

## Estimador Seletivo de Componentes Harmônicos de Corrente Baseado em Rede Neural Profunda

Luiz G. R. Bernardino\* Claudionor F. Nascimento\*\*  
Wesley A. Souza\*\*\* Augusto M. S. Alonso\*\*\*\* Fernando P. Marafão\*  
Edson H. Watanabe†

\* *ICTS, Universidade Estadual Paulista, SP, Brasil*  
(e-mail: lgr.bernardino@unesp.br, fernando.marafao@unesp.br)

\*\* *DEE, Universidade Federal de São Carlos, SP, Brasil*  
(e-mail: claudionor@ufscar.br)

\*\*\* *DAELE, Universidade Tecnológica Federal do Paraná, PR, Brasil*  
(e-mail: wesleyangelino@utfpr.edu.br)

\*\*\*\* *EESC, Universidade de São Paulo, SP, Brasil*  
(e-mail: augusto.alonso@usp.br)

† *COPPE, Universidade Federal do Rio de Janeiro, RJ, Brasil*  
(e-mail: watanabe@coe.ufrj.br)

---

**Abstract:** This work proposes a selective estimator of harmonic current components based on a deep neural network (DNN), which is able to provide the amplitudes and phase shifts of these components through a quarter cycle of the current fundamental waveform. A sufficiently optimal configuration was reached for application in the harmonic estimation proposal from an exhaustive search for DNN parameters. The DNN training was performed from a set of current samples in the time domain. The evaluation test indicated that the DNN presents an average of approx. 99% of amplitude errors smaller than 0.0036 pu and, in relation to the phase shifts, the average errors are smaller than 0.0041 rad. Furthermore, a case study targeting selective harmonic compensation by means of an active power filter is presented considering reference currents generated from the DNN estimations. The results show that there was a 59.3% reduction in total harmonic distortion (THD) by using the proposed strategy, reducing from 29.88% to 12.16% which is still a high value, while individual (selected) harmonic components were attenuated into values between 80 and 94%, indicating the viability of DNN in this type of application.

**Resumo:** Este trabalho propõe um estimador seletivo do conteúdo harmônico de corrente por meio de uma rede neural profunda (DNN), que é capaz de fornecer as amplitudes e ângulos de fase desses componentes usando um quarto de ciclo da forma de onda do componente fundamental. A arquitetura da DNN suficientemente ótima para aplicação na estimativa harmônica proposta foi obtida por meio da busca exaustiva por parâmetros da DNN. O treinamento do modelo neural foi realizado a partir de um conjunto de dados de formas de onda de correntes, no domínio do tempo. A avaliação a partir das amostras de teste indicou que a DNN apresenta média de 99% dos erros de estimativa de amplitudes menores que 0,0036 pu e, em relação aos ângulos de fase, os erros médios são menores que 0,0041 rad. No estudo de caso para compensação harmônica individual por meio de um filtro ativo de potência, com corrente de referência gerada a partir das estimativas da DNN, houve uma redução de 59,3% da distorção harmônica total, que evoluiu de 29,88% para 12,16%, enquanto componentes harmônicos individuais (selecionados) foram atenuados para valores entre 80 e 94%, indicando a viabilidade da DNN nesse tipo de aplicação.

**Keywords:** Deep neural networks; Exhaustive search; Harmonics; Harmonic content estimation; Harmonic mitigation.

**Palavras-chaves:** Redes neurais profundas; Busca exaustiva; Harmônicos; Estimativa do conteúdo harmônico; Atenuação harmônica.

---

## 1. INTRODUÇÃO

A aplicação de rede neural profunda (DNN) em sistemas de controle de inversores (baseados em eletrônica de potência) tem sido amplamente pesquisada pela comunidade científica, principalmente com o objetivo de resolver limitações das técnicas convencionais empregadas em problemas de qualidade da energia elétrica (QEE) (Chawda et al., 2020) no contexto das microrredes inteligentes (*smart micro-grids*) (Xiao e Li, 2021). Destaca-se ainda que a distorção harmônica é um dos principais problemas de QEE que afetam a operação regular das microrredes (Wang et al., 2020).

Nesse contexto, a distorção harmônica pode ocorrer principalmente em razão da presença de cargas não-lineares e do uso de conversores eletrônicos como dispositivos de interface de conversão de energia (Arrillaga e Watson, 2004). Tais equipamentos são responsáveis por conectar fontes renováveis distribuídas de energia à microrrede (Gong e Ruan, 2020). Portanto, a manutenção de indicadores de QEE dentro dos padrões estabelecidos é uma tarefa crítica, especialmente quando se trata de perdas provocadas por componentes harmônicos (Nascimento et al., 2017). Existem diversos efeitos prejudiciais causados pela distorção harmônica, tais como o mal funcionamento de dispositivos de controle, a redução da vida útil de equipamentos e o aumento das perdas elétricas (Ray et al., 2022).

Algumas das formas de compensação dos componentes harmônicos em sistemas de potência utilizam filtros passivos (Baitha e Gupta, 2015), filtros passivos amortecidos (Dovgun et al., 2020) ou um filtro ativo de potência (FAP) (Singh et al., 1999). Em geral, FAPs são projetados para atenuar componentes harmônicas específicas (Akagi et al., 1984; Mattavelli e Marafão, 2004) ou dentro de uma faixa limitada de frequência de operação.

