

TÉCNICA DE COMPRESSÃO DE SINAIS DE OSCILOGRAFIA BASEADA NA VARIAÇÃO DO CONTEÚDO ESPECTRAL

VICTOR V. DE MORAIS, EDER B. KAPISCH, LEANDRO R. M. SILVA, CARLOS A. DUQUE

Departamento de Circuitos Elétricos, Universidade Federal de Juiz de Fora - UFJF

Rua José Lourenço Kelmer, s/n - São Pedro, Juiz de Fora - MG

*E-mails: victor.morais@engenharia.ufjf.br, eder.kapisch@engenharia.ufjf.br,
leandro.manso@ufjf.edu.br, carlos.duque@ufjf.edu.br*

Abstract— This paper proposes a signal compression technique for Electrical Power Systems waveform signals. The proposed technique is based on the spectral content variation of the analyzed voltage or current signal. The Fast Fourier Transform is used as the signal spectrum estimator. In order to show the advantages of the method, a comparison with another compression technique based on the Discrete Wavelet Transform is done. Results are presented from simulation tests. The proposed technique allows the entire reconstruction of the waveforms of the analyzed signals from the compressed data, keeping all relevant information present in the signal for further analysis and processing.

Keywords— Waveform Signal Compression, Smart Grids, Digital Signal Processing, Fast Fourier Transform, Discrete Wavelet Transform.

Resumo— Este artigo propõe uma técnica de compressão de sinais de forma de onda de Sistemas Elétricos de Potência. A técnica proposta é baseada na variação do conteúdo espectral do sinal analisado de tensão ou corrente. Como ferramenta de estimação do espectro utiliza-se a Transformada Rápida de Fourier. A fim de se mostrar as vantagens do método, é realizada uma comparação com outra técnica de compressão baseada na Transformada Wavelet Discreta. Resultados são apresentados a partir de testes de simulação. A técnica proposta permite a inteira reconstrução das formas de onda dos sinais analisados a partir dos dados comprimidos, mantendo-se toda a informação relevante presente no sinal para posterior análise e processamento.

Palavras-chave— Compressão de Sinais de Formas de Onda, Redes Elétricas Inteligentes, Processamento Digital de Sinais, Transformada Rápida de Fourier, Transformada Wavelet Discreta.

1 Introdução

O crescente desenvolvimento dos Sistemas Elétricos de Potência (SEP) ao redor do mundo tem contribuído para o aumento massivo da quantidade de dados proveniente das medições dos parâmetros dos sinais do SEP (Kapisch, et al., 2016).

Apesar de necessária para a estimação do estado da rede elétrica para uma eficaz operação, essa grande massa de dados pode causar problemas como congestionamento dos canais de comunicação e atrasos nos sistemas de proteção, devido ao tempo de transmissão despendido pelo transporte dos dados (Unterweger & Engel, Resumable Load Data Compression in Smart Grids, 2015).

A inserção de novas tecnologias no SEP, bem como a integração de todos os seus componentes de controle e comunicação tem sido relacionado pela literatura como o estabelecimento do novo contexto das Redes Elétricas inteligentes (REIs) (Khan J. , Bhuiyan, Murphy, & Williams, 2016). Pesquisas têm sido realizadas com o foco na transição das redes convencionais em REIs (Yu, Cecati, Dillon, & Simões, 2011; Arritt & Dugan, 2011).

Conforme as REIs se tornam realidade, o desenvolvimento de técnicas eficientes para a transmissão e armazenamento de dados se torna crucial (Cormane & Nascimento, 2016).

O desempenho de uma REI se baseia nas informações de relevância presente nos dados coletados dos medidores espalhados por ela. A partir dessas informações, a rede atua de forma inteligente em seus

diversos componentes a fim de se ajustar à atual condição e obter uma melhor eficiência na entrega da energia elétrica.

Algumas informações de interesse presentes na forma de onda podem ser essenciais para a estimação do estado do sistema e uma correta avaliação de sua operação. Essas informações apenas podem ser recuperadas caso haja um armazenamento completo das formas de onda dos sinais. Por exemplo, alguns equipamentos podem apresentar assinaturas elétricas únicas, vistas através das formas de onda de tensão e corrente. Distúrbios de alta frequência, como transientes oscilatórios, processos de chaveamento, ligamento de banco de capacitores, dentre outros, são unicamente visíveis através das formas de onda (Kapisch, et al., 2016; Silva, et al., 2017). Além disso, aplicações que envolvem a busca por assinaturas elétricas escondidas nas formas de onda, a fim de se prever possíveis rompimentos de cabos de transmissão, estão sendo desenvolvidas (Xu, Santoso, & Freitas, 2015).

