

Algoritmo para a compressão de sinais da rede elétrica baseado na combinação da técnica *Compressive Sensing* com uma abordagem dissociativa ^{*}

Camila Franco de Sousa ^{*} Jorge Cormane ^{**}

^{*} *Engenharia Eletrônica, Faculdade UnB Gama, Universidade de Brasília, DF, (e-mail: imcamilafranco@gmail.com).*

^{**} *Engenharia de Energia, Faculdade UnB Gama, Universidade de Brasília, DF, (e-mail: jcormane@unb.br)*

Abstract: This work presents a method for compressing power grid signals based on the Compressive Sensing technique combined with a dissociative approach. From this, Iteratively Reweighted Least-Squares and Conjugate Gradient are used. The first is suitable for the reconstruction of one-dimensional signals, while the second is suitable for the reconstruction of the signal in a two-dimensional format. The results demonstrate the preservation of the signal after reconstruction (SNR > 40 dB), in addition to the reduction of computational complexity, from the dissociation of the signal according to its behavior: permanent regime or disturbance.

Resumo: Este trabalho apresenta um método de compressão de sinais da rede elétrica baseado na técnica de *Compressive Sensing* combinada com uma abordagem dissociativa. Para isso, utilizam-se os algoritmos *Iteratively Reweighted Least-Squares* e o *Conjugate Gradient*. O primeiro adequado para a reconstrução de sinais unidimensionais, enquanto que o segundo é adequado para a reconstrução do sinal em um formato bidimensional. Os resultados demonstram a preservação do sinal após a reconstrução (SNR > 40 dB), além da redução da complexidade computacional, a partir da dissociação do sinal segundo seu comportamento: regime permanente ou distúrbio.

Keywords: Compressive Sensing, IRLS, Smart Grid, Data Compression.

Palavras-chaves: *Compressive Sensing*, IRLS, *Smart Grid*, Compressão de Dados.

1. INTRODUÇÃO

As tecnologias *Smart Grids* requerem uma comunicação rápida e eficiente entre todos os componentes da rede elétrica. Para isso, tecnologias da informação e comunicação, além de sistemas de supervisão e controle de maior cobertura tem sido incorporados cada vez mais às redes elétricas convencionais, para fazer delas umas redes elétricas mais modernas e preparadas para responder aos desafios do setor no futuro (Fan et al., 2013).

No contexto tecnológico atual, observa-se que as redes elétricas permitem o fluxo de dados além do fluxo de energia. Este fato traz a possibilidade da transformação da rede elétrica convencional em uma rede elétrica "inteligente", que possibilite extrair características e informações durante a operação. Neste sentido, utilizando-se um sistema de comunicação, os dados são processados, transmitidos e armazenados para estudos futuros. Para isso, a economia de espaço, tamanho de banda e tempo é necessária (Tcheou et al., 2014).

É neste contexto, que as pesquisas e desenvolvimento de técnicas na área de compressão de sinais crescem, voltadas

para essa aplicação específica. Dentre essas contribuições, pode-se ressaltar o uso de transformadas ortogonais para codificação. Em (Ning et al., 2011), aborda-se esse tema e *denoising* usando-se a transformada de *Wavelet Daubechies 2* para sinais de perturbação em sinais de potência em *Smart Grids*. Em (Shyh-Jier Huang and Ming-Jong Jou, 2004), utiliza-se *Wavelet Packet* com pré-processamento de sinais originados de distúrbios na rede elétrica. Já em (Li et al., 2018), obteve-se um baixo erro de reconstrução e alta taxa de compressão, com a decomposição de valores singulares no domínio discreto de *Wavelet*, em 2D. A técnica de decomposição de valores singulares aplicada em *Smart Grids* também é estudada em (de Souza et al., 2017). Além dessas abordagens, encontram-se na literatura: (Loia et al., 2017), que usa a transformada *Fuzzy* do sinal no domínio retangular para sua compressão e reconstrução. Em (Abuadba et al., 2018), aplicam-se a transformada *Burrow - Wheeler* (BWT) e a aproximação *gaussiana* para essa finalidade. Em (Zhang et al., 2017), emprega-se um algoritmo iterativo baseado na análise de componentes principais (PCA), como um método de compressão de dados de multicanais de qualidade de potência. Os métodos anteriormente propostos tratam o sinal após sua aquisição. Então, um grande espaço amostral contendo