Assim, o sistema de controle de um FAP requer uma corrente de referência, valendo-se da corrente da carga não-linear conectada ao ponto de conexão comum (PCC) do circuito. Akagi (2005), por exemplo, aplica um FAP em paralelo com a carga não-linear usando uma estratégia de determinação do conteúdo harmônico da corrente baseada na transformada discreta de Fourier (DFT).

As estratégias baseadas em inteligência artificial (IA) podem ser usadas para identificação do conteúdo harmônico em microrredes (Kumar e Bansal, 2019; Kumar et al., 2019; Faria et al., 2019; Gong e Ruan, 2020; Flores-Garrido et al., 2021; Alsaidan et al., 2021). Essa estratégia apresenta algumas vantagens, principalmente reduzindo o esforço computacional no estágio de operação e possibilitando a integração de diferentes ferramentas baseadas em sistemas inteligentes. Ucar et al. (2019) aplicam técnicas de aprendizado de máquina para aumentar a velocidade de detecção de eventos como afundamentos e surtos de tensão, interrupções e harmônicos. Žnidarec et al. (2019) emprega uma rede neural artificial (RNA) na identificação de amplitudes e fases de sinais elétricos distorcidos. Uma abordagem baseada em uma RNA adaptativa também foi empregada por Hosseini et al. (2021) com o intuito de regular níveis de tensão e a frequência da microrrede ilhada. Essas aplicações demonstram a capacidade das

RNAs operarem na detecção e estimativa de fenômenos de QEE.

Neste trabalho se propõe uma DNN treinada com dados sintetizados para aplicação de um estimador seletivo das amplitudes e ângulos de fase do conteúdo harmônico de 5<sup>a</sup>, 7<sup>a</sup>, 11<sup>a</sup> e 13<sup>a</sup> ordens da corrente de uma carga não-linear. Um modelo de retificador trifásico controlado com carga *RL*, usando fontes de corrente ideais, é usado para testar o estimador proposto. Um cenário de operação com o componente harmônico de corrente de 5<sup>a</sup> ordem no PCC também é avaliado.

A estrutura do texto está dividida em 5 seções. A Seção 2 apresenta uma síntese de conceitos e aplicações de DNNs. A Seção 3.1 apresenta o processo de geração do conjunto de amostras para treinamento, validação e testes. A Seção 3.2 apresenta o processo de configuração e implementação da DNN e a Seção 3.3 o treinamento do modelo de DNN para a estimativa do conteúdo harmônico. Um estudo de aplicação da DNN proposta na estimativa de componentes harmônicos para geração da corrente de referência de um FAP é exibido na Seção 4. A Seção 5 apresenta as conclusões deste trabalho e as limitações encontradas.

## 2. APLICAÇÃO DE REDES NEURAIIS PROFUNDAS

Uma RNA padrão é formada por várias unidades de processamento conectados de forma ordenada chamadas de neurônios. Esses neurônios geram uma sequência de valores reais em suas saídas (Schmidhuber, 2015). Dependendo do problema e de como os neurônios estão conectados, pode ser necessário utilizar engenharia de atributos (Souza et al., 2022) e vários estágios de processamento computacional para agregar a informação necessária à rede neural.

Uma rede neural formada por múltiplas camadas de processamento (com vários neurônios) pode ser denominada rede neural profunda (DNN). Essa combinação de múltiplas unidades, com diversas camadas de processamento, é denominada de aprendizado profundo (*deep learning*), que é utilizado, por exemplo, para identificar objetos em imagens, transcrever falas para textos, recomendar produtos a clientes (LeCun et al., 2015), construir carros autônomos (Chen et al., 2015), e até no auxílio ao diagnóstico na área de saúde (Esteva et al., 2017). O reconhecimento de padrões e/ou a capacidade de realizar estimativas advém do processo de aprendizagem, que é composto por uma série de métodos que permitem que o modelo seja alimentado com informações não tratadas e automaticamente realize a inferência necessária para a identificação ou classificação (LeCun et al., 2015; Souza et al., 2018).

Mesmo considerando o grande esforço computacional na etapa de treinamento do modelo de DNN, que pode demandar um conjunto de dados relativamente grande, a rede neural treinada requer um baixo esforço computacional em razão das operações matemáticas realizadas pelo modelo resultante. As DNNs podem ser usadas no estágio principal de processamento para reconhecer padrões (LeCun et al., 2015), como distorções harmônicas. Neste trabalho, uma DNN foi configurada para estimar amplitudes e ângulos de fase a partir de um sinal de um quarto de ciclo de onda, conforme a Seção 3. A estimativa resultante pode ser aplicada, por exemplo, na geração da corrente de

referência para um FAP, que pode promover a atenuação dos componentes estimados por meio da injeção de uma corrente de compensação no PCC, conforme ilustrado na Figura 1.

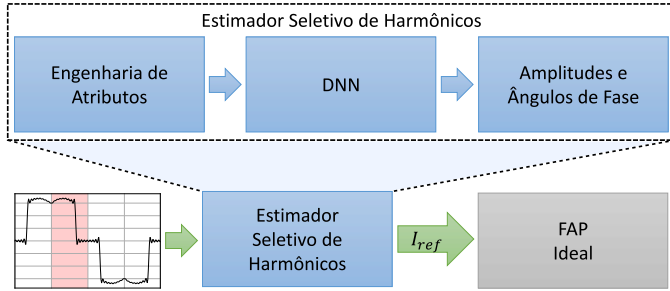


Figura 1. Estimador seletivo de harmônicos.