Considerando, portanto, a grande massa de dados provenientes das medições das REIs, e a importância de se preservar os sinais de forma de onda, um estágio de compressão se torna uma tarefa altamente recomendável. Esta etapa promove tanto o monitoramento e armazenamento de eventos de curta duração, quanto o rastreamento de fenômenos de longo período relacionados aos distúrbios de Qualidade de Energia QE (Cormane & Nascimento, 2016).

Além disso, tratando-se do estabelecimento das REIs, é de fundamental importância a forma como esses dados são gerenciados (Sarkar, Kundu, & Sarkar, 2017). Tal gerenciamento pode ser facilitado através

do desenvolvimento de um adequado algoritmo de compressão (Khan J. , Bhuiyan, Murphy, & Arline, 2015; Wen & Li, 2016; Alam, Natarajan, & Pahwa, 2014).

Deste modo, as mais importantes motivações para a compressão dos dados fornecidos pelas medições dos sinais nas REIs são:

- A necessidade de se preservar as formas de onda dos sinais de tensão e de corrente;
- Reduzir o grande volume de dados resultantes das medições (*Big-Data*) (Rehmani, Reisslein, Rachedi, Erol-Kantarci, & Radenkovic, 2018);
- A limitação de largura de banda das conexões dos sistemas de comunicação (Ning, Wang, Gao, & Liu, 2011).

Sendo assim, o presente trabalho apresenta uma proposta para a compressão das formas de onda dos sinais do SEP no contexto das REIs. Utiliza-se como base a variação do conteúdo espectral presente nos sinais. A ferramenta utilizada para a estimação dos componentes espectrais é a Transformada Discreta de Fourier (TDF), a qual é implementada utilizando-se a técnica da Transformada Rápida de Fourier (*Fast Fourier Transform*, ou FFT).

A abordagem apresentada prevê a recuperação das informações de relevância presentes no sinal de tensão ou corrente através da descompressão, pois preserva as características fundamentais das formas de onda, mostrando-se adequada ao novo contexto das REIs, onde novos eventos desconhecidos podem ocorrer (Kapisch, et al., 2016).

O sinal, após descomprimido, pode ser utilizado em análises oscilográficas, aplicação de algoritmos e detecção de problemas de QE. Dessa forma, mantém-se o baixo consumo de memória de armazenamento, permitindo-se maiores períodos de monitoramento, melhor gerenciamento e transporte dos dados. Além disso, é feita uma comparação com um outro método de compressão baseado em transformada Wavelet discreta (TWD).

O artigo é organizado como se segue. Na Seção 3 é mostrada a TDF e a FFT. Na Seção 4 o método de compressão proposto é apresentado. Em seguida, na Seção 5 alguns resultados são exibidos, sendo seguidos da Seção 6, onde algumas conclusões são feitas.

2 Requisitos para compressão de dados em REIS

Alguns requerimentos básicos são exigidos para que um método de compressão de dados seja adequado para o novo contexto das REIs, a saber:

- Alta confiabilidade: Métodos que possuem altas taxas de falha, perda de partes do sinal ou de informação relevante podem prejudicar o desempenho do sistema pelo fato de poderem não revelar possíveis eventos indicadores de problemas presentes na rede.

- Alta fidelidade de reconstrução: o resultado da descompressão deve ser o mais próximo da reconstrução perfeita do sinal original.
- Alta taxa de compressão: quanto maior a taxa de compressão mais fácil será o gerenciamento de dados e mais eficiente a comunicação dos mesmos, pois maior quantidade de informação poderá ser transmitida.

O terceiro requerimento deve estar subordinado aos dois primeiros. Além disso, uma maior a preservação das informações relevantes presentes no sinal e uma maior fidelidade de reconstrução contribuem para uma menor taxa de compressão. Dessa forma, é necessário que se encontre um equilíbrio entre os requerimentos mencionados. Quanto mais eventos existirem nos sinais analisados, maior será o espaço de armazenamento necessário para a manutenção das informações relevantes e, assim, menor será a taxa de compressão.

Diversas técnicas de processamento de sinais têm sido desenvolvidas e aplicadas a fim de se comprimir os sinais do SEP (Tcheou, et al., 2014). Dentre elas comumente encontram-se técnicas baseadas em transformadas tempo-frequência ou tempo-escala, como a Transformada Wavelet (Kapisch, Silva, Martins, Filho, & Duque, 2014; Mehra, Patel, Kazi, Singh, & Wagh, 2013; Bhuiyan, Absar, & Roy, 2017). Outras técnicas baseiam-se na Transformada de Fourier dos sinais examinados (Dapper, Susin, Bampi, & Crovato, 2015). Além destas, existem ainda outras abordagens presentes na literatura, as quais utilizam outras ferramentas de análise (Wang, Chen, Kang, Xia, & Luo, 2017; Unterweger & Engel, 2016; Loia, Tomasiello, & Vaccaro, 2017).