^{*} Este trabalho foi realizado no âmbito do Edital FAPDF 04/2017. TOA 1373/2017 e Processo: 193.001.474/2017.

métodos que propõem aumento da eficiência durante a aquisição dos sinais não foram encontrados na literatura.

Aplica-se um algoritmo de compressão em (Cormane and de O. Nascimento, 2016), levando-se em conta o transiente e o estado estacionário do sinal de potência. O estudo apresenta uma modelagem de perfil espectral do sinal no domínio da transformada Wavelet, utilizando uma rede neural. O resultado obtido em termos de *Compression Ratio* (CR) e *Signal to Noise Ratio* (SNR) foi de valores acima 16:1 e de 42 dB, respectivamente.

Verifica-se que na grande maioria dos trabalhos se utiliza uma abordagem unidimensional do problema onde é explorada a correlação temporal do dada as características dos sinais tratados. Porém é possível construir uma representação em 2D destes mesmos sinais de forma a explorar as características espaciais desta representação. Neste trabalho pretende-se explorar o potencial que possui a técnica de Compressive Sensing na compressão de imagens, para fazer compressão de uma representação 2D de sinais de distúrbios.

Com isso, pode-se utilizar *Compressive Sensing*, que se trata de um método de compressão de medidas durante o processo de aquisição de sinais. Essa técnica permite que a taxa de amostragem do sinal possa ser menor que a taxa determinada pela teoria de Shannon, com o pressuposto de que algumas características específicas sejam contempladas: o sinal assume uma representação esparsa em um domínio transformado e as medidas adquiridas são lineares. Como consequência, a qualidade da informação reconstruída é preservada. O uso dessa técnica culmina na redução do número de medidas suficientes para a composição do sinal Hui Tang et al. (2016).

A transmissão de dados pode ser efetiva, explorando-se as correlações espaciais e temporais do sinal, utilizando-se *Compressive Sensing*, quando comparada com o método tradicional de aquisição de informações. Isso acontece porque a aplicação de *Compressive Sensing* culmina em uma diminuição do custo matemático e o tempo de processamento do sinal. O uso dessa técnica é disseminado em diversas áreas, sobretudo em processamento de imagem (Wang et al., 2018) e processamento de imagens biomédicas (Miosso et al., 2009). A aplicação em sinais derivados do monitoramento de uma *Smart Grid* é encontrado em (Hui Tang et al., 2016), onde a técnica de *Compressive Sensing* é aplicada em um modelo de janela dissociativa em *Wireless Sensor Networks* (WSNs), obtendo-se resultados sólidos.

2. METODOLOGIA

2.1 Compressive Sensing

Dado um sinal N -dimensional x , que assume uma transformada esparsa \hat{x} , com n coeficientes de \hat{x} não nulos e T a matriz de transformação:

$$\hat{x} = Tx \quad (1)$$

Ademais, considerando-se que b é a matriz de medidas lineares e $M_{m \times N}$ é uma matriz aleatória Gaussiana, tem-se que:

$$b = Mx \quad (2)$$

O sistema permite a determinação dos N componentes de x , através das m medidas disponíveis. Sua solução consiste em um problema de otimização, a qual é aproximada pelo vetor \hat{x} mais esparsa encontrado. Então, utiliza-se uma aproximação definida pela minimização da L_p do \hat{x} , onde $0 < p < 1$:

$$\min_{\hat{x}} \frac{1}{2} \|\hat{x}\|_p^p, \quad \text{s.t } A\hat{x} = b \quad (3)$$