### 3. ESTIMADOR SELETIVO DE HARMÔNICOS

#### 3.1 Conjunto de Amostras para Treinamento, Validação e Testes da DNN

De acordo com (UCA, 2004), a taxa de amostragem recomendada na frequência fundamental da tensão de 60 Hz é de 15,36 kHz, o que resulta em um sinal discretizado com 256 amostras por ciclo do componente fundamental (64 amostras a cada um quarto de ciclo). Dessa forma, o treinamento das DNNs foi realizado a partir de um conjunto de dados representativos das formas de onda da corrente de carga no PCC analisado, considerando-se 64 amostras formadas a partir de um quarto de ciclo de onda. As correntes do conjunto de amostras são geradas, conforme dado em

$$i_k(t) = I_1 \cos(\omega t + \phi_1) + \sum_{m=5,11\dots35} I_m \cos(m\omega t + \phi_m) + \sum_{n=7,13\dots37} I_n \cos(n\omega t + \phi_n) \quad (1)$$

em que:

- $i_k(t)$  é a  $k$ -ésima corrente do conjunto de amostras, no domínio do tempo;
- $I_1$ ,  $I_m$  e  $I_n$  são respectivamente as amplitudes dos componentes fundamental, de ordem  $m$  (sequência negativa) e de ordem  $n$  (sequência positiva), em pu;
- $\phi_1$ ,  $\phi_m$  e  $\phi_n$  são, respectivamente, os ângulos de fase dos componentes fundamental, de ordem  $m$  e de ordem  $n$ , em radianos;
- $\omega$  é a frequência angular, em radianos por segundo; e  $t$  é o tempo, em segundos da microrrede.

A forma de construção do conjunto de amostras foi baseada em Temurtas et al. (2004). Somente o ângulo de fase 0,00 rad é usado quando a amplitude é 0,00 pu, ignorando-se as demais, para evitar repetições de formas de onda desnecessárias no conjunto de amostras. A eliminação de repetições otimiza o desempenho do processo de treinamento do modelo de DNN (Gupta et al., 2022). Idealmente, o conjunto de amostras poderia conter amplitudes até a unidade, por exemplo, e toda a faixa de ângulos, mas isso provocaria um aumento exponencial no tamanho do conjunto de amostras. Sendo assim, a fim de possibilitar que o conjunto fosse gerado, as amplitudes e

ângulos foram limitados para se adequarem à capacidade da RAM (16 GB) e da CPU (Intel(R) Core(TM) i7-10750H) disponíveis para uso neste trabalho.

Os componentes harmônicos utilizados na geração de amostras para treinamento estão disponíveis na Tabela 1, resultando em um conjunto de 4.515.840 formas de onda com 64 amostras cada. Cada amostra do conjunto é normalizada para manter a sua média próxima a zero e o seu desvio padrão próximo à unidade (Ba et al., 2016). Com o conjunto de amostras pronto, inicia-se o processo de configuração do modelo de DNN.

Tabela 1. Amplitudes e ângulos de fase empregados na formação do conjunto de amostras.

Harmônico	Amplitudes [pu]	Ângulos de fase [rad]
1	1,00	-1,5708
5	0,00; 0,05...0,25	1,4835; 1,5708; 1,6581
7	0,00; 0,05...0,15	1,4835; 1,5708; 1,6581
11	0,00; 0,05; 0,10	-1,4835; -1,5708; -1,6581
13	0,00; 0,05; 0,10	-1,4835; -1,5708; -1,6581
17	0,00; 0,05; 0,10	1,5708
19	0,00; 0,05; 0,10	1,5708
23	0,00; 0,05	-1,5708
25	0,00; 0,05	-1,5708
29	0,00; 0,05	1,5708
31	0,00; 0,05	1,5708
35	0,00; 0,05	-1,5708
37	0,00; 0,05	-1,5708

#### 3.2 Arquitetura do Modelo da DNN

O otimizador Adamax (Kingma e Ba, 2014), usado neste trabalho, é conveniente em aplicações que envolvem uma grande quantidade de dados e parâmetros, além de ser computacionalmente eficiente. Existem diversas funções de perda e métricas adequadas para DNNs com função regressora. Entretanto, segundo Chollet (2017), a função de perda e a métrica geralmente usadas são, respectivamente, a erro quadrático médio (MSE) e a erro absoluto médio (MAE), que podem ser definidas conforme (2) e (3), respectivamente. A métrica MAE informa quão próximas estão as estimativas em relação aos rótulos.

$$\text{MSE} = \sqrt{y_v - y_p} \quad (2)$$

$$\text{MAE} = |y_v - y_p| \quad (3)$$

em que:

- $y_v$  é a saída verdadeira, ou esperada;
- $y_p$  é a saída prevista, ou estimada, pela DNN.

