

UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Luiz Gustavo Reis Bernardino**

**Estimador Seletivo do Conteúdo  
Harmônico de Tensão e Corrente  
Baseado em Rede Neural Profunda**



**Luiz Gustavo Reis Bernardino**

**Estimador Seletivo do Conteúdo  
Harmônico de Tensão e Corrente  
Baseado em Rede Neural Profunda**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Sistemas Elétricos e Eletrônicos

Orientador: Prof. Dr. Claudionor Francisco do Nascimento

Coorientador: Prof. Dr. Fernando Pinhabel Marafão

São Carlos - SP

2022





**UNIVERSIDADE FEDERAL DE SÃO CARLOS**

Centro de Ciências Exatas e de Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica

---

**Folha de Aprovação**

---

Defesa de Dissertação de Mestrado do candidato Luiz Gustavo Reis Bernardino, realizada em 27/04/2022.

**Comissão Julgadora:**

Prof. Dr. Claudionor Francisco do Nascimento (UFSCar)

Prof. Dr. Alfeu Joãozinho Sguarezi Filho (UFABC)

Prof. Dr. Wesley Angelino de Souza (UTFPR)

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia Elétrica.



*Este trabalho é dedicado à minha avó,  
Teolina Maria Bonini (in memoriam).*



---

# Agradecimentos

---

Agradeço a minha família, que sempre me deu apoio, de todas as formas possíveis, para realizar este e tantos outros objetivos.

Agradeço ao Prof. Dr. Claudionor Francisco do Nascimento, que depositou a sua confiança neste trabalho e me orientou brilhantemente desde o início.

Agradeço ao Prof. Dr. Fernando Pinhabel Marafão, por também ter confiado neste trabalho e por ter aceito me coorientar.

Agradeço ao Prof. Dr. Wesley Angelino de Souza por suas contribuições essenciais com este trabalho e por sua paciência em compartilhar o seu grande conhecimento.

Agradeço ao Prof. Dr. Roberto Fernandes Tavares Neto por suas contribuições tempestivas com este trabalho e por sua disponibilidade em compartilhar seu conhecimento.

Agradeço aos colegas mestrandos do Programa de Pós-Graduação em Engenharia Elétrica, em especial aos colegas Paulo Fernando Silva e Alex Ferreira Silva, por compartilharem seu conhecimento contribuindo, não só com este trabalho, mas também com o meu amadurecimento pessoal.

Agradeço ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de São Carlos pela confiança depositada e pelo apoio dispendido.

Agradeço ao Professor José Antenor Pomilio, coordenador do Laboratório de Pesquisas em Redes Elétricas Inteligentes, por ter nos acolhido como parte da sua equipe.

Finalmente, agradeço a Deus pela saúde que tenho, pelas pessoas que fazem e fizeram parte da minha vida, e por me conceder a oportunidade de concluir as metas pessoais e profissionais que estabeleço.



*"Em tudo dai graças, porque esta é a vontade  
de Deus em Cristo Jesus para convosco."  
(1 Tessalonicenses 5:18)*