Independente da técnica utilizada, um método de compressão adequado para as aplicações nas REIs deve cumprir com as seguintes premissas:

- Possuir de baixa à média complexidade computacional, de modo a ser possível sua implementação nos medidores inteligentes e operação em tempo real;
- Baixa exigência de memória de massa: alguns algoritmos de compressão baseados em dicionários podem ocupar grande espaço de armazenamento por si próprios.
- Rápida inicialização: considerando eventos interrupções no fornecimento de energia, a técnica utilizada deve atingir o seu funcionamento normal de compressão no menor tempo possível após o restabelecimento da alimentação (Unterweger & Engel, Resumable Load Data Compression in Smart Grids, 2015).

As técnicas de compressão de dados podem ser classificadas com respeito à preservação das informações originalmente presentes nos sinais brutos: compressão sem perdas (*Lossless compression*) e compressão com perdas (*Lossy compression*). Técnicas de compressão sem perdas preservam completamente o sinal original, baseando-se principalmente na reorganização da informação para obter a compres-

são (Sayood, 2017). Técnicas de compressão com perdas não preservam por completo o sinal original, por isso apresentam maiores taxas de compressão quando comparadas as técnicas de compressão sem perdas. Quanto mais informação é perdida, maior será taxa de compressão obtida. Porém, vale ressaltar que o sinal reconstruído deve preservar suas principais características para proporcionar posteriores análises e diagnósticos (Tcheou, et al., 2012). A abordagem apresentada neste artigo se enquadra na categoria de técnicas de compressão com perdas.

3 Transformada Rápida de Fourier (FFT)

Transformada Discreta de Fourier (do inglês, *Discrete Fourier Transform* (DFT)) é uma das mais comuns ferramentas para a representação de sinais no domínio da frequência, que originalmente estão representados no domínio do tempo. A DFT do sinal $x[n]$ é ilustrada pela Equação (1).

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j2\pi k \frac{n}{N}} \quad (1)$$

em que, N é o número de pontos contidos na janela do sinal a ser analisado, k é o índice do componente no espectro de frequências estimado e cada componente da sequência $X[k]$ é considerado um *bin*.

De posse dos coeficientes espectrais $X[k]$, é possível recuperar o sinal $x[n]$, no domínio do tempo, utilizando a Transformada Inversa de Fourier, definida pela seguinte equação:

$$x[n] = \frac{1}{N} \sum_{k=0}^{N-1} X[k] e^{j2\pi k \frac{n}{N}} \quad (2)$$

A complexidade computacional da DFT e de sua inversa é N^2 , pois, como pode ser percebido pela Equação (2), são necessárias N multiplicações complexas para cada um dos N coeficientes espectrais a serem estimados.

Uma maneira mais eficiente de implementar essas transformadas é utilizando o algoritmo computacional conhecido por Transformada Rápida de Fourier (do inglês, *Fast Fourier Transform* (FFT)).

A principal vantagem da FFT em relação a DFT é a sua complexidade computacional, dada por $\theta(N \times \log(N))$, enquanto que a da DFT é $\theta(N^2)$, tal que N corresponde ao comprimento do vetor. Dessa maneira, neste trabalho a FFT será utilizada como ferramenta para o cálculo espectral utilizado na compressão dos sinais, bem como na sua reconstrução.

4 Método de compressão proposto

O método de compressão proposto neste artigo consiste na implementação de um sistema baseado no conteúdo espectral de cada ciclo do sinal de entrada.

Cada *bin* do espectro, obtido utilizando a FFT, de cada ciclo do sinal é comparado sequencialmente com o objetivo de se armazenar apenas informações relevantes e que possibilitem uma boa reconstrução do sinal, e ao mesmo tempo uma redução do tamanho do arquivo.

São armazenados apenas os valores médios de cada *bin* durante um intervalo de tempo que é limitado de acordo com a amplitude da variação do próprio *bin*. O armazenamento de apenas o valor médio reduz a quantidade de informação a ser armazenada, mas também pode afetar a qualidade do sinal reconstruído.

4.1 Compressão

A Figura 1 apresenta um diagrama do funcionamento desse método.




Figura 1. Esquemático do sistema de compressão

O método inicia com o cálculo da FFT de cada ciclo do sinal de entrada, de acordo com a frequência de amostragem utilizada, por exemplo 7680 Hz, em que cada ciclo do sinal contém 128 pontos. A FFT resulta em um vetor complexo de 128 posições, ou um vetor de números reais de 256 posições, sendo 128 delas relativas à parte real de cada *bin* e as outras 128 à parte imaginária dos mesmos.