É possível determinar as características da camada de entrada da DNN com base no formato do conjunto de amostras e da camada de saída com base nos objetivos definidos. Cada forma de onda do conjunto de amostras é armazenada em um vetor de 64 posições. Por isso, a camada de entrada da DNN terá um formato de 64 posições. Já a camada de saída deve ter 8 neurônios, visto que cada saída corresponde a uma amplitude e a um ângulo de fase das 4 ordens harmônicas estimadas. A função de ativação mais comumente empregada em DNNs de regressão é a linear (Chollet, 2017).

A DNN proposta neste trabalho tem camadas totalmente conectadas entre si, chamadas de camadas densas (*Dense*

layers). Utiliza-se o método de busca exaustiva sobre valores de parâmetros (Pedregosa et al., 2011) para definição da quantidade de camadas escondidas e do número de neurônios em cada camada. Esse método implementa um treinamento e uma pontuação para cada modelo criado dentro de critérios preestabelecidos. A busca utiliza o método de validação cruzada de divisão aleatória estratificada. Esse método fornece índices de treinamento e teste para dividir o conjunto de amostras em conjunto de treinamento e conjunto de teste. As dobras são feitas preservando a porcentagem de amostras para cada classe.

Assim, definiu-se que o conjunto de testes seria formado por 95% das amostras e o conjunto de treinamento por 5%, enquanto o conjunto de validação corresponde a 15% do conjunto de treinamento. Os parâmetros buscados são o número de neurônios ( $n$ ) nas camadas escondidas e o número de camadas escondidas ( $c$ ), tal que  $n = \{32, 40, 48, \dots, 144, 152\}$  e  $c = \{2, 3, 4\}$ . Uma característica essencial das camadas escondidas é a sua função de ativação. Segundo Chollet (2017), a ativação mais utilizada em redes neurais profundas é a unidade linear retificada (ReLU), a qual foi adotada nas camadas ocultas desse modelo.

Dessa forma, o modelo foi treinado e avaliado a cada mudança de parâmetros e os resultados da busca foram classificados em ordem crescente do MAE de avaliação. As cinco configurações que apresentaram os menores erros estão ilustradas na Tabela 2.

Tabela 2. Resultado da busca por parâmetros.

Classificação	Configuração das camadas ocultas	MAE
1	(112, 112, 112, 112)	$2,18 \cdot 10^{-6}$
2	(152, 152, 152)	$2,93 \cdot 10^{-6}$
3	(128, 128, 128, 128)	$4,00 \cdot 10^{-6}$
4	(136, 136, 136, 136)	$4,04 \cdot 10^{-6}$
5	(120, 120, 120, 120)	$5,02 \cdot 10^{-6}$

A configuração com menor MAE foi adotada para realizar a estimativa de amplitudes e ângulos de fase dos componentes harmônicos. Assim, o modelo final de DNN é descrito por meio da Tabela 3. As camadas receberam o inicializador de pesos sinápticos *Glorot Uniform* (Glorot e Bengio, 2010), padrão do Keras, com semente definida ( $seed = 333$ ) para reprodutibilidade dos experimentos. Após a configuração do modelo de DNN, o passo seguinte é realizar o treinamento.

Tabela 3. Configuração final da DNN.

Camada (tipo)	Ativação	Formato de saída	Parâmetros
entrada	-	(None, 64)	-
oculta_1 (Densa)	ReLU	(None, 112)	7280
oculta_2 (Densa)	ReLU	(None, 112)	12565
oculta_3 (Densa)	ReLU	(None, 112)	12565
oculta_4 (Densa)	ReLU	(None, 112)	12565
saída (Densa)	Linear	(None, 8)	904

### 3.3 Treinamento da DNN

O treinamento foi configurado da mesma forma que a busca exaustiva sobre valores de parâmetros, descrita na subseção 3.2. A interface Keras (Chollet, 2017) é usada para o treinamento da DNN. O número máximo de épocas definido é 200, podendo ser menor em caso de interrupção

antecipada caso o critério de parada seja atingido. Este estabelece uma condição de variação mínima no erro absoluto médio de  $10^{-4}$  em 5 épocas.

O histórico, que é o registro de valores de perda de treinamento e valores de métricas em épocas sucessivas, bem como valores de perda de validação e valores de métricas de validação (se aplicável), durante o treinamento pode ser observado na Figura 2. O treinamento acontece até a época 34, quando o critério de parada é acionado para evitar um esforço computacional desnecessário, visto que o erro absoluto médio não decresceu na taxa especificada de  $10^{-4}$  em 5 épocas. Na última época de treinamento, o MAE atingido foi de  $8,77 \cdot 10^{-4}$ .

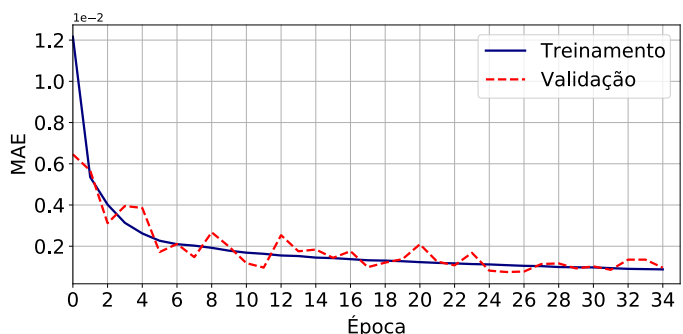


Figura 2. Histórico de treinamento.