Onde, $A = MT^{-1}$ (Miosso et al., 2009). O algoritmo utilizado no presente trabalho utiliza $L = 1$. Esse problema de otimização convexa permite a reconstrução do sinal compressível ou esparsa com uma alta probabilidade. (Hui Tang et al., 2016)

2.2 Método direto (IRLS)

O IRLS é um método de solução iterativa, utilizado para a reconstrução de sinais esparsos, a partir de medidas lineares. Tem-se que:

$$\min_{\hat{x}} \frac{1}{2} \sum_{k=1}^N w_k^{p-2} \hat{x}_k^2, \quad \text{s.t } A\hat{x} = b \quad (4)$$

onde w_k é o parâmetro de peso, modificado a cada iteração, até aproximar-se de \hat{x}_k , de forma que a função aproxima:

$$\sum_{k=1}^N |\hat{x}_k|^p \quad (5)$$

A modificação é tal que:

$$w^{(m)} = |\hat{x}^{(m-1)}| \quad (6)$$

onde $w^{(m)}$ é o valor do vetor de pesos a serem usados na m -ésima iteração e $\hat{x}^{(m-1)}$ é a $(m-1)$ -ésima iteração. Assim, $\hat{x}^{(m-1)}$ será próximo de $\hat{x}^{(m)}$, a partir de uma tolerância igual a 10^{-8} e, dessa forma, compatível com a função original. (Miosso et al., 2009) O sinal pode ser reconstruído a partir de um vetor b de medidas lineares suficientes, incrementando-se o m até a convergência:

$$\min_{\hat{x}} \frac{1}{2} \sum_{k=1}^N |w_k^{(m)}|^{p-2} \hat{x}_k^2, \quad \text{s.t } A\hat{x} = b \quad (7)$$

onde, (7) corresponde à minimização da l_2 :

$$\hat{x}^{(m)} = Q^{(m)} A^H (A Q^{(m)} A^H)^{-1} b \quad (8)$$

onde

$$Q = \text{diag}(q_1, q_2, q_3, \dots, q_N) \quad (9)$$

As iterações usadas para a reconstrução do sinal esparsa requer uma regularização durante a definição de $Q^{(m)}$, consequente da inversão de matriz. Então, uma constante μ é adicionada em q_k . Então, \hat{x} é iniciado e atualizado em cada iteração. Atualiza-se também o μ , reduzido por um fator de 10, até que ele alcance um valor específico, que foi testado durante as simulações: $\mu \leq 10^{-8}$. O Algoritmo 1 demonstra as instruções da reconstrução do sinal em um

Algoritmo 1 Método IRLS utilizando *Compressive Sensing*

Requer: $p > 0$, A , Ah , N , b , μ_0

1 Inicialize $\hat{x}^{(0)}$ e $Q^{(0)}$

2 Loop:

2.1 Inicialize $m = 1$

2.2 Atualize $Q^{(m)}$

2.3 Calcule $\hat{x}^{(m)}$

2.4 Se houver convergência, vá para 3 senão, $m = m+1$

e vá para 2.2

3 Atualize μ ;

4 Se $\mu < 10^{-8}$, termine. Se não, vá para 2

domínio esparsa, a partir de um vetor b de medidas lineares (Miosso et al., 2009).

Utilizou-se esse algoritmo para o caso unidimensional dos sinais de potência. Nesse contexto, foram testadas diferentes transformadas esparsificantes, a seguir: transformada discreta de Fourier (do inglês, Discrete Fourier Transform - DFT), transformada discreta de Cosseno (do inglês, Discrete Cosine Transform - DCT) e transformada discreta de Wavelet (do inglês, Discrete Wavelet Transform - DWT) com filtro *Daubechies 4*. Primeiro, as transformadas DFT e DCT foram utilizadas em todo o sinal, por seu comportamento estacionário ser predominante. Então, dissociou-se o sinal em regime permanente e transiente, onde uma diferente transformada foi empregada para cada caso. Segmentou-se então o sinal para o tamanho específico do fenômeno.

