

Análise Comparativa de Algoritmos de ICA para Decomposição de Múltiplos Distúrbios de Qualidade da Energia Elétrica

Daniel R. de Oliveira

Marcelo A. A. Lima

Patrick S. de Oliveira

Universidade Federal de Juiz de Fora

E-mails: daniel.ramalho@engenharia.ufjf.br,

marcelo.lima@ufjf.edu.br,

patrick.oliveira@ifmg.edu.br

Resumo — A ocorrência de distúrbios simultâneos que afetam a Qualidade da Energia Elétrica (QEE) na tensão e/ou corrente é um fato possível, já que múltiplas fontes geradoras de distúrbios podem ocorrer ao mesmo tempo. Existem trabalhos na literatura que abordam a decomposição de formas de onda contendo múltiplos distúrbios de QEE utilizando-se a técnica de Análise de Componentes Independentes (ICA), o que confere uma característica adaptativa e não supervisionada aos métodos, pois esta é uma técnica utilizada para separação cega de fontes. Este artigo apresenta uma análise comparativa de dois desses métodos, aplicados com diferentes algoritmos de ICA. Tal estudo aborda os erros de estimação, os tempos de processamento e a influência de ruído na separação de algumas combinações de distúrbios.

Palavras-chaves — Análise de Componentes Independentes, Múltiplos Distúrbios, Qualidade da Energia Elétrica, Separação Cega de Fontes.

I. INTRODUÇÃO

A Qualidade da Energia Elétrica (QEE) tem se tornado tema cada vez mais comum em diversas áreas do Sistema Elétrico de Potência (SEP), setores da indústria, e até mesmo na comunicação digital. O tema também trata sobre o aumento da produção, do racionamento de energia e da vida útil dos diversos equipamentos, além do funcionamento e eficiência energética dos equipamentos industriais.

Distúrbios da QEE são definidos como distúrbios eletromagnéticos que alteram a tensão e/ou corrente, afetando a amplitude, frequência e/ou a forma de onda do sinal de potência [1]. Para poder identificar os distúrbios, utilizam-se métodos de separação eficientes, uma vez que diferentes distúrbios podem ocorrer de forma simultânea, como por exemplo, um sistema elétrico que apresenta um conjunto de harmônicos e sofre o chaveamento de um banco de capacitores produzindo assim um transitório oscilatório [1].

Neste trabalho, aplica-se a Análise de Componentes Independentes (ICA – *Independent Component Analysis*), como técnica de Separação Cega de Fontes (BSS – *Blind Source Separation*), para a decomposição não-supervisionada de sinais contendo distúrbios de QEE. Em conjunto com a ICA, são utilizados métodos de pré-processamento do sinal elétrico disponível, realizando ainda, ao final do processo, a

recuperação das amplitudes das formas de onda dos distúrbios estimados, a partir da matriz de separação obtida com a ICA e do agrupamento das fontes independentes.

Os objetivos do presente trabalho são comparar diferentes algoritmos de ICA, utilizando-se dois diferentes métodos de pré-processamento para ICA de canal único [1], e analisar o desempenho da separação realizada com relação aos erros entre os componentes de distúrbio originais e suas estimativas. Além disso, são comparados os tempos de processamento dos algoritmos de ICA, considerando para tanto, um cenário com ruído.

O artigo está organizado da seguinte forma: a Seção II realiza uma breve revisão da ICA e de seus algoritmos que serão empregados; a Seção III trata dos métodos de ICA de canal único empregados neste trabalho; a Seção IV apresenta os resultados de simulação dos algoritmos de ICA para decomposição de distúrbios de QEE e a Seção V expõe as conclusões a respeito deste trabalho.

II. ANÁLISE DE COMPONENTES INDEPENDENTES

A ICA é uma técnica estatística e computacional que sem conhecimento prévio sobre as fontes de um sinal possibilita a sua separação em componentes independentes.

A técnica assume a hipótese de que as fontes que compõem um determinado modelo de misturas são mutuamente independentes. Tem-se então o objetivo de estimar as fontes independentes na saída de filtros de separação, tendo-se disponível apenas as misturas. Assim, é imposta uma restrição sobre a função densidade de probabilidade das fontes, onde, no máximo uma das fontes seja gaussiana [3]. Pode-se dizer então que a ICA difere de técnicas tradicionais utilizadas na área, como por exemplo, a Análise de Componentes Principais (PCA – *Principal Component Analysis*), pois supõe que seus componentes são estatisticamente independentes, ou tem dependência minimizada, e são não-gaussianos [4].