A avaliação a partir do conjunto de teste atingiu um MAE de  $9,57 \cdot 10^{-4}$ , o que é considerado aceitável para a aplicação. Avaliando-se exclusivamente a estimativa de amplitudes, o MAE obtido foi de  $4,81 \cdot 10^{-4}$  pu, o que representa 50,3% do valor do MAE de treinamento. Já a avaliação exclusiva dos ângulos de fase apurou um MAE de  $1,43 \cdot 10^{-3}$  rad, equivalente a 149,7% do MAE de treinamento. Esse resultado indica que a DNN tem melhor desempenho na estimativa de amplitudes, quando comparado ao desempenho na estimativa de ângulos de fase. Estatisticamente, pode-se avaliar o desempenho do modelo quando submetido às amostras de teste por meio do diagrama de caixa (*boxplot*) da Figura 3, que representa o agrupamento de erros individuais por ordem harmônica observados na saída da DNN por meio de quartis.




Figura 3. Avaliação da DNN a partir das amostras de teste. (a) Estimativa de amplitude e (b) estimativa de ângulos de fase.

Na Figura 3, observa-se que as medianas de todos os erros de amplitude ficaram menores que  $10^{-3}$  pu e as medianas

de todos erros de ângulo de fase ficaram menores que  $2 \cdot 10^{-3}$  rad. Os erros de 99% das estimativas de amplitude do 5<sup>o</sup>, 7<sup>o</sup>, 11<sup>o</sup> e 13<sup>o</sup> harmônicos foram, respectivamente, menores que  $1,87 \cdot 10^{-3}$  pu,  $1,74 \cdot 10^{-3}$  pu,  $9,41 \cdot 10^{-3}$  pu, e  $1,42 \cdot 10^{-3}$  pu. Já os erros de 99% das estimativas de ângulo de fase destes harmônicos foram, respectivamente, menores que  $4,40 \cdot 10^{-3}$  rad,  $6,49 \cdot 10^{-3}$  rad,  $2,45 \cdot 10^{-3}$  rad e  $2,98 \cdot 10^{-3}$  rad.

#### 4. COMPENSAÇÃO SELETIVA DOS HARMÔNICOS ESTIMADOS POR DNN

Dois casos são estudados nesta seção. No primeiro caso realiza-se uma análise de desempenho de um FAP que recebe as amplitudes e ângulos de fase da corrente de referência fornecidos pela DNN proposta, atenuando os componentes harmônicos de corrente de 5<sup>a</sup>, 7<sup>a</sup>, 11<sup>a</sup> e 13<sup>a</sup> ordens. No segundo caso, a atenuação é realizada em um cenário no qual a corrente a ser compensada contém os componentes fundamental e 5<sup>o</sup> harmônico.

##### 4.1 Caso com corrente no PCC contendo componentes harmônicos até a 5<sup>a</sup> ordem

Neste caso, avalia-se a aplicação de um modelo computacional de FAP (Akagi, 1996) simulado como uma fonte de corrente trifásica controlada equilibrada (ideal), apresentado na Figura 4, para demonstrar a compensação seletiva dos componentes harmônicos de corrente estimados pela DNN proposta. As características de compensação do FAP são definidas principalmente pela estratégia usada para determinar o conteúdo harmônico da corrente de carga, com o objetivo de gerar uma corrente de referência para o seu sistema de controle (Akagi et al., 2007; Watanabe et al., 2004). Os autores de (Akagi et al., 1984) utilizam a teoria de potência ativa e reativa instantâneas (Teoria p-q) para calcular a corrente de referência dos FAPs, que utilizam métodos convencionais de controle operando com um desempenho dentro do projetado (Akagi, 1996). Além disso, a Teoria p-q possibilita o cálculo preciso da capacitância do lado CC do FAP, valendo-se da constante de inércia desse conversor (Nascimento et al., 2017). Um sistema de controle que aplica uma estratégia de DNN para extrair o conteúdo harmônico e gerar a corrente de referência tem a vantagem de determinar esse conteúdo em apenas um quarto de ciclo da rede e compensar de forma seletiva. A carga não-linear usado neste trabalho é composta por um retificador trifásico controlado alimentando uma carga RL equilibrada. O ângulo de disparo do retificador é de  $\pi/6$  rad (30°) e duas combinações de carga foram avaliadas. A primeira combinação apresenta  $R = 10\Omega$  e  $L = 5\text{mH}$ , e a segunda apresenta  $R = 20\Omega$  e  $L = 10\text{mH}$ . As tensões do lado CA são consideradas equilibradas e puramente senoidais.