2.3 Método Indireto

O segundo método proposto de reconstrução dos sinais se deu pela dissociação do sinal em janelas de tamanho $N = 256$. Os sinais foram passados para o domínio retangular 256×60 . Por isso, adicionou-se o algoritmo *Conjugate Gradient* ao processo anterior, uma técnica iterativa de resolução de sistemas esparsos de equações lineares (Shewchuk, 1994). Como a matriz A possui dimensão elevada, o algoritmo é adicionado para reduzir a complexidade computacional, resolvendo-se assim o sistema $Ax = b$ sem a utilização da matriz A . A transformada esparsificante foi a DFT de duas dimensões, por apresentar maior esparsidade para o caso unidimensional.

3. RESULTADOS E DISCUSSÕES

Os algoritmos foram implementados com o auxílio do software *Matlab*. Um banco de dados, no qual extraiu-se dois sinais reais contendo um distúrbio do sistema de potência foi utilizado para a testar o algoritmo (EPRI, 2011). Na Figura 1 e Figura 2), são apresentadas as formas de onda dos sinais de tensão (Evento 1) e de corrente (Evento 2), respectivamente.

Para o caso do método direto (IRLS), além da aplicação da DCT e da DFT no sinal inteiro, também simulou-se para o uso de duas transformadas distintas em trechos específicos dos sinais. Então, uma transformada foi utilizada para o trecho correspondente ao comportamento do sinal antes e depois da perturbação e uma segunda transformada foi utilizada para o trecho durante a perturbação. A Tabela 1 apresenta os resultados das simulações executadas para valores de CR de 30%, 50% e 60%.

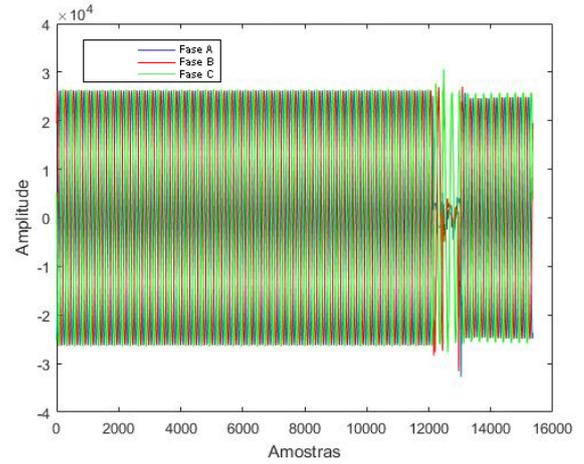


Figura 1. Forma de onda original do sinal de tensão.

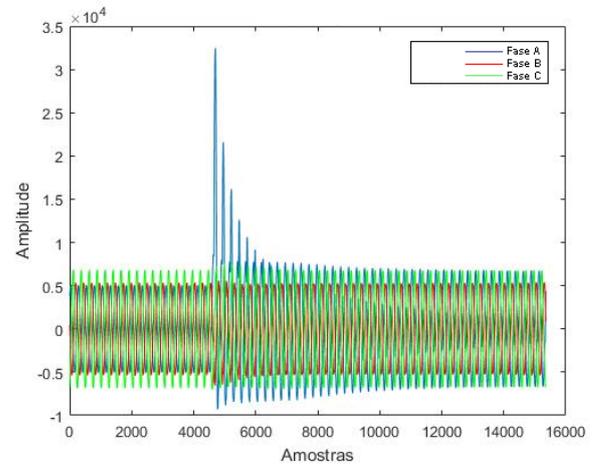


Figura 2. Forma de onda original do sinal de corrente.

Para o caso do CR = 60%, simulações utilizando o método indireto, com o sinal no domínio bidimensional foram realizadas. Obteve-se, dessa forma, a melhor qualidade de reconstrução em ambos os eventos. O motivo pelo qual o método não foi aplicado para as duas taxas de compressão menores, foi a falta de convergência do algoritmo em um curto espaço de tempo, o que não cumpre a finalidade do estudo. Isso acontece pois durante a resolução do sistema pelo algoritmo *Conjugate Gradient* precisa convergir para a resolução do sistema.