O sistema inicialmente recebe uma amostra NOVA, que corresponde ao vetor resultante da FFT do primeiro ciclo, para inicializar os vetores MAX,

MIN e SOMA, ambos com tamanho igual ao número de posições do vetor de saída da FFT, que armazenam, respectivamente, o valor máximo, o valor mínimo e o valor acumulado de cada posição ao longo do tempo.

Com esses vetores inicializados o sistema aguarda uma amostra “NOVA”, ou seja, um *bin* da FFT do ciclo posterior do sinal. Os valores contidos nesse vetor são comparados com os valores de MIN e MAX, previamente armazenados e caso o valor de alguma posição seja maior que aquela posição do vetor MAX ou menor que aquela posição do vetor MIN, essa posição em MIN ou MAX é atualizada. Dessa forma, o vetor MIN contém o valor mínimo observado para cada posição da FFT para uma dada janela de processamento e, de forma análoga, o vetor MAX contém o valor máximo.

Com os vetores MIN e MAX atualizados, a comparação do valor absoluto da diferença entre eles com um valor de limiar (ou tolerância) é realizada. Caso essa diferença seja menor que a tolerância, os vetores SOMA e CONT são atualizados. Ao vetor SOMA, é somado o valor da posição do resultado da FFT e o vetor CONT é incrementado de um. Dessa forma, SOMA armazena o valor acumulado para cada posição do vetor de saída da FFT durante uma janela de processamento e o vetor CONT armazena a quantidade de valores contidos na janela. Dessa maneira, é possível calcular o valor médio de cada posição dividindo SOMA por CONT.

Caso a comparação com a tolerância seja verdadeira, ou seja, o valor absoluto da diferença entre MAX e MIN seja maior que a tolerância, o que indica uma grande variação para aquela posição do vetor, é necessário salvar as informações necessárias à reconstrução do sinal, que são elas: a posição do vetor, o valor médio para aquela posição (SOMA/CONT) e o valor de CONT, que indica qual o intervalo de validade daquele valor. Após salvar essas informações, o processo é inicializado para aquela posição do vetor da FFT e o processo é realizado novamente.

Os valores armazenados para a posterior reconstrução são os valores médios de cada posição ou *bin* do espectro do sinal ao longo de um intervalo delimitado pela comparação entre o valor mínimo e máximo desse intervalo. Dessa forma, a tolerância permitida na comparação, está relacionada com a qualidade da reconstrução do sinal. Neste trabalho a mesma foi obtida através de testes buscando a melhor reconstrução do sinal e a maior taxa de compressão. O valor que melhor atendeu as expectativas foi o de 0,03, considerando que os sinais passam pelo processo de normalização na parte inicial do método.

É importante destacar que o valor da tolerância utilizado interfere diretamente na taxa de compressão. Quanto menor for o valor utilizado, melhor será a qualidade da reconstrução do sinal, porém, a taxa de compressão será comprometida. Para um valor de tolerância maior, a taxa de compressão será maior e, consequentemente, a qualidade da reconstrução do sinal será reduzida.

4.2 Reconstrução

A reconstrução do sinal consiste na manipulação dos dados que foram armazenados na parte de compressão, de forma a montar uma matriz, em que cada linha representa o espectro de frequência para cada ciclo do sinal. Para tal, são utilizados os valores de posição do *bin*, valor médio (SOMA/CONT) e o número de vezes que ele aparece (CONT).

A Figura 2 ilustra um exemplo simplificado de uma matriz de reconstrução contendo três componentes de frequência. As colunas C0, C2 e C4 representam respectivamente os valores reais dos três primeiros componentes espectrais. As colunas C1, C3 e C5 são os valores imaginários dos mesmos componentes. As linhas L0, L1, ..., L7 correspondem aos espectros de frequência dos oito primeiros ciclos do exemplo considerado.

	C0	C1	C2	C3	C4	C5
L0			3			5
L1			3			5
L2			3			5
L3			3			5
L4			3			8
L5			3			8
L6			3			8
L7			3			8

Figura 2. Ilustração do início do processo de montagem da matriz de FFTs.

De posse dos valores SOMA e CONT, é possível reconstruir o vetor de saída da FFT para cada ciclo. Isso é feito repetindo-se o valor médio de cada *bin* CONT vezes para aquela determinada posição do vetor. Por exemplo, se para a posição 2 do vetor, o valor médio foi 3 durante 8 ciclos, repete-se então o valor 3 para 8 linhas da coluna C2 da matriz de reconstrução. Se para a coluna C5, o valor médio foi 5 por 4 ciclos e 8 por mais 4 ciclos, a matriz é preenchida sequencialmente e fica como mostrada na Figura 2.

Para o sinal retornar a sua forma original, no domínio do tempo, é necessário fazer a transformada de Fourier inversa de cada linha da matriz e concatenar o resultado para formar o sinal ao longo do tempo.