A compensação harmônica inicia-se pela aquisição do sinal da corrente distorcida no processo de sensoriamento, condicionamento e digitalização, que realiza a filtragem do sinal analógico por meio de um filtro passa-baixas configurado para que as frequências maiores que 780Hz (13<sup>o</sup> harmônico) sejam eliminadas. Nessa etapa também ocorre a normalização e a conversão analógica-digital do sinal de corrente. O sinal digitalizado passa pelo processo de estimativa harmônica, que é composto pelas fases

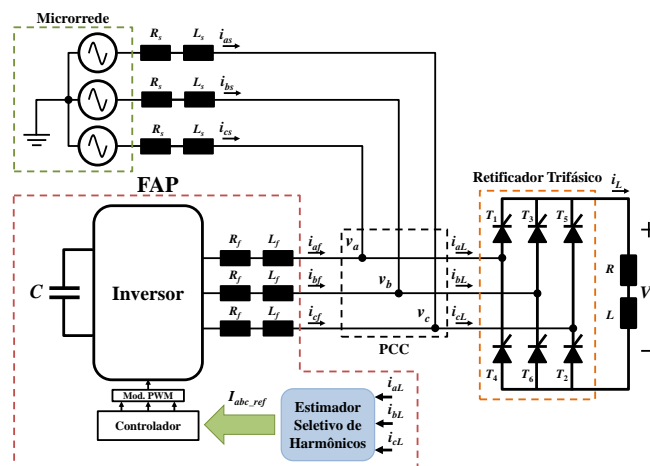


Figura 4. FAP usando estimador seletivo de harmônicos com DNN.

de engenharia de atributos, e estimativa pela DNN. A engenharia de atributos é responsável por adaptar o sinal digital ao formato de entrada da DNN, o que inclui a normalização e agregação de 64 amostras a cada um quarto de ciclo de onda em um vetor. Esse vetor é, então, submetido à DNN, que retorna a estimativa de amplitudes e ângulos de fase do sinal de entrada. Os valores estimados são utilizados para reconstrução do sinal de referência para que o FAP gere a corrente de compensação seletiva. A corrente de compensação é injetada no PCC proporcionando a atenuação da distorção harmônica total (DHT) nesse ponto.

A Tabela 4 e a Figura 5 apresentam a atenuação seletiva dos componentes harmônicos de corrente estimados pela DNN. Houve uma significativa atenuação realizada pelo FAP de todos os harmônicos estimados. A DNN foi capaz de estimar com precisão as componentes harmônicas de corrente indesejadas, o que proporcionou a geração de um sinal de referência adequado para a operação do FAP.

Tabela 4. Distorções harmônicas individuais e DHT, antes e após a compensação harmônica com estimativa dos componentes pela DNN.

Harmônico	Antes da Compensação	Após a Compensação
5	22,3%	3,1%
7	11,7%	2,3%
11	9,1%	0,5%
13	6,6%	0,8%
DHT	29,9%	12,2%




Figura 5. Espectro harmônico da corrente no PCC, antes (azul escuro) e após (azul claro) a compensação.

Na Figura 6(a), a corrente no PCC é mostrada diante de 3 cenários de operação. Inicialmente, entre 0 e 37,5 ms, a corrente de carga é exibida. A partir desse instante, a




Figura 6. Compensação dos harmônicos estimados. (a) Corrente da microrrede ( $i_{as}$ ). (b) Corrente de compensação ( $i_{af}$ ).

corrente de compensação gerada pelo FAP, mostrada na Figura 6(b), é injetada no PCC. A carga  $RL$  é alterada em 70,8 ms gerando um degrau negativo, o que faz com que DNN estime o novo conteúdo harmônico para ser aplicado no FAP. Note que a compensação se mantém efetiva mesmo com a alteração de carga promovida no teste, mas agora com uma nova corrente de compensação (Figura 6(b)). A redução da DHT com a estimador seletivo proposto para gerar a referência de compensação foi de 29,88% para 12,16% representando uma melhora de 57%, enquanto componentes harmônicos individuais (selecionados pela estratégia proposta) foram atenuados entre 50 e 92%, indicando a viabilidade da DNN nesse tipo de aplicação. A distorção remanescente da compensação na Figura 6(a) pode ser devida ao erro da estimativa harmônica, por conta do processamento, e/ou em razão de componentes harmônicos acima dos que foram estimados e compensados (acima do 13<sup>o</sup>).

#### 4.2 Caso com corrente no PCC contendo o componente fundamental e o 5<sup>o</sup> harmônico

Existem casos em que a corrente no PCC de um sistema de potência é composta pelo componente fundamental da instalação conhecida e por harmônicos gerados por fontes desconhecidas, que circulam na rede principal, como, por exemplo, o 5<sup>o</sup> harmônico. Esse caso também foi estudado nesse trabalho, considerando a corrente fundamental com amplitude de 13A e o 5<sup>o</sup> harmônico (22,3% do fundamental). A DNN proposta é aplicada na estimativa dos componentes harmônicos contidos no sinal de corrente do PCC. O resultado da estimativa é usado para reconstrução do sinal e geração da corrente de compensação pelo FAP. As formas de onda da corrente da microrrede e da corrente de compensação estão ilustradas na Figura 7. O resultado da atenuação reduziu a amplitude do 5<sup>o</sup> harmônico para 0,29%, o que representa praticamente uma compensação completa.

#### 4.3 Comparação com outros métodos de regressão

A fim de se comparar a abordagem proposta com outros métodos de regressão, utilizou-se os métodos de árvore de decisão (DT) e vizinhos próximos (KNN) (Pedregosa et al., 2011; Bernardino, 2022) configuradas de acordo com o trabalho de Bernardino (2022), no qual foram utilizados métodos de busca por parâmetros suficientemente adequados para a estimação do conteúdo harmônico de correntes.




Figura 7. Compensação do 5<sup>o</sup> harmônico. (a) Corrente da microrrede ( $i_{as}$ ). (b) Corrente de compensação ( $i_{af}$ ).