As versões após o uso da técnica *Compressive Sensing*, no domínio bidimensional são apresentadas na Figura 3 e Figura 4, respectivamente. Os sinais de erro calculado entre os sinais originais e os sinais reconstruídos são apresentados na Figura 5 e Figura 6.

Tratando-se do caso em que o CR é de 30%, o melhor desempenho se deu a partir da utilização da DCT para o domínio esparsa. Isso mostra que a utilização de diferentes transformadas esparsificantes nos trechos de sinal antes, durante e depois do distúrbio, não contribuiu para um melhor valor de SNR com o uso do método. O mesmo ocorreu para o caso de 50% e 60%, nos quais usou-se a mesma transformada esparsificante (DFT), culminando na obtenção de uma melhor qualidade da reconstrução do

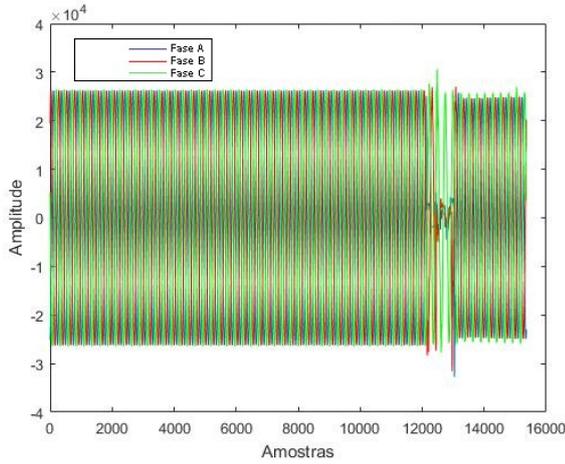


Figura 3. Forma de onda reconstruída do sinal de tensão para CR = 60%.

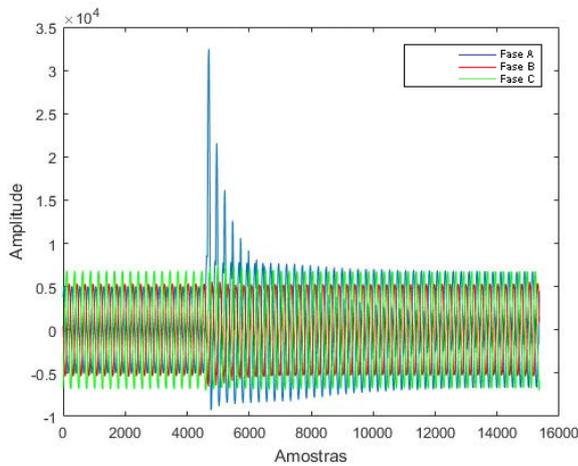


Figura 4. Forma de onda reconstruída do sinal de corrente para CR = 60%.

Tabela 1. Valores de SNR (dB)

Transformada	Evento 1			Evento 2		
	Fase A	Fase B	Fase C	Fase A	Fase B	Fase C
CR=30%						
DCT	22,7	20,37	22,85	14,90	20,14	24,16
DFT	21,41	20,87	21,17	19,37	20,65	20,80
DCT/DWT/DCT	20,65	17,46	14,02	11,89	12,01	13,10
DFT/DWT/DFT	20,52	17,31	18,17	14,29	13,26	14,06
DCT/DFT/DCT	14,22	12,51	12,37	10,61	10,16	10,02
DFT/DCT/DFT	14,85	12,41	12,47	9,94	9,94	10,11
CR=50%						
DCT	22,45	22,57	26,11	21,38	22,54	21,70
DFT	26,10	25,87	25,02	28,16	25,92	26,22
DCT - DWT - DCT	22,73	23,47	24,96	19,09	16,72	18,94
DFT - DWT - DFT	25,11	24,32	24,66	21,20	22,63	23,32
DCT - DFT - DCT	18,65	14,22	14,59	12,29	11,70	11,69
DFT - DCT - DFT	24,41	23,60	24,09	25,90	26,62	25,38
CR=60%						
DCT	25,90	25,69	26,51	23,43	25,40	25,98
DFT	28,13	27,75	27,76	29,61	28,80	28,75
DCT - DWT - DCT	25,69	26,63	29,32	26,36	25,62	21,79
DFT - DWT - DFT	26,44	27,84	26,25	31,02	25,20	26,02
DCT - DFT - DCT	24,44	29,95	30,16	24,42	26,31	24,54
DFT - DCT - DFT	26,65	25,98	25,88	31,26	26,31	28,22
2D-DFT	52,09	47,45	48,86	48,79	49,73	49,21

