuperadas projetando-os no domínio da observação original. Pode ser visto que cada componente independente estimada é uma versão filtrada de $x[n]$, e existem múltiplas estimativas associadas ao mesmo componente harmônico/interharmônico.

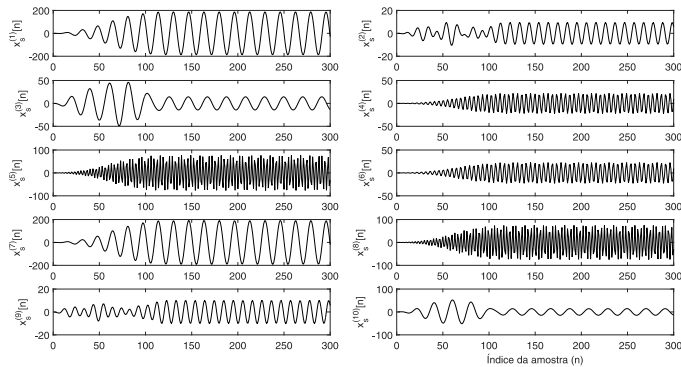


Fig. 1. Estimativas de componentes independentes com escalas recuperadas.

A Fig. 2 mostra as magnitudes das funções de transferência para cada coluna da matriz \mathbf{A} quando interpretadas como filtros. Usando o algoritmo *k-means*, essas colunas foram agrupadas em 5 clusters ($C = 5$) baseado em suas similaridades espectrais, já que esperam-se que 5 componentes harmônicos e interharmônicos sejam separados e reconstruídos

¹Neste trabalho, um pacote de funções livres que executam o algoritmo em ambiente Matlab foi usado. Esse pacote pode ser baixado em <http://www.cis.hut.fi/projects/ica/fastica/>

pelo algoritmo SCICA. As legendas dos clusters também foram incluídas na figura. Como se pode ver, as colunas 4 e 6 foram agrupadas no cluster 1 (ou γ_1), as colunas 1 e 7 foram agrupadas no cluster 2 (ou γ_2), as colunas 3 e 10 foram agrupadas no cluster 3 (ou γ_3), as colunas 5 e 8 foram agrupadas no cluster 4 (ou γ_4) e as colunas 2 e 9 foram agrupadas no cluster 5 (ou γ_5). De fato, voltando à Fig. 1, pode-se ver que os componentes independentes 1 e 7 estão associados a um mesmo componente de frequência de $x[n]$, os componentes independentes 2 e 9 estão associados a um outro componente de frequência de $x[n]$, os componentes independentes 3 e 10 estão associados a outro componente de frequência de $x[n]$, os componentes independentes 4 e 6 estão associados a outro componente de frequência de $x[n]$, e os componentes independentes 5 e 8 estão ambos associados ao componente de frequência remanescente de $x[n]$.

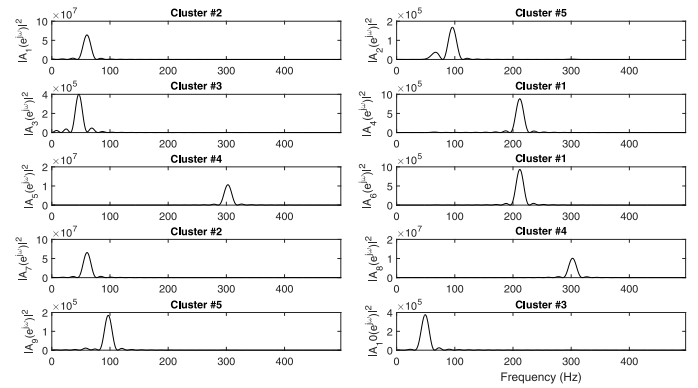


Fig. 2. Magnitudes das respostas em frequência para as funções base das colunas da matriz de misturas, \mathbf{A} , estimada pelo FastICA, e sua clusterização baseada em suas similaridades usando *k-means*.

Na Fig. 2, pode-se ver que o cluster γ_1 parece representar o subespaço independente associado ao interharmônico 211,75 Hz, já que o lóbulo principal do filtro está centrado em volta dessa frequência. O cluster γ_2 parece representar o subespaço independente do harmônico 60,5 Hz, o cluster γ_3 parece representar o subespaço do interharmônico 48,4 Hz, o cluster γ_4 parece representar o subespaço do interharmônico 302,5 Hz e o cluster γ_5 parece representar o subespaço do interharmônico 96,8 Hz.

Agrupando os componentes independentes em mais de 5 clusters resultaria em mais de um filtro de separação correspondente a um mesmo componente harmônico ou interharmônico. Por outro lado, agrupando-os em menos de 5 clusters resultaria em filtros de separação com significativa sobreposição espectral. Conseqüentemente, tais situações poderiam ser descontadas.

Oteve-se então 5 conjuntos de filtros ($f_1[n]$, $f_2[n]$, $f_3[n]$, $f_4[n]$ e $f_5[n]$) passa-faixas com aproximadamente a mesma largura da faixa de passagem, e cinco subespaços independentes com dimensão dois cada um. A dimensão é uma função da largura de banda dos componentes separados, como previsto pela teoria [5]. Conforme cada componente de frequência harmônica ou interharmônica é um componente de frequência única, a dimensão é a mesma para os cinco subespaços. Para extrair os componentes individuais resultantes, constrói-

se os filtros, através de (15), e filtra-se o sinal $x[n]$ com eles. A Fig. 3 ilustra os sinais de saída dos cinco filtros. Depois do estágio transitório de filtragem, os cinco filtros estimaram corretamente a amplitude e a frequência dos cinco componentes.