Assim, o algoritmo de DT foi configurado com uma profundidade máxima de 10 e critério de erro MSE. A KNN foi configurada com a métrica euclidiana e com o número de vizinhos igual a 5. Com os métodos treinados, a amostra de corrente do retificador foi submetida aos modelos, resultando nos valores da Tabela 5.

Tabela 5. Comparação entre regressores.

Método	Harmônico	Antes da Compensação	Após a Compensação
DT	5	22,3%	0,8%
	7	11,7%	0,4%
	11	9,1%	1,1%
	13	6,6%	0,8%
	DHT	29,9%	11,6%
DNN	5	22,3%	3,1%
	7	11,7%	2,3%
	11	9,1%	0,5%
	13	6,6%	0,8%
	DHT	29,9%	12,2%
KNN	5	22,3%	3,6%
	7	11,7%	2,5%
	11	9,1%	0,9%
	13	6,6%	1,9%
	DHT	29,9%	12,5%

Pode-se observar que o método de estimativa e compensação harmônica utilizando a DNN atingiu um resultado intermediário de redução da DHT quando comparado aos outros métodos testados. O método DT forneceu uma estimativa dos componentes harmônicos capaz de reduzir cerca de 96,4% do componente de 5<sup>o</sup> harmônico e cerca

de 96,6% do componente de 7<sup>a</sup> ordem, que possuem as maiores amplitudes entre os harmônicos da corrente do retificador, desempenhando uma compensação mais efetiva quando comparado ao método com DNN. Já o desempenho com o método KNN foi menos eficaz em todas as ordens harmônicas compensadas, o que resultou em um maior percentual de DHT após a compensação.

## 5. CONCLUSÃO

Esse artigo apresentou uma proposta de estimador seletivo de componentes harmônicos, por meio de DNN, o qual é capaz de extrair as amplitudes e ângulos de fase de uma forma de onda periódica, a partir de medidas de um quarto do ciclo fundamental. A estimativa seletiva baseada em DNN pode ser aplicada, por exemplo, para a compensação harmônica usando um FAP, conforme ilustrado no teste de compensação realizado na Seção 3. Os resultados obtidos demonstraram que os harmônicos de interesse foram significativamente atenuados (entre 80 e 94%), reduzindo a DHT em mais de 59% no PCC. Após o treinamento da DNN, a partir do conjunto de amostras gerado, o teste de avaliação com 5% das amostras do conjunto indicou que 99% dos erros das amplitudes estimadas estão abaixo de  $2 \cdot 10^{-3}$ , ou 0,2 pu. Em relação aos ângulos de fase, 99% dos erros de estimativa estão abaixo de 0,03 rad. Os resultados dos testes e comparações com outros métodos de regressão (conforme Seção 4.3) indicaram que a precisão do método proposto através da DNN resulta em valores semelhantes a outros métodos da literatura (DT e KNN), validando sua aplicabilidade e com a vantagem da detecção em um quarto de ciclo da fundamental. Como era esperado, no caso de formas de onda com amplitudes e ângulos de fase fora da faixa treinada, algumas limitações foram encontradas, principalmente em razão dos limites de memória computacional para o treinamento da DNN. Futuramente, pretende-se estender a aplicação dessa estratégia com um novo algoritmo de treinamento e realizar testes experimentais em um hardware dedicado.

## AGRADECIMENTOS

Os autores agradecem à FAPESP (Proc. 2016/08645-9, 2022/00317-3), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001, à FAPERJ (Proc. E-26/201.078/2021), e à UNESP pelos suportes financeiros para o desenvolvimento do presente trabalho.

## REFERÊNCIAS

- Akagi, H. (1996). New trends in active filters for power conditioning. *IEEE Transactions on Industry Applications*, 32(6), 1312–1322.
- Akagi, H. (2005). Active harmonic filters. *Proceedings of the IEEE*, 93(12), 2128–2141.
- Akagi, H., Kanazawa, Y., e Nabae, A. (1984). Instantaneous reactive power compensators comprising switching devices without energy storage components. *IEEE Transactions on Industry Applications*, IA-20(3), 625–630.
- Akagi, H., Watanabe, E.H., e Aredes, M. (2007). *Instantaneous Power Theory and Applications to Power Conditioning*. John Wiley & Sons, Inc.