Para definir a ICA matematicamente, utiliza-se um modelo estatístico de variáveis latentes, ou seja, variáveis não diretamente observáveis, mas, através de propriedades de outras variáveis, as quais são observáveis.

Suponha que n variáveis aleatórias observadas $(x_1, x_2, \dots, x_n)$ sejam misturas medidas por sensores. Suponha

também que essas misturas sejam formadas por combinações lineares de n variáveis aleatórias estatisticamente independentes, por definição $(s_1, s_2, \dots, s_n)$, de tal forma que:

$x_i = a_{i1} * s_1 + a_{i2} * s_2 + \dots + a_{in} * s_n$, para $i, j = 1, 2, \dots, n$. Onde os a_{ij} são os coeficientes das misturas.

Na forma matricial tem-se:

$$\mathbf{x} = \mathbf{A} * \mathbf{s} \quad (1)$$

Como apenas o valor de $\mathbf{x}$ é conhecido, deve-se estimar o valor da matriz de misturas $\mathbf{A}$ para então estimar as variáveis aleatórias $\mathbf{s}$.

$$\mathbf{s} = \mathbf{A}^{-1} * \mathbf{x} : \mathbf{s} = \mathbf{W} * \mathbf{x} \quad (2)$$

Como $\mathbf{A}$ é desconhecido, pode-se estimar o valor de $\mathbf{A}'$, de modo que:

$$\mathbf{y} = \mathbf{A}'^{-1} * \mathbf{x} : \mathbf{y} = \mathbf{W}' * \mathbf{x} \quad (3)$$

Dentre os algoritmos de ICA propostos na literatura, pode-se separá-los em dois grupos principais: aqueles que utilizam Estatísticas de Segunda Ordem (ESO) e os que utilizam Estatísticas de Ordem Superior (EOS) [5]. Neste trabalho foram utilizados dois algoritmos de cada grupo.

A. Algoritmos ESO

Algoritmo para Extração de Múltiplos Sinais (AMUSE – *Algorithm for Multiple Unknown Source Extraction*): Este algoritmo parte da hipótese de que as autocovariâncias das fontes são diferentes. Utiliza decomposições dos autovalores de uma matriz de covariância atrasada no tempo [5].

Identificação Cega de Segunda Ordem (SOBI – *Second Order Blind Identification*): Este algoritmo combina e, conjuntamente, diagonaliza diversas matrizes de covariância atrasadas no tempo [5]. Por isso, o algoritmo SOBI tende a apresentar uma complexidade computacional maior do que o AMUSE.

B. Algoritmos EOS

Algoritmo Aproximado de Diagonalização de Auto-matrizes (JADE – *Joint Approximate Diagonalization of Eigen-matrices*): Este método pode ser entendido como uma generalização da diagonalização das matrizes de covariâncias, utilizando-se cumulantes [5].

Análise de Componentes Independentes de Ponto Fixo (FastICA – *Fixed-Point ICA*): Seu princípio é maximizar a não-gaussianidade do sinal e encontrar um componente independente a cada iteração do algoritmo, ortogonalizando cada vetor de saída entre si [6].

III. MÉTODOS DE APLICAÇÃO DE ICA PARA CANAL ÚNICO

Como a ICA é uma técnica desenvolvida para aplicação em sinais provenientes de múltiplas fontes (multicanal) e assume-se neste trabalho uma única fonte de observação (canal único), é necessário um pré-processamento dos dados a fim de preparar a matriz de observações para aplicação adequada dos algoritmos de ICA. Nesse contexto, são utilizados o método FICA e o método SCICA [1].

A. Método FICA (Filtros ICA)

Proposto em [1], este método gera sinais observáveis através da utilização de um banco de filtros *Finite-duration Impulse Response* (FIR) pré-projetados, onde cada filtro é responsável pelo fornecimento de um diferente sinal observável para a ICA. O método também realiza a recuperação das amplitudes dos componentes independentes estimados, baseado no algoritmo de mínimos quadrados estocástico (LMS – *Least Mean Squares*), para garantir que as fontes estimadas estejam de volta ao mesmo domínio das fontes de observação. Este procedimento se faz necessário porque a ICA não recupera as escalas das fontes independentes, tendo em vista que ela não tem o conhecimento prévio das fontes e nem de como elas se encontram misturadas.