---

# Resumo

---

Um problema comum quando cargas não-lineares estão presentes em sistemas de distribuição de energia elétrica é a distorção harmônica de tensão e/ou corrente. Esse problema de qualidade da energia elétrica (QEE) pode ser mitigado, mas antes os componentes harmônicos precisam ser identificados ou estimados. O objetivo deste trabalho é desenvolver um método para a estimativa seletiva de amplitudes e ângulos de fase dos componentes harmônicos de 3<sup>a</sup>, 5<sup>a</sup>, 7<sup>a</sup> e 9<sup>a</sup> ordens a partir de amostras de um quarto de ciclo de formas de onda desconhecidas, baseado em redes neurais profundas (DNN - *deep neural networks*). Um conjunto de amostras de formas de onda de corrente com um quarto de ciclo foi gerado para treinamento, validação e testes da DNN. Utilizou-se a busca exaustiva por parâmetros em conjunto com a validação cruzada para a definição da configuração do modelo computacional, o que resultou na configuração de DNN utilizada neste trabalho. Outros métodos de regressão foram comparados à DNN para justificar o seu uso, mostrando que o método de redes neurais é capaz de alcançar menores erros em relação aos demais métodos testados. Os resultados de testes mostram que é possível realizar atenuação da distorção harmônica total (THD) por meio de um filtro ativo de potência (FAP) ideal. Esse FAP recebe a corrente de referência gerada por meio das amplitudes e ângulos de fase estimados pela DNN proposta. Conseguiu-se uma atenuação da THD de 18,54% para 0,81% no estudo de caso realizado com FAP ideal. A validação do método ocorreu por meio de simulações computacionais que demonstraram a capacidade de estimar seletivamente os harmônicos por meio de um sinal de corrente com amostragem de um quarto de ciclo. A principal contribuição do trabalho é a proposta de um método de estimativa harmônica seletiva que pode ser empregado, por exemplo, em um FAP, para atenuação da distorção harmônica, ou em aplicações de monitoramento e controle da QEE.

**Palavras-chave:** Estimativa do Conteúdo Harmônico. Redes Neurais Artificiais. Aprendizado Profundo. Aprendizado de Máquina. Qualidade da Energia Elétrica.



---

# Abstract

---

A common issue when non-linear loads are present in electric power distribution systems is voltage and/or current harmonic distortion. This power quality (PQ) problem can be mitigated, but first the harmonic components need to be identified or estimated. The main goal of this work is to develop a method for the selective estimation of amplitudes and phase shifts of the 3, 5, 7 and 9 harmonics from quarter-cycle samples of unknown waveforms, based on deep neural networks (DNN). A sample set of quarter-cycle current waveforms was generated for DNN training, validation and testing. A grid search for parameters was used together with cross validation to define the configuration of the computational model, which resulted in the DNN configuration used in this work. Other regression methods were compared to DNN to justify its use, showing that the neural network method is capable of achieving lower errors in relation to the other methods tested. Test results show that it is possible to achieve total harmonic distortion (THD) attenuation by means of an ideal active power filter (APF). This APF receives the reference current generated through the amplitudes and phase angles estimated by the proposed DNN. An THD attenuation was achieved from 18.54% to 0.81% in the case study carried out with ideal APF. The method validation took place through computer simulations that demonstrated the ability to selectively estimate harmonics through a current signal with a quarter-cycle sampling. The main contribution of this work is the proposal of a selective harmonic estimation method that can be used, for example, in an APF, for harmonic distortion attenuation, or in PQ monitoring and control applications.

**Keywords:** Harmonic Estimation. Artificial Neural Networks. Deep Learning. Machine Learning. Power Quality.



---

# Lista de Figuras

---

Figura 1 – Neurônio Artificial. . . . .	41
Figura 2 – Função de Ativação ReLU. . . . .	42
Figura 3 – Exemplo de arquitetura de múltiplas camadas com uma camada oculta. . . . .	43
Figura 4 – Procedimentos de geração de amostras e rótulos e de treinamento e aplicação da DNN. . . . .	55
Figura 5 – Exemplo de resultado da busca em grade (busca por parâmetros). . . . .	57
Figura 6 – Histórico de treinamento: (a) utilizando divisão aleatória de amostras e (b) com divisão estratificada de amostras. . . . .	59
Figura 7 – Diagramas de caixa dos erros absolutos individuais da DNN em relação a (a) amplitudes e a (b) ângulos de fase. . . . .	60
Figura 8 – Testes 1: (a) formas de onda comparativas e (b) erro em 1 ciclo da forma de onda. Teste 2: (c) formas de onda comparativas e (d) erro em 1 ciclo. . . . .	67
Figura 9 – Formas de onda comparativas referentes aos testes (a) 3, (b) 4, (c) 5, (d) 6. . . . .	68
Figura 10 – Formas de onda comparativas referentes aos testes (a) 7, (b) 8, (c) 9, (d) 10, (e) 11, (f) 12. . . . .	69
Figura 11 – Aplicação da rede neural profunda (DNN) como estimador seletivo de harmônicos do filtro ativo de potência (FAP). . . . .	70
Figura 12 – Exemplo de aplicação: FAP. . . . .	70
Figura 13 – Caso 1: (a) corrente no PCC, (b) corrente de compensação, (c) DHT. . . . .	72
Figura 14 – Caso 2: (a) corrente no PCC, (b) corrente de compensação, (c) DHT. . . . .	73
Figura 15 – Caso 3: (a) corrente no PCC, (b) corrente de compensação, (c) DHT. . . . .	74
Figura 16 – Caso 4: (a) corrente no PCC, (b) corrente de compensação, (c) DHT. . . . .	75
Figura 17 – Caso 5: (a) corrente no PCC, (b) corrente de compensação, (c) DHT. . . . .	76
Figura 18 – Caso 6: (a) corrente no PCC, (b) corrente de compensação, (c) DHT. . . . .	77