5 Resultados

Para ilustrar o comportamento do método proposto serão considerados três sinais diferentes. O primeiro é um sinal senoidal com frequência fundamental igual a 60 Hz e frequência de amostragem igual a 7680 Hz. Foram analisados 100 ciclos resultando em 12800 amostras, contendo harmônicos de ordem baixa a partir da metade do sinal. O segundo sinal senoidal possui a mesma frequência fundamental, frequência de amostragem e comprimento analisado do primeiro, porém, sem a presença de harmônicos e contendo um

transitório no decorrer dos ciclos desse sinal. O terceiro é um sinal de tensão sintético, com a mesma frequência de amostragem e fundamental dos sinais anteriores, porém, contendo 47484 ciclos resultando em 6077952 amostras. Esse sinal contém vários distúrbios, dentre eles *sag*, *swell* e variações de amplitudes em rampa crescentes e decrescentes.

Para avaliar a qualidade do sinal reconstruídoas seguintes métricas serão utilizadas: o Erro Quadrático Médio Normalizado (*Normalized Mean Square Error* (NMSE)), definido por (3), a correlação cruzada (*Cross-correlation* (COR)) entre o sinal reconstruído e o original, definido por (4), e a porcentagem de energia retida (*The percentage of retained energy* (RTE (%))), definida por (5).

$$NMSE = \frac{\|x - x'\|^2}{\|x\|^2} \quad (3)$$

$$COR = \frac{x^T \times x'}{x^T \times x} \quad (4)$$

$$RTE(\%) = \frac{\sum_{n=0}^N x[n]^2}{\sum_{n=0}^N x'[n]^2} \quad (5)$$

Note que x é a notação que corresponde ao vetor do sinal original $x[n]$ e x' ao vetor do sinal reconstruído $x'[n]$, tal que N é o comprimento do sinal.

A taxa de compressão (TC) do sinal, é calculada como sendo a razão entre o tamanho do arquivo utilizado para armazenar o sinal sem compressão e o tamanho do arquivo utilizado para armazenar o sinal comprimido. A mesma será expressa como TC:1, o que indica que o sinal comprimido ocupa TC vezes menos espaço em disco quando comparado ao sinal sem compressão.

A. Sinal com harmônico

Para armazenar todo o sinal utilizando uma frequência de amostragem igual a 7680 Hz e resolução de 16 bits, seria necessário 204,8 kbits de memória, com a utilização do método proposto, o espaço utilizado reduziria para 8,768 kbits, proporcionando assim uma taxa de compressão igual a 23:1.

Em relação a qualidade de reconstrução do sinal, temos $NMSE = 0,00018$, $COR = 0,99$ e $RTE = 99,97\%$, o que significa que o sinal reconstruído possui boa qualidade em relação quando comparado com o sinal original.

A Figura 3 apresenta os sinais, o original e o reconstruído, bem como o erro absoluto entre eles. Vale ressaltar que os sinais original e reconstruído contêm 100 ciclos da componente fundamental e que para melhor visualização dos resultados, apenas 6 ciclos do sinal são mostrados na figura.




Figura 3. Representação do sinal (gráfico superior); Erros de reconstrução do sinal com harmônico (gráfico inferior).

Analisando os gráficos mostrados na Figura 3, pode-se perceber que o sinal reconstruído apresenta boa qualidade e que o erro absoluto máximo não ultrapassa 10%, ficando abaixo de 5% para a maior parte das amostras.

B. Sinal com transitório

Para armazenar todo o sinal utilizando a mesma frequência de amostragem e resolução do caso anterior, seria necessário 204,8 kbits de memória disponível, com o uso do método proposto, o espaço utilizado reduziria para 9,728 kbits, configurando assim uma taxa de compressão de 21:1.

As métricas de qualidade para esse sinal foram $NMSE = 0,00009$, $COR = 0,99$ e $RTE = 99,97\%$, mostrando novamente a capacidade do método em preservar a qualidade dos sinais comprimidos.

A Figura 4 apresenta os sinais, original e reconstruído, bem como o erro absoluto entre eles representado pela diferença dos sinais.




Figura 4. Representação do sinal (gráfico superior); Erros de reconstrução do sinal com transitório (gráfico inferior).

Nota-se que para esse sinal, durante o transitório, há um erro perceptível devido a brusca variação provocada pelo transitório. Esse fato se deve à limitação

da FFT em representar sinais de curta duração, dificultando assim a reconstrução do sinal. Porém, no geral, o sinal foi reconstruído de forma satisfatória. Vale a pena ressaltar que para uma melhor reconstrução do pico do transitório, o valor do parâmetro tolerância apresentado no diagrama da Figura 1 deveria ser reduzido de forma a armazenar mais informações do sinal, proporcionando uma melhor reconstrução às custas de reduzir-se a taxa de compressão.