É apresentado na Figura 1 o diagrama de blocos do método FICA, onde o sinal de entrada $x[n]$ é inicialmente filtrado por M filtros FIR, resultando na matriz de observações $\mathbf{X}$. Para que a separação seja adequada M deve ser maior que a quantidade de fontes presentes no sinal. Em seguida, a técnica de ICA estima a matriz de componentes independentes $\mathbf{Y}$, e por fim as amplitudes das estimativas de componentes independentes são recuperadas pelo algoritmo LMS.




Figura 1 - Diagrama de Blocos do Método FICA.

Este método possui a vantagem de requerer menos misturas quando comparado ao método SCICA, pois a ordem do banco de filtros de separação obtido pela ICA é igual à ordem do banco de filtros fixos de pré-processamento, o que, consequentemente, facilita o processamento das técnicas de ICA. No entanto, existe a dificuldade de separar sinais sobrepostos na frequência ou muito próximos no espectro de frequências [7].

B. Método SCICA (Single-channel ICA – ICA de Canal Único)

Baseado no método proposto em [7] e adaptado em [1], consiste em gerar uma matriz de observação por meio da aplicação de sucessivos atrasos temporais no sinal de entrada, de modo a aumentar o número de sinais observáveis disponibilizados para a ICA. Após a estimação das fontes, também é necessário um algoritmo de agrupamento das fontes estimadas, uma vez que a quantidade de atrasos gerados tende a ser superior à quantidade de componentes independentes estimados, acarretando em mais de um componente independente associado a uma mesma fonte.

Na Figura 2, é mostrado o diagrama de blocos do método SCICA. No bloco “Construção da matriz de observações”, são aplicados sucessivos atrasos temporais no sinal original $x[n]$ e, a partir das matrizes $\mathbf{A}$ e $\mathbf{W}$ obtidas pela ICA, o sinal original é filtrado, resultando em P componentes independentes estimados. Como P é maior que o número de fontes independentes presentes em $x[n]$, faz-se necessária uma etapa de agrupamento, geralmente realizada pelo algoritmo *k-means* [8]. Ressalta-se que esta etapa de grupamento é bastante importante, pois existem componentes de ruído ou sinais indesejados, que não devem ser agrupados, e estratégias devem ser desenvolvidas no sentido de definir apenas os componentes estimados de interesse [9].




Figura 2 - Diagrama de blocos do Método SCICA.

Uma das vantagens do método SCICA é o pré-processamento simples, que consiste em versões atrasadas do sinal original. Todavia, é necessária uma grande quantidade de

observações para gerar a independência estatística necessária aos algoritmos de ICA, o que se espera resultar tanto numa maior demanda computacional quanto da necessidade de um estágio de agrupamento dos componentes independentes.

IV. SIMULAÇÃO E RESULTADOS

Nesta seção serão apresentados os resultados obtidos com as simulações de diferentes algoritmos de ICA, implementados em dois métodos para canal único, FICA e SCICA, com o objetivo de avaliar o nível de erro da separação de distúrbios realizada para distintos cenários de múltiplos distúrbios.

Um algoritmo foi desenvolvido em ambiente Matlab®, pois sua natureza matricial e sua ampla biblioteca ajudaram no desenvolvimento da programação. Foram realizados experimentos com três combinações de distúrbios de QEE: harmônico com transitório oscilatório (C1), harmônico com transitório impulsivo (C2) e harmônico com *notch* (C3).

Foram escolhidas essas combinações pois os distúrbios analisados não apresentam sobreposição de espectro. Para cada combinação foram realizados cem testes, variando-se para os harmônicos sua amplitude e fase, para o transitório oscilatório seu tempo de decaimento e frequência de oscilação, para o transitório impulsivo seu tempo de decaimento e sua intensidade e ainda, a intensidade do *notch*. O Erro Quadrático Médio (EQM) foi calculado em relação ao distúrbio mais semelhante com o resultado da separação baseado no menor EQM. A frequência de amostragem utilizada para a geração de todos os sinais deste artigo foi $f_s = 15360$ Hz, sendo a frequência fundamental dos sinais igual a 60 Hz, o que confere uma amostragem de 256 amostras por ciclo.




Figura 3 – Melhor EQM para os testes realizados em C1.




Figura 4 – EQM do Distúrbio Harmônico (C1).