---

# Lista de Tabelas

---

Tabela 1 – Categorias e características de fenômenos eletromagnéticos do sistema elétrico. . . . .	26
Tabela 2 – Função de ativação recomendada por tipo de problema. . . . .	42
Tabela 3 – Amplitudes e ângulos de fase dos harmônicos presentes no conjunto de amostras de treinamento e validação. . . . .	55
Tabela 4 – Resultado da busca por parâmetros. . . . .	57
Tabela 5 – Configuração final da DNN. . . . .	58
Tabela 6 – Busca em grade para a regressão Ridge. . . . .	61
Tabela 7 – Busca em grade para Vizinhos Mais Próximos. . . . .	62
Tabela 8 – Busca em grade para Árvore de Decisão. . . . .	63
Tabela 9 – Busca em grade para Floresta de Decisão Aleatória. . . . .	63
Tabela 10 – Classificação baseada no MAE obtido entre os métodos comparados. . . . .	64
Tabela 11 – Descrição das cargas. . . . .	65
Tabela 12 – Características harmônicas das correntes de carga. . . . .	66
Tabela 13 – Descrição dos testes. . . . .	66
Tabela 14 – Erros de amplitude [pu] e ângulos de fase [rad], e diferença média e máxima entre amplitudes das formas de onda apresentadas nos testes. . . . .	67
Tabela 15 – Características harmônicas das correntes de carga. . . . .	71
Tabela 16 – Descrição dos casos estudados. . . . .	72
Tabela 17 – Comparação do tempo médio de 1.000 execuções de DNN e DFT. . . . .	79



---

# Lista de Siglas

---

- API** interface de programação de aplicações
- CA** corrente alternada
- CED** conjunto de equipamentos domésticos
- CEE** conjunto de equipamentos de escritório
- CEI** conjunto de equipamentos de iluminação
- DFT** transformada discreta de Fourier
- DNN** rede neural profunda
- DHT** distorção harmônica total
- FAP** filtro ativo de potência
- FFT** transformada rápida de Fourier
- IA** inteligência artificial
- MAE** erro absoluto médio
- MR** microrrede
- MSE** erro quadrático médio
- PCC** ponto de conexão comum
- PMC** *perceptron* de múltiplas camadas
- PV** fotovoltaica
- QEE** qualidade da energia elétrica
- ReLU** unidade linear retificada
- RNA** rede neural artificial