C. Sinal Sintético

O sinal utilizado nesse caso foi gerado sinteticamente e possui os seguintes distúrbios: afundamento, elevação, harmônicos pares, harmônicos ímpares, inter-harmônicos e variação de amplitude em rampa.

A Figura 5 ilustra o sinal sintético, onde é possível perceber diversas variações na amplitude do sinal.




Figura 5. Representação do sinal sintético.

Para armazenar todo o sinal da rede utilizando a mesma frequência de amostragem e resolução do caso anterior, seria necessário 97,247 Mbits de memória disponível, com o uso do método proposto, o espaço utilizado reduziria para 1,561 Mbits, tendo assim uma taxa de compressão igual a 62:1.

Em relação a qualidade da reconstrução, os parâmetros calculados para esse sinal foram NMSE = 0,0003, COR = 0,9996 e RTE = 99,96%, apresentando novamente uma boa qualidade de reconstrução do sinal. Para todos os casos de compressão, nota-se resultados favoráveis, com reduções de espaço consideráveis. A Tabela 1 apresenta o sumário dos resultados alcançados.

Tabela 1. Sumário dos resultados do método de compressão proposto.

	Caso A	Caso B	Caso C
Tamanho original	204,8 Kbits	204,8 Kbits	97,247 Mbits
Tamanho comprimido	8,768 Kbits	9,728 Kbits	1,561 Mbits
Taxa de compressão	23:1	21:1	62:1
NMSE	0,00018	0,00009	0,0003
COR	0,9998	0,9997	0,9996
RTE (%)	99,97	99,97	99,96

5.1 Variação do parâmetro tolerância

A fim de ser realizada uma análise da variação da taxa de compressão e do NMSE com relação à variação do parâmetro tolerância, foi utilizado o sinal $s(t)$ expresso pela Equação (6). Sua representação no tempo pode ser vista através da Figura 6.

$$s(t) = \sin(2\pi f_1 t) \quad \forall t < 0,75 \text{ s}$$

$$s(t) = \sin(2\pi f_1 t) + 0,3\sin(2\pi 3 f_1 t) + 0,2\sin(2\pi 5 f_1 t) + 0,1\sin(2\pi 7 f_1 t) \quad \forall t \geq 0,75 \text{ s} \quad (6)$$



Figura 6. Sinal para teste de variação do parâmetro tolerância.

Os valores para o parâmetro tolerância e os respectivos valores para a taxa de compressão e NMSE estão descritos na Tabela 2.

Tabela 2. Resultados da variação do parâmetro tolerância.

Tolerância	NMSE	Taxa de compressão
0,03	$8,05 \times 10^{-11}$	24:1
0,1	$8,05 \times 10^{-11}$	24:1
0,2	0,0021	25:1
0,3	0,0095	25:1
0,4	0,0229	25:1

Conforme pode ser visto através da Tabela 2, os valores de NMSE crescem com o aumento da tolerância, como também a taxa de compressão. Uma importante observação é que para uma tolerância abaixo de 0,1, tanto o NMSE quanto a taxa de compressão permanecem os mesmos. O aumento dos valores de tolerância acima de 0,1, reflete no aumento do NMSE. Já a taxa de compressão se mantém constante para os mesmos valores.

5.2 Comparação com a compressão utilizando TW

A Transformada Wavelet (TW) é uma ferramenta de processamento consagrada na área de compressão de sinais. Este fato decorre da sua capacidade de representar um sinal qualquer em sub-bandas de frequência, possibilitando, assim, o armazenamento apenas das informações relevantes para a reconstrução do sinal.

Dessa forma, os mesmos sinais que foram comprimidos utilizando o método proposto, foram agora comprimidos utilizando a TW, baseada na wavelet mãe do tipo bi ortogonal utilizando 5 níveis de decomposição, ou seja, o sinal foi dividido em 6 bandas de

frequência, em que, 5 delas são referentes aos coeficientes de detalhe e 1 aos coeficientes de aproximação da TW. Como ilustrado na Figura 7, em que CD_k e CA_k são os coeficientes de detalhe e aproximação do k -ésimo nível, respectivamente, H_d e L_d representam os filtros passa-altas e passa-baixas, respectivamente, e a parte preta simboliza a operação de decimação por um fator 2.




Figura 7. Decomposição Wavelet.

Após a decomposição, um limiar é aplicado aos coeficientes de detalhe, e então somente os que forem superiores ao limiar são mantidos para a reconstrução do sinal. O número total de coeficientes após a decomposição é idêntico ao número de amostras do sinal de entrada, e como apenas os que são superiores ao limiar são mantidos, atinge-se assim a compressão do sinal.