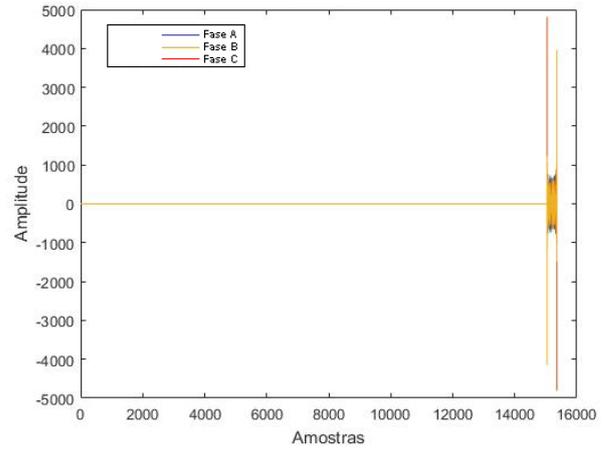


Figura 5. Sinal de erro de tensão para CR = 60%.

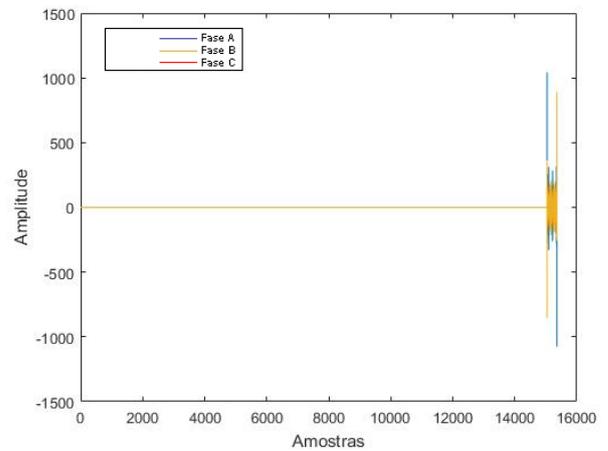


Figura 6. Sinal de erro de corrente para CR = 60%.

sinal. Os resultados apresentados demonstram que no caso da reconstrução dos sinais de potência, a abordagem da reconstrução em 2D, com CR = 60%, utilizando *Compressive Sensing* e método indireto, cumpriu um melhor critério de preservação da fidelidade do sinal, mesmo com os efeitos de distorção devido às bordas da imagem, observados nos erros de reconstrução do sinal. A partir das figuras 5 e 6, onde o erro é próximo de zero até uma pequena parcela cercana ao final do janelamento.

4. CONCLUSÃO

Dado o exposto, nesse trabalho, foi apresentado um método de compressão de sinais baseado na técnica de *Compressive Sensing* com uma abordagem dissociativa. Utilizou-se o método direto para o caso unidimensional e o método indireto para o caso bidimensional, comparando-se os resultados das simulações. Além disso, os casos foram estudados para diferentes taxas de compressão, utilizando-se, também, três tipos de transformadas esparsificantes. A abordagem para o caso bidimensional, com CR = 60%, obteve melhor desempenho, de forma que há uma melhor preservação da informação do sinal original. Os resultados dos testes mostram que o método proposto é uma alternativa para a aplicação da compressão de dados em ambientes *Smart Grid*.