---

# Lista de Símbolos

---

$\Delta_{max}$  diferença máxima entre amplitudes instantâneas

$\Delta_{med}$  diferença média entre amplitudes instantâneas

$\mu s$  microssegundo

$\omega$  velocidade angular

$\phi_n$  ângulo de fase do harmônico de ordem n

$A_n$  amplitude de pico do harmônico de ordem n

$GB$  giga byte

$Hz$  Hertz

$i$  corrente elétrica

$kB$  quilo byte

$kHz$  quilo hertz

$kV$  quilo Volt

$min$  minuto

$ms$  milissegundo

$ns$  nanossegundo

$pu$  por unidade

$rad$  radiano

$s$  segundo

$t$  tempo, em segundos

$V$  Volt

---

# Sumário

---

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>25</b>
1.1	Aspectos de Qualidade da Energia Elétrica . . . . .	25
1.2	Determinação do Conteúdo Harmônico . . . . .	27
1.3	Estimativa Harmônica com Redes Neurais Profundas . . . . .	28
1.4	Objetivos . . . . .	29
1.5	Justificativa . . . . .	30
1.6	Principais Contribuições . . . . .	31
<b>2</b>	<b>DETECÇÃO DO CONTEÚDO HARMÔNICO . . . . .</b>	<b>33</b>
2.1	Distorção Harmônica em Baixa Tensão . . . . .	33
2.2	Métodos de Identificação Harmônica . . . . .	35
2.3	Aplicação de Redes Neurais Artificiais . . . . .	36
<b>3</b>	<b>SÍNTESE DE REDES NEURAIS ARTIFICIAIS . . . . .</b>	<b>39</b>
<b>3.1</b>	<b>Definições e Características Gerais . . . . .</b>	<b>39</b>
3.1.1	Neurônio Artificial . . . . .	40
3.1.2	Funções de Ativação . . . . .	41
3.1.3	Arquiteturas de Redes Neurais Artificiais . . . . .	42
3.1.4	Treinamento e Aprendizado de Máquina . . . . .	44
<b>3.2</b>	<b>Implementação de RNAs em Python . . . . .</b>	<b>45</b>
3.2.1	Pacotes e Bibliotecas para RNAs em Python . . . . .	45
3.2.2	A Interface Keras na Implementação de RNAs em Python . . . . .	46
<b>3.3</b>	<b>Aprendizado Profundo com Python . . . . .</b>	<b>51</b>
<b>4</b>	<b>ESTIMATIVA DO CONTEÚDO HARMÔNICO . . . . .</b>	<b>53</b>
4.1	Amostras para Treinamento, Validação e Testes . . . . .	53
4.2	Arquitetura do Modelo da DNN . . . . .	56

<b>4.3</b>	<b>Método de Treinamento da DNN . . . . .</b>	<b>58</b>
<b>4.4</b>	<b>Comparação entre Métodos de Regressão . . . . .</b>	<b>60</b>
4.4.1	Regressão Ridge . . . . .	61
4.4.2	Vizinhos Mais Próximos . . . . .	61
4.4.3	Árvore de Decisão . . . . .	62
4.4.4	Floresta de Decisão Aleatória . . . . .	63
4.4.5	Classificação dos Métodos Comparados . . . . .	63
<b>5</b>	<b>RESULTADOS E DISCUSSÕES . . . . .</b>	<b>65</b>
<b>5.1</b>	<b>Testes com Correntes de Cargas Experimentais . . . . .</b>	<b>65</b>
<b>5.2</b>	<b>Compensação Seletiva de Harmônicos Estimados por DNN . . . . .</b>	<b>69</b>
5.2.1	Caso 1: Conjunto de Equipamentos Domésticos 1 . . . . .	72
5.2.2	Caso 2: Conjunto de Equipamentos Domésticos 2 . . . . .	73
5.2.3	Caso 3: Conjunto de Equipamentos de Escritório 1 . . . . .	74
5.2.4	Caso 4: Conjunto de Equipamentos de Escritório 2 . . . . .	75
5.2.5	Caso 5: Conjunto de Equipamentos de Iluminação 1 . . . . .	76
5.2.6	Caso 6: Conjunto de Equipamentos de Iluminação 2 . . . . .	77
<b>5.3</b>	<b>Conclusões Parciais . . . . .</b>	<b>78</b>
	<b>CONCLUSÃO . . . . .</b>	<b>81</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>85</b>

---

# Capítulo 1

## Introdução

---

Os sistemas elétricos avançados podem ser considerados como um conjunto de sistemas com fontes energéticas distribuídas (HE et al., 2017). A geração e a circulação de harmônicos em sistemas de distribuição de energia elétrica ocorrem devido à presença de cargas não-lineares como os conversores eletrônicos, responsáveis por conectar fontes distribuídas de energia à rede elétrica das concessionárias (DUGAN et al., 2012). A manutenção de indicadores de qualidade da energia elétrica (QEE) dentro dos padrões estabelecidos ainda é uma tarefa crítica, especialmente quando se trata de perdas provocadas por componentes harmônicos gerados por cargas não-lineares (NASCIMENTO et al., 2017).