Os mesmos sinais utilizados para o método proposto foram comprimidos utilizando a TW e os resultados de compressão e qualidade de reconstrução podem ser vistos na Tabela 3.

Tabela 3. Sumário dos resultados de compressão do método baseado em Wavelet.

	Caso A	Caso B	Caso C
Taxa de compressão	11:1	11:1	13:1
NMSE	0,0000002	0,0000006	0,0026
COR	0,99	0,99	0,99
RTE (%)	98,79	97,97	99,27

Comparando a taxa de compressão de ambos os métodos, conclui-se que para os três casos o método baseado em FFT se sobressai, destacando a larga vantagem do uso desse método no caso C. A justificativa desse destaque do método proposto está no descarte de informação redundante que ele faz, focando no armazenamento apenas dos componentes de frequência que sejam muito significativos, por exemplo, se houver vários ciclos de senóides idênticas, o sistema armazena a informação de um ciclo somente e quantas vezes ele se repete, descartando o restante.

Em relação a qualidade de reconstrução do sinal, com base nas métricas calculadas, destaca-se que ambos os métodos são eficientes nesse quesito, com erro reduzido, alta correlação cruzada e grandes porcentagens de energia retida.

Uma importante ressalva do método proposto pode ser feita com relação a cenários onde ocorrem variação na frequência fundamental. Caso seja utilizada uma frequência de amostragem fixa, erros ex-

pressivos na reconstrução podem ocorrer. Uma alternativa para contornar essa limitação, seria a utilização da sincronização da taxa de amostragem por meio de um estimador de frequência ou métodos de interpolação (Gurrola-Navarro, 2018; Xiang, Cui, & Shen, 2018), abordagens não realizadas neste trabalho.

Uma outra consideração pode ser feita em relação resolução da FFT utilizada, que se limita a 60 Hz pelo fato de ser usado um comprimento de janela de apenas um ciclo do sinal. Para melhorar a resolução espectral do sistema, pode-se utilizar janelas maiores, porém, isso afetaria diretamente na taxa de compressão final.

6 Conclusão

O presente trabalho apresentou um método de compressão de sinais de formas de onda de sistemas elétricos de potência, baseado na variação do conteúdo espectral dos sinais e que faz uso da Transformada Rápida de Fourier, para a compressão do sinal, e da Transformada Inversa de Fourier para a reconstrução do sinal.

O método proposto foi testado com alguns sinais contendo distúrbios característicos de sistemas de potência e o mesmo apresentou boas taxas de compressão e boa capacidade para reconstruir os sinais com qualidade. Quando comparado a uma técnica de compressão clássica, baseada na Transformada Wavelet, o método proposto se destacou, apresentando maiores taxas de compressão.

Em relação a variação do parâmetro tolerância, pode-se concluir que tanto a taxa de compressão como o NMSE são diretamente dependentes desse parâmetro. Além disso, a taxa de compressão é também influenciada pelo número de ocorrências de distúrbios presentes no sinal.

Por fim, pode-se concluir que o método apresentou resultados promissores de compressão, mostrando assim sua capacidade de ser empregado em sistemas para armazenamento de sinais de forma de onda de sistemas de potência durante longos períodos de tempo.

Agradecimentos

Os autores deste trabalho agradecem à Universidade Federal de Juiz de Fora, à CAPES, ao CNPQ e à FAPEMIG pelo suporte a essa pesquisa.

Referências Bibliográficas

- Alam, S. M., Natarajan, B., & Pahwa, A. (2014). Distribution Grid State Estimation from Compressed Measurements. *IEEE Transactions on Smart Grid*.
- Arritt, R. F., & Dugan, R. C. (2011). Distribution System Analysis and the Future Smart Grid.