A Figura 3 apresenta o melhor resultado obtido a partir dos cem sinais gerados com a combinação de distúrbios C1, sendo que tal resultado foi obtido para o método FICA e o algoritmo de ICA AMUSE. Em vermelho estão as formas de onda dos distúrbios originais e em azul os distúrbios estimados pela ICA. Nesse caso, o algoritmo AMUSE teve um EQM de $5,34 \times 10^{-5}$ para o harmônico e $5,40 \times 10^{-5}$ para o transitório oscilatório.

As Figuras 4 e 5 mostram os gráficos de EQM relativos a C1, onde é possível observar que o método FICA obteve bom desempenho para todas as técnicas de ICA consideradas. A técnica AMUSE teve menor EQM para o

método FICA, sendo um pouco superior aos valores obtidos pelo FastICA. Vale ressaltar que o FastICA obteve bom desempenho para ambos os métodos FICA e SCICA, tendo o segundo melhor EQM do método FICA e o melhor valor do método SCICA.

Na Tabela 1 é apresentada a média do EQM dentre todos os cem testes realizados, para cada combinação de distúrbio, cada método de canal único e cada técnica de ICA. As incertezas dos valores dos testes foram calculadas de acordo com as Equações (4) e (5).




Figura 5 – EQM do Distúrbio Transitório Oscilatório (C1).

$$\sigma(EQM) = \sqrt{\frac{\sum_{k=1}^N (EQM_k - \overline{EQM})^2}{N-1}} \quad (4)$$




Figura 6 – EQM com a variação da relação sinal ruído.

$$\sigma(\overline{EQM}) = \frac{\sigma(EQM_k)}{\sqrt{N}} \quad (5)$$

Como pode ser observado, o algoritmo AMUSE aplicado no método FICA possui a menor média em todas as combinações. Outros aspectos que podem ser analisados são que o algoritmo SOBI obteve os piores resultados nas separações em C2 no método FICA, mas atingiu separações semelhantes aos demais algoritmos no método SCICA. Nas demais situações, o método FICA apresentou melhores resultados que os obtidos com o método SCICA.

Além do EQM, também foi observado o tempo de processamento de cada método de ICA para C1, mostrados na Tabela 2, onde é possível notar que a técnica AMUSE é a mais rápida independentemente do método, e que as técnicas JADE com método SCICA e SOBI com o método FICA, apesar de apresentarem bons resultados de EQM, apresentam um tempo de processamento mais lento.

É interessante notar na Tabela 2, como comentado na seção anterior, que com o pré-processamento utilizado no método FICA, esperava-se uma execução mais rápida quando comparado com o método SCICA. Essa diferença foi observada nos algoritmos JADE, AMUSE e FastICA, no entanto, a técnica SOBI foi mais rápida no método SCICA.

Já na Figura 6, mostra-se o desempenho das técnicas de ICA em função da Relação Sinal Ruído (SNR – *Signal-to-Noise Ratio*). Esse teste foi realizado mantendo-se as formas de onda dos dois distúrbios da combinação C1 mas diminuindo-se a SNR. Pode-se notar que os algoritmos FastICA, AMUSE e SOBI possuem desempenho semelhante, sendo que à medida que o nível de ruído aumenta, a média do EQM também aumenta.

Tabela 1. MÉDIA DO EQM DAS TÉCNICAS DE ICA PARA O MÉTODO FICA E SCICA.

Método FICA				
ICA	FastICA	SOBI	AMUSE	JADE
C1	2.60e-04 ± 0.07e-04	3.2e-04 ± 0.1e-04	2.60e-04 ± 0.07e-05	2.79e-04 ± 0.07e-04
C2	5.61e-04 ± 0.04e-04	2.1e-03 ± 0.1e-03	5.37e-04 ± 0.04e-04	6.9e-04 ± 0.1e-04
C3	3.41e-04 ± 0.06e-04	3.25e-04 ± 0.05e-05	3.11e-04 ± 0.04e-04	4.30e-04 ± 0.08e-04
Método SCICA				
ICA	FastICA	SOBI	AMUSE	JADE
C1	1.30e-03 ± 0.06e-03	3.1e-03 ± 0.1e-03	3.1e-03 ± 0.1e-03	1.93e-03 ± 0.06e-03
C2	6.557e-04 ± 0.005e-04	1.042e-03 ± 0.005e-03	1.022e-03 ± 0.007e-03	8.5e-04 ± 0.1e-04
C3	4.09e-03 ± 0.05e-03	4.22e-03 ± 0.04e-03	4.04e-03 ± 0.03e-03	4.51e-03 ± 0.06e-03