A DNN, do inglês *deep neural network*, proposta neste trabalho foi testada com cargas não-lineares para demonstrar a sua capacidade de estimar harmônicos e fornecer a corrente de referência a um FAP para geração da corrente de compensação, promovendo a atenuação da distorção harmônica total (DHT).

### 1.1 Aspectos de Qualidade da Energia Elétrica

Um bom desempenho dos indicadores de QEE é um dos aspectos essenciais dos sistemas de distribuição de energia elétrica atuais e futuros (FUCHS; MASOUM, 2015). A frequência nominal do sistema de distribuição brasileiro é de 60 Hz e a forma de onda da tensão deveria ser, idealmente, senoidal em corrente alternada (CA), dentro dos indicadores descritos no Prodist (ANEEL, 2021). Entretanto, quando uma tensão senoidal é aplicada a dispositivos e cargas não-lineares, o resultado é uma corrente que não é puramente senoidal (NASCIMENTO et al., 2017; DUGAN et al., 2012).

A QEE geralmente se refere à qualidade da tensão e/ou da corrente, e pode ser definida como a medida, análise e melhoria da tensão no barramento para manter a forma de onda

Tabela 1 – Categorias e características de fenômenos eletromagnéticos do sistema elétrico.

Categorias	Duração típica	Magnitude típica
<b>1. Transitório</b>		
1.1. Impulsivos		
1.1.1. Nanosegundos	<50 ns	-
1.1.2. Microsegundos	50 ns - 1 ms	-
1.1.3. Milisegundos	>1 ms	-
1.2. Oscilatórios		
1.2.1. Baixa frequência	0,3 - 50 ms	0 - 4 pu
1.2.2. Média frequência	20 $\mu$ s	0 - 8 pu
1.2.3. Alta frequência	5 $\mu$ s	0 - 4 pu
<b>2. Variação de curta duração</b>		
2.1. Instantânea		
2.1.1. Interrupção	0,5 - 30 ciclos	<0,1 pu
2.1.2. Afundamento	0,5 - 30 ciclos	0,1 - 0,9 pu
2.1.3. Surto	0,5 - 30 ciclos	1,1 - 1,8 pu
2.2 Momentânea		
2.2.1. Interrupção	30 ciclos - 3 s	<0,1 pu
2.2.2. Afundamento	30 ciclos - 3 s	0,1 - 0,9 pu
2.2.3. Surto	30 ciclos - 3 s	1,1 - 1,4 pu
2.3. Temporário		
2.3.1. Interrupção	3 s - 1 min	<0,1 pu
2.3.2. Afundamento	3 s - 1 min	0,1 - 0,9 pu
2.3.3. Surto	3 s - 1 min	1,1 - 1,2 pu
<b>3. Variação de longa duração</b>		
3.1. Interrupção	>1 min	0,0 pu
3.2. Subtensão	>1 min	0,8 - 0,9 pu
3.3. Sobretensão	>1 min	1,1 - 1,2 pu
<b>4. Desequilíbrio de tensão</b>	Regime permanente	0,5 - 2%
<b>5. Distorções na forma de onda</b>		
5.1. Offset CC	Regime permanente	0 - 0,1%
5.2. Harmônicos	Regime permanente	0 - 20%
5.3. Interharmônicos	Regime permanente	0 - 2%
5.4. Notching	Regime permanente	-
5.5. Ruído	Regime permanente	0 - 1%
<b>6. Flutuação de tensão</b>	Intermitente	0,1 - 7%
<b>7. Variações de frequência</b>	<10 s	