- IEEE Transactions on Industry Applications*, pp. 2343 - 2350.
- Bhuiyan, B. A., Absar, M. W., & Roy, A. (2017). Performance comparison of various wavelets in compression of PMU generated data in smart grid. *3rd International Conference on Electrical Information and Communication Technology (EICT)*, pp. 1 - 6.
- Cormane, J., & Nascimento, F. A. (2016). Spectral Shape Estimation in Data Compression for Smart Grid Monitoring. *IEEE Transactions on Smart Grid*, pp. 1214 - 1221.
- Dapper, R. E., Susin, A. A., Bampi, S., & Crovato, C. D. (2015). High compression ratio algorithm for power quality signals. *IEEE 24th International Symposium on Industrial Electronics (ISIE)*, pp. 1322 - 1326.
- Gurrola-Navarro, M. A. (25-28 de Fev. de 2018). Frequency-domain interpolation for simultaneous periodic nonuniform samples. *2018 IEEE 9th Latin American Symposium on Circuits & Systems (LASCAS)*.
- Kapisch, E. B., Silva, L. R., Cerqueira, A. S., Filho, L. M., Duque, C. A., & Ribeiro, P. F. (2016). A Gapless Waveform Recorder for Monitoring Smart Grids. *2016 17th International Conference on Harmonics and Quality of Power (ICHQP)*, pp. 130 - 136.
- Kapisch, E. B., Silva, L. R., Martins, C. H., Filho, L. M., & Duque, C. A. (2014). Implementação em FPGA de Transformada Wavelet para compactação de sinais elétricos de sistemas de potência utilizando processador embarcado. *Congresso Brasileiro de Automática*, pp. 195 - 202.
- Khan, J., Bhuiyan, S. M., Murphy, G., & Arline, M. (2015). Embedded-Zerotree-Wavelet-Based Data Denoising and Compression for Smart Grid. *IEEE Transactions on Industry Applications*, pp. 4190 - 4200.
- Khan, J., Bhuiyan, S., Murphy, G., & Williams, J. (2016). Data Denoising and Compression for Smart Grid Communication. *IEEE Transactions on Signal and Information Processing over Networks*, pp. 200 - 214.
- Loia, V., Tomasiello, S., & Vaccaro, A. (2017). Fuzzy Transform Based Compression of Electric Signal Waveforms for Smart Grids. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, pp. 121 - 132.
- Mehra, R., Patel, V., Kazi, F., Singh, N. M., & Wagh, S. R. (2013). Modes preserving wavelet based multi-scale PCA algorithm for compression of smart grid data. *International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pp. 817 - 821.
- Ning, J., Wang, J., Gao, W., & Liu, C. (2011). A Wavelet-Based Data Compression Technique for Smart Grid. pp. 212 - 218.
- Rehmani, M. H., Reisslein, M. G., Rachedi, A., Erol-Kantarci, M. G., & Radenkovic, M. G. (2018). Integrating Renewable Energy Resources into the Smart Grid: Recent Developments in Information and Communication Technologies. *IEEE Transactions on Industrial Informatics*.
- Sarkar, S. J., Kundu, P. K., & Sarkar, G. (2017). DBEA: A novel approach of repetitive data array compression for power system application. *2017 2nd International Conference for Convergence in Technology (I2CT)*, pp. 824 - 827.
- Sayood, K. (2017). *Introduction to data compression*. Morgan Kaufmann.
- Silva, L. R., Kapisch, E. B., Martins, C. H., Filho, L. M., Cerqueira, A. S., Duque, C. A., & Ribeiro, P. F. (2017). Gapless Power-Quality Disturbance Recorder. *IEEE Transactions on Power Delivery*, pp. 862 - 871.
- Tcheou, M. P., Lovisolo, L., Ribeiro, M. V., da Silva, E. A., Rodrigues, M. A., Romano, J. M., & Diniz, P. S. (2014). The Compression of Electric Signal Waveforms for Smart Grids: State of the Art and Future Trends. *IEEE Transactions on Smart Grid*, pp. 291 - 302.
- Tcheou, M. P., Miranda, A. L., Lovisolo, L., da Silva, E. A., Rodrigues, M. A., & Diniz, P. S. (2012). How far can one compress digital fault records? Analysis of a matching pursuit-based algorithm. *Digital Signal Processing*, 22, pp. 288-297.
- Unterweger, A., & Engel, D. (2015). Resumable Load Data Compression in Smart Grids. *IEEE Transactions on Smart Grid*, pp. 919 - 929.
- Unterweger, A., & Engel, D. (2016). Lossless compression of high-frequency voltage and current data in smart grids. *IEEE International Conference on Big Data (Big Data)*, pp. 3131 - 3139.
- Wang, Y., Chen, Q., Kang, C., Xia, Q., & Luo, M. (2017). Sparse and Redundant Representation-Based Smart Meter Data Compression and Pattern Extraction. *IEEE Transactions on Power Systems*, pp. 2142 - 2151.
- Wen, M. H., & Li, V. O. (2016). Optimal Phasor Data Compression Unit Installation for Wide-Area Measurement Systems—An Integer Linear Programming Approach. *IEEE Transactions on Smart Grid*, pp. 2644 - 2653.
- Xiang, J., Cui, W., & Shen, Q. (2018). Flexible and Accurate Frequency Estimation for Complex Sinusoid Signal by Interpolation Using DFT Samples. *Chinese Journal of Electronics*, 109 - 114.
- Xu, W., Santoso, S., & Freitas, W. (2015). *Electric signatures of power equipment*. Technical Report.
- Yu, X., Cecati, C., Dillon, T., & Simões, M. G. (2011). The New Frontier of Smart Grids. *IEEE Industrial Electronics Magazine*, pp. 49 - 63.