- Alsaidan, I., Chaudhary, P., Alaraj, M., e Rizwan, M. (2021). An intelligent approach to active and reactive power control in a grid-connected solar photovoltaic system. *Sustainability*, 13(8), 4219.
- Arrillaga, J. e Watson, N.R. (2004). *Effects of Harmonic Distortion*, 143–189. John Wiley & Sons, Ltd.
- Ba, J.L., Kiros, J.R., e Hinton, G.E. (2016). Layer normalization.
- Baitha, A. e Gupta, N. (2015). A comparative analysis of passive filters for power quality improvement. In *2015 International Conference on Technological Advancements in Power and Energy (TAP Energy)*, 327–332.
- Bernardino, L.G.R. (2022). *Estimador seletivo do conteúdo harmônico de tensão e corrente baseado em rede neural profunda*. Dissertação de mestrado, Universidade Federal de São Carlos.
- Chawda, G.S. et al. (2020). Comprehensive review on detection and classification of power quality disturbances in utility grid with renewable energy penetration. *IEEE Access*, 8, 146807–146830.
- Chen, C., Seff, A., Kornhauser, A., e Xiao, J. (2015). Deepdriving: Learning affordance for direct perception in autonomous driving. In *Proceedings of the International Conference on Computer Vision*, 2722–2730.
- Chollet, F. (2017). *Deep Learning with Python*. Manning.
- Dovgun, V., Egorov, D., e Temerbaev, S. (2020). Passive filtering systems for multipulse rectifiers. In *Proceedings of the International Ural Conference on Electrical Power Engineering*, 235–239.
- Esteva, A., Kuprel, B., Novoa, R.A., Ko, J., Swetter, S.M., Blau, H.M., e Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118.
- Faria, J., Pombo, J., Calado, M., e Mariano, S. (2019). Power management control strategy based on artificial neural networks for standalone PV applications with a hybrid energy storage system. *Energies*, 12(5), 902.
- Flores-Garrido, J.L., Salmerón, P., e Gómez-Galán, J.A. (2021). Nonlinear loads compensation using a shunt active power filter controlled by feedforward neural networks. *Applied Sciences*, 11(16), 7737.
- Glorot, X. e Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. In *Proceedings of the International Conference on Artificial Intelligence and Statistics*, volume 9, 249–256.
- Gong, R. e Ruan, T. (2020). A new convolutional network structure for power quality disturbance identification and classification in micro-grids. *IEEE Access*, 8, 88801–88814.
- Gupta, S., Paudel, A., Thapa, M., Mulani, S.B., e Walters, R. (2022). Adaptive sampling-based artificial neural network for surrogate modeling. In *AIAA SCITECH 2022 Forum*. American Institute of Aeronautics and Astronautics.
- Hosseini, H., Radmehr, M., e Ranjbar, S. (2021). Central damping controller for microgrid voltage and frequency dynamic stability using adaptive artificial neural network. *Journal of Control, Automation and Electrical Systems*, 32(1), 1024–1040.
- Kingma, D.P. e Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv*.
- Kumar, N., Singh, B., e Panigrahi, B.K. (2019). PNKLMF-based neural network control and learning-

- based HC MPPT technique for multiobjective grid integrated solar PV based distributed generating system. *IEEE Transactions on Industrial Informatics*, 15(6), 3732–3742.
- Kumar, R. e Bansal, H.O. (2019). Real-time implementation of adaptive PV-integrated SAPF to enhance power quality. *International Transactions on Electrical Energy Systems*, 29(5), e12004.
- LeCun, Y., Bengio, Y., e Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Mattavelli, P. e Marafão, F. (2004). Repetitive-based control for selective harmonic compensation in active power filters. *IEEE Transactions on Industrial Electronics*, 51(5), 1018–1024.
- Nascimento, C.F. et al. (2017). Analysis of noncharacteristic harmonics generated by voltage-source converters operating under unbalanced voltage. *IEEE Transactions on Power Delivery*, 32(2), 951–961.
- Pedregosa, F. et al. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Ray, P., Ray, P.K., e Dash, S.K. (2022). Power quality enhancement and power flow analysis of a PV integrated UPQC system in a distribution network. *IEEE Transactions on Industry Applications*, 58(1), 201–211.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117.
- Singh, B., Al-Haddad, K., e Chandra, A. (1999). A review of active filters for power quality improvement. *IEEE Transactions on Industrial Electronics*, 46(5), 960–971.
- Souza, W.A. et al. (2018). A NILM dataset for cognitive meters based on conservative power theory and pattern recognition techniques. *Journal of Control, Automation and Electrical Systems*, 29(6), 742–755.
- Souza, W.A. et al. (2022). Selection of features from power theories to compose NILM datasets. *Advanced Engineering Informatics*, 52, 101556.
- Temurtas, F., Gunturkun, R., Yumusak, N., e Temurtas, H. (2004). Harmonic detection using feed forward and recurrent neural networks for active filters. *Electric Power Systems Research*, 72(1), 33–40.
- UCA (2004). Implementation guideline for digital interface to instrument transformers using IEC 61850-9-2. Available online: <https://iec61850.ucaiug.org/Implementation%20Guidelines/Forms/AllItems.aspx>. Accessed on 16 March 2022.
- Ucar, F., Cordova, J., Alcin, O.F., Dandil, B., Ata, F., e Arghandeh, R. (2019). Bundle extreme learning machine for power quality analysis in transmission networks. *Energies*, 12(8), 1449.
- Wang, L., Zhu, Z.Q., Bin, H., e Gong, L.M. (2020). Current harmonics suppression strategy for PMSM with non-sinusoidal back-EMF based on adaptive linear neuron method. *IEEE Transactions on Industrial Electronics*, 67(11), 9164–9173.
- Watanabe, E.H., Akagi, H., e Aredes, M. (2004). The p-q Theory for active filter control: Some problems and solutions. *Revista Controle & Automação*, 15(1), 78–84.
- Xiao, X. e Li, K. (2021). Multi-label classification for power quality disturbances by integrated deep learning. *IEEE Access*, 9, 152250–152260.
- Žnidarec, M., Klaić, Z., Šljivac, D., e Dumnić, B. (2019). Harmonic distortion prediction model of a grid-tie photovoltaic inverter using an artificial neural network. *Energies*, 12(5), 790.