Fonte: Baseado na Tabela 2 da IEEE-1159 (IEEE, 2019).

senoidal na tensão e frequência nominais (TEODORESCU; LISERRE; RODRIGUEZ, 2011). Os indicadores de QEE da tensão e/ou corrente fornecidas às cargas são regulados por práticas e normas relacionadas à cintilação, frequência, harmônicos, fator de potência, entre outros. Alguns exemplos dessas práticas e normas são o PRODIST (ANEEL, 2021), a IEEE 519 (IEEE, 2014) e a IEC 61000-3-2 (IEC, 2018).

A Tabela 2 da IEEE 1159 (IEEE, 2019) define categorias e características de fenô-

menos eletromagnéticos, que foi traduzida do inglês e exposta neste trabalho por meio da Tabela 1. Essas categorias são: transitórios, variações de curta-duração, variações de longa-duração, desequilíbrios de tensão, distorções da forma de onda, flutuações de tensão, e variações de frequência (DUGAN et al., 2012). Os harmônicos estão classificados entre os fenômenos de distorção da forma de onda.

Harmônicos são tensões ou correntes com frequências múltiplas inteiras da frequência em que o sistema elétrico foi projetado para operar, chamada de frequência fundamental (DUGAN et al., 2012). Devido à impedância do sistema elétrico, qualquer corrente (ou tensão) harmônica resultará em geração e propagação de tensões (ou correntes) harmônicas geradas por cargas não-lineares em um sistema elétrico com cargas lineares (ARRILLAGA; WATSON, 2004; FUCHS; MASOUM, 2015).

De acordo com o PRODIST - Módulo 8 (ANEEL, 2021), o limite de DHT de tensão para tensões nominais iguais ou menores que 1,0 kV é de 10,0%, e para tensões entre 1,0 kV e 69 kV é de 8,0%. Já a IEEE 1547 (IEEE, 2018) e a IEC 61727 (IEC, 2004) limitam o DHT de corrente em 5% para harmônicos de ordem ímpar e em 1,25% para harmônicos de ordem par (TEODORESCU; LISERRE; RODRIGUEZ, 2011). A ANSI recomenda que a série de DHT seja truncada em 5 kHz, mas a maioria dos instrumentos comerciais disponíveis são limitados a uma frequência em torno de 1,6 kHz (FUCHS; MASOUM, 2015).

Diversas soluções para mitigação de componentes harmônicos, principalmente aquelas que utilizam elementos ativos, necessitam da determinação desses componentes. Um indicador de QEE pode ser construído com base no DHT da tensão ou das amplitudes dos harmônicos mais importantes (3<sup>o</sup>, 5<sup>o</sup>, 7<sup>o</sup>, 9<sup>o</sup> e 11<sup>o</sup>) (TEODORESCU; LISERRE; RODRIGUEZ, 2011). Para se obter os valores de amplitudes e ângulos de fase dos componentes harmônicos de uma forma de onda de tensão ou corrente, utiliza-se a determinação do conteúdo harmônico (ARRILLAGA; WATSON, 2004).

## 1.2 Determinação do Conteúdo Harmônico

A determinação do conteúdo harmônico é o processo de cálculo de magnitudes (amplitudes) e ângulos de fase do componente fundamental e dos componentes harmônicos de uma forma de onda periódica (ARRILLAGA; WATSON, 2004). O resultado é conhecido como série de Fourier e estabelece a relação entre uma função no domínio do tempo e a função no domínio da frequência (FUCHS; MASOUM, 2015). A série de Fourier é um caso especial da transformada de Fourier aplicada a um sinal periódico.