Fig. 3. Componentes separados e reconstruídos obtidos pelos filtros adaptativos SCICA; (a) filtro $f_1[n]$: interarmônico 211,75 Hz, (b) filtro $f_2[n]$: harmônico 60,5 Hz, (c) filtro $f_3[n]$: interarmônico 48,4 Hz, (d) filtro $f_4[n]$: interarmônico 302,5 Hz e filtro $f_5[n]$: interarmônico 96,8 Hz.

A Fig. 4 mostra as magnitudes da respostas em frequência dos filtros adaptativos resultantes $f_1[n]$, $f_2[n]$, $f_3[n]$, $f_4[n]$ e $f_5[n]$ obtidos pela SCICA, ao longo do espectro de frequências de $x[n]$ ($|X(e^{j\omega})|$). Para fins de comparação, a figura também mostra a TDF de $x[n]$ calculada para o comprimento de janela de $N = 300$ amostras. Pode ser visto que o filtro $f_1[n]$ é um filtro passa faixa que passa o interarmônico de 211,75 Hz com ganho quase unitário e rejeita os outros harmônicos e interarmônicos. Por outro lado, o filtro $f_2[n]$ é um filtro passa faixa que permite o harmônico 60,5 Hz e rejeita os demais componentes. O filtro $f_3[n]$ é um filtro passa faixa que passa apenas o interarmônico 48,4 Hz. Já $f_4[n]$ é um filtro passa faixa que passa apenas o interarmônico 302,5 Hz e, finalmente, o filtro $f_5[n]$ é um filtro passa faixa que permite apenas o interarmônico 96,8 Hz e rejeita os demais interarmônicos. Deve-se reforçar a característica não supervisionada desses filtros, conforme são capazes de adaptativamente extrair as fontes individuais mesmo que a única informação que o algoritmo SCICA conheça sobre as fontes seja o sinal $x[n]$.

O espectro da TDF mostra os erros inerentes à amostragem assíncrona do sinal $x[n]$ como também sua resolução insuficiente Δf_{DFT} . Os erros do vazamento espectral introduzem componentes de energia e valores de frequência não existentes e o efeito “picket-fence” não permite que nenhum componente harmônico ou interarmônico verdadeiro de $x[n]$ seja estimado. Destes resultados, pode ser concluído que o método de decomposição proposto baseado em SCICA obteve melhores resultados do que a TDF para estimar precisamente os harmônicos e interarmônicos nessas condições não ideais onde a TDF falha.

VI. CONCLUSÕES

Este trabalho apresentou em detalhes o algoritmo SCICA e propôs uma aplicação para estimar harmônicos e interarmônicos em formas de onda do sistema elétrico. O algoritmo SCICA permite o uso da ICA para realizar cegamente a




Fig. 4. Magnitudes da resposta em frequência dos filtros adaptativos não supervisionados obtidos pela SCICA.

separação de fontes a partir dos dados de um canal único. Como a operação da SCICA é equivalente a um banco de filtros adaptativos lineares que podem separar espectralmente componentes independentes não adjacentes de um sinal, esta aplicação pôde adequadamente separar e reconstruir os componentes harmônicos e interarmônicos individuais do sinal mesmo quando o processo de amostragem é assíncrono e a resolução de frequência não é um divisor inteiro das frequências interarmônicas. Uma comparação com a TDF mostrou que o método de decomposição baseado na SCICA proposto foi mais preciso em realizar a estimação espectral quando as condições ideais para operação da TDF não foram satisfeitas.

REFERÊNCIAS

- [1] T. X. Zhu, “Exact Harmonics/Interharmonics Calculation Using Adaptive Window Width,” *IEEE Transactions on Power Delivery*, vol. 22, no. 4, pp. 2279–2288, 2007.
- [2] J. R. Carvalho, C. A. Duque, M. A. A. Lima, D. V. Coury, and P. F. Ribeiro, “A Novel DFT-based method for spectral analysis under time-varying frequency conditions,” *Electric Power Systems Research*, vol. 108, pp. 74–81, 2014.
- [3] C.-I. Chen and Y.-C. Chen, “Comparative Study of Harmonic and Interharmonic Estimation Methods for Stationary and Time-Varying Signals,” *IEEE Transactions on Industrial Electronics*, vol. 61, no. 1, pp. 397–404, 2014.
- [4] D. D. Ferreira, E. A. Nagata, S. C. Ferreira, J. M. de Seixas, C. A. Duque, C. A. G. Marques, J. D. S. Guedes, and A. S. Cerqueira, “Method based on independent component analysis for harmonic extraction from power system signals,” *Electric Power Systems Research*, vol. 119, pp. 19–24, 2015.
- [5] M. E. Davies and C. J. James, “Source Separation Using Single Channel ICA,” *Signal Processing*, vol. 87, no. 8, pp. 1819–1832, 2007.
- [6] D. V. Coury, M. A. A. Lima, and A. S. Cerqueira, “An ICA-based method for adaptive decomposition of multiple PQ disturbances,” in *Harmonics and Quality of Power (ICHQP), 2012 IEEE 15th International Conference on*, June 2012, pp. 168–173.
- [7] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Component Analysis*. John Wiley & Sons, 2001.
- [8] IEC Std. 61000-4-7, *Testing and Measurement Techniques: General Guide on Harmonics and Interharmonics Measurements and Instrumentation, for power supply systems and equipment connected thereto*, 2009.
- [9] S. K. Mitra, *Digital Signal Processing: A Computer-Based Approach*, 3rd ed. Tata McGraw-Hill, 2006.
- [10] R. R. Coifman and D. L. Donoho, “Translation-invariant denoising,” in *A. Antoniadis, G. Oppenheim (Eds.), Wavelets and Statistics, Springer Lecture Notes in Statistics*, vol. 103, 1995, pp. 126–150.
- [11] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Prentice Hall, 2008.