Nota-se que a curva de erro para a separação de harmônicos se situa sempre abaixo ou no mesmo nível da curva de erro para a separação do transitório oscilatório, e que para níveis de ruído maiores (menores SNRs), as estimativas do transitório oscilatório apresentam maiores EQMs. Isso se deve ao fato do ruído estar sendo agrupado agregado em sua maioria às estimativas do transitório oscilatório, pois tal distúrbio possui espectro mais amplo do que os harmônicos.

Tabela 2. TEMPO DE PROCESSAMENTO DAS TÉCNICAS DE ICA PARA O MÉTODO FICA E SCICA (C1).

Tempo de Processamento [s]				
ICA	Método	Máximo	Mínimo	Médio
FastICA	FICA	0,1175	0,0266	0,0305
	SCICA	0,7919	0,062	0,1059
SOBI	FICA	2,5399	2,0548	2, 3434
	SCICA	0,2651	0,1883	0,2115
AMUSE	FICA	0,0346	0,0259	0,0276
	SCICA	0,0417	0,028	0,0317
JADE	FICA	0,0373	0,026	0,0282
	SCICA	4,8999	0,6850	1,3035

V. CONCLUSÃO

Os resultados apresentados neste trabalho são um bom ponto de partida para se escolher o melhor método e a melhor técnica de ICA para realizar a separação de distúrbios de QEE no que tange o tempo de processamento e o erro considerado na estimação.

Observou-se que a técnica AMUSE apresentou ser melhor, analisando seu $\overline{EQM}$, em todas as combinações de distúrbios, sendo o FastICA e AMUSE com método FICA para C1, AMUSE com FICA para C2 e AMUSE com FICA para C3.

Observa-se que o método FICA obteve o melhor $\overline{EQM}$ para todas as combinações e que apesar da utilização de de menos sinais de observação no método FICA, o algoritmo SOBI teve execução mais rápida no método SCICA.

AGRADECIMENTOS

Os autores gostariam de agradecer o apoio do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora e o suporte financeiro da FAPEMIG, do CNPq e da CAPES para o desenvolvimento deste trabalho.

VI. REFERÊNCIAS

- [1] M. A. A. Lima, “Uma Nova Metodologia para Análise de Qualidade de Energia Elétrica sob Condições de Ocorrência de Múltiplos Distúrbios”, Tese de Doutorado, Universidade de São Paulo, 2013.
- [2] F. Sebastião e I. Oliveira, “Estudo de Séries Temporais na Análise em Componentes Principais e na Análise em Componentes Independentes”, *Proceedings de XVI Congresso Anual de SPE*, pp 3.
- [3] C. C. Cavalcante, “Sobre Separação Cega de Fontes: Proposição e Análise de Estratégias para Processamento Multi-Usuário”, Tese de Doutorado, Universidade Estadual de Campinas, 2004.
- [4] I.C.C. Leite, “Análise de Componentes Independentes Aplicada a Avaliação de Imagem Radiográfica de Sementes”, Tese de Doutorado, Universidade Federal de Lavras, 2013.
- [5] J. M. Faier, “Análise de Componentes Independentes para a Monitoração da Qualidade de Dados em Séries Temporais”, Universidade Federal do Rio de Janeiro, 2011, pp 28-42.
- [6] A. P. O. da Silva, “Uma Implementação de Análise de Componentes Independentes em Plataforma de Hardware Reconfigurável”, Universidade Federal do Rio Grande do Norte, 2010, pp 29-31.
- [7] Davies, M. E., James, C. J., “Source separation using single channel ICA”, *Signal Processing*, vol.87, no.8, pp1819–1832, 2007.
- [8] C. He e Q. Shu, “Separation and analyzing of harmonics and inter-harmonics based on single channel independent component analysis”, Sichuan University, 2013.
- [9] P. S. de Oliveira, M. A. A. Lima, A. S. Cerqueira, C. A. Duque e D. D. Ferreira, “Harmonic Extraction based on Independent Component Analysis and Quadrature Matched Filters”, *Proceedings of International Conference on Harmonics and Quality of Power*, Belo Horizonte, 2016.