Na prática, as informações da forma de ondas são frequentemente obtidas em função do tempo amostral, sendo representada por uma série temporal de amplitudes, separada por intervalos fixos de tempo de duração limitada (ARRILLAGA; WATSON, 2004; FUCHS; MASOUM, 2015). Quando se trabalha com dados discretizados, utiliza-se a

transformada discreta de Fourier (DFT), do inglês *discrete Fourier transform* (ARRILLAGA; WATSON, 2004). A implementação da DFT por meio da chamada transformada rápida de Fourier (FFT), do inglês *fast Fourier transform* (ARRILLAGA; WATSON, 2004) forma a base da maioria dos sistemas espectrais modernos e dos sistemas de análise harmônica.

A DFT/FFT se popularizou devido a sua simplicidade e velocidade computacional. Entretanto, em muitos casos práticos, quando há presença de inter-harmônicos, desvio da frequência fundamental, presença de ruídos não múltiplos da frequência fundamental, sinais variantes no tempo, entre outros, o seu desempenho não atinge o nível de precisão desejado em algumas aplicações, principalmente relacionadas à eletrônica de potência (LIN, 2007; LIN, 2012; CHANG; CHEN, 2010; ZHU, 2007). Além disso, a IEEE 519-2014 (IEEE, 2014) estabelece que a largura da janela de medição de instrumentos digitais que utilizam a DFT/FFT deve ser de 12 ciclos (aproximadamente 200 ms) para sistemas com frequência de 60 Hz (FERREIRA et al., 2019; JAIN; SINGH, 2012).

Pode-se realizar a atenuação da distorção harmônica por meio de um FAP utilizando a DFT/FFT como método de extração dos componentes harmônicos de uma forma de onda distorcida em conjunto com um filtro passa-baixas para conservar o componente fundamental. Entretanto, por conta da complexidade do conjunto, a operação do filtro pode ocorrer de forma atrasada. Esse é um dos desafios da compensação harmônica em tempo-real.

Alguns métodos mais recentes, utilizando automação e inteligência artificial (IA), podem lidar de forma satisfatória com a identificação de harmônicos no sistema elétrico. Dentro das formas de automação do reconhecimento de distúrbios estão os modelos de DNN. Estas podem ser usadas no estágio de processamento para reconhecer padrões como harmônicos em redes e microrredes (ARRILLAGA; WATSON, 2004; FUCHS; MASOUM, 2015).

### 1.3 Estimativa Harmônica com Redes Neurais Profundas

Uma rede neural padrão é formada por vários processadores simples conectados entre si, chamados de neurônios, que 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. O aprendizado profundo, traduzido do inglês *deep learning*, se refere à classe de técnicas de aprendizado de máquina em que várias camadas, ou estágios, de processamento de informações são empregadas para a estimativa de valores ou classificação de padrões, por exemplo (JIA et al., 2016).

Uma rede neural formada por múltiplas camadas de processamento pode ser denominada DNN. As DNNs são empregadas em diversas de aplicações, desde carros autônomos (CHEN et al., 2015), até detecção de câncer (ESTEVA et al., 2017). O desempenho superior das DNNs, comparado às redes neurais padrão, vem de sua capacidade de extrair recursos de alto nível de dados sensoriais brutos após usar o aprendizado estatístico em uma grande quantidade de dados para obter uma representação eficaz de um espaço de entrada (SZE et al., 2017).

A precisão superior de DNNs, no entanto, vem ao custo de alta complexidade computacional (HINTON et al., 2012). Embora os mecanismos de computação de uso geral, especialmente as unidades de processamento gráfico (FAINGNAERT; BESARD; SUTTER, 2022), tenham sido a base para grande parte do processamento de DNNs, cada vez mais há interesse em fornecer aceleração mais especializada da computação de DNNs. Para reduzir o tempo do processo, o treinamento distribuído de DNNs, que utiliza simultaneamente vários nós de computação, é amplamente utilizado (GU et al., 2019). Outra alternativa é a utilização de um cluster de treinamento de DNNs usando um serviço de nuvem (OH; KIM; SEO, 2020).

Mesmo considerando o grande esforço computacional na etapa de treinamento do modelo de DNN, que utiliza um conjunto de dados relativamente grandes (por exemplo, 2,67 GB usados neste trabalho