REFERÊNCIAS

- Abuadba, A., Khalil, I., and Yu, X. (2018). Gaussian approximation-based lossless compression of smart meter readings. *IEEE Transactions on Smart Grid*, 9(5), 5047–5056. doi:10.1109/TSG.2017.2679111.
- Cormane, J. and de O. Nascimento, F.A. (2016). Spectral shape estimation in data compression for smart grid monitoring. *IEEE Transactions on Smart Grid*, 7(3), 1214–1221. doi:10.1109/TSG.2015.2500359.
- de Souza, J.C.S., Assis, T.M.L., and Pal, B.C. (2017). Data compression in smart distribution systems via singular value decomposition. *IEEE Transactions on Smart Grid*, 8(1), 275–284. doi:10.1109/TSG.2015.2456979.
- EPRI (2011). *National Database Repository of Power System Events*. [Online]. Available: <http://expertmonitoring.com/doelibrary/default.asp>.
- Fan, Z., Kulkarni, P., Gormus, S., Efthymiou, C., Kalogridis, G., Sooriyabandara, M., Zhu, Z., Lambbotharan, S., and Chin, W.H. (2013). Smart grid communications: Overview of research challenges, solutions, and standardization activities. *IEEE Communications Surveys Tutorials*, 15(1), 21–38. doi:10.1109/SURV.2011.122211.00021.
- Hui Tang, Yinliang Xu, and Zhicheng Li (2016). Compressed sensing based real-time control in a smart grid. In *2016 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, 1782–1786. doi:10.1109/APPEEC.2016.7779795.
- Li, Q., Zhang, M., He, S., and Li, S. (2018). Instructions data compression for smart grid monitoring using wavelet domain singular value decomposition. In *2018 Chinese Control And Decision Conference (CCDC)*, 5171–5175. doi:10.1109/CCDC.2018.8408029.
- Loia, V., Tomasiello, S., and Vaccaro, A. (2017). Fuzzy transform based compression of electric signal waveforms for smart grids. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 47(1), 121–132. doi:10.1109/TSMC.2016.2578641.
- Miosso, C.J., von Borries, R., Arguez, M., Velazquez, L., Quintero, C., and Potes, C.M. (2009). Compressive sensing reconstruction with prior information by iteratively reweighted least-squares. *IEEE Transactions on Signal Processing*, 57(6), 2424–2431. doi:10.1109/TSP.2009.2016889.
- Ning, J., Wang, J., Gao, W., and Liu, C. (2011). A wavelet-based data compression technique for smart grid. *IEEE Transactions on Smart Grid*, 2(1), 212–218. doi:10.1109/TSG.2010.2091291.
- Shewchuk, J.R. (1994). An introduction to the conjugate gradient method without the agonizing pain. Technical report, Pittsburgh, PA, USA.
- Shyh-Jier Huang and Ming-Jong Jou (2004). Application of arithmetic coding for electric power disturbance data compression with wavelet packet enhancement. *IEEE Transactions on Power Systems*, 19(3), 1334–1341. doi:10.1109/TPWRS.2004.825899.
- Tcheou, M.P., Lovisolio, L., Ribeiro, M.V., da Silva, E.A.B., Rodrigues, M.A.M., Romano, J.M.T., and Diniz, P.S.R. (2014). The compression of electric signal waveforms for smart grids: State of the art and future trends. *IEEE Transactions on Smart Grid*, 5(1), 291–302. doi:10.1109/TSG.2013.2293957.
- Wang, Y., Bai, H., and Zhao, Y. (2018). Image reconstruction from patch compressive sensing measurements. In *2018 IEEE Fourth International Conference on Multimedia Big Data (BigMM)*, 1–4. doi:10.1109/BigMM.2018.8499088.
- Zhang, M., Zhan, Y., and He, S. (2017). Power quality data compression based on iterative pca algorithm in smart distribution systems. *Smart Grid and Renewable Energy*, 08, 366–378. doi:10.4236/sgre.2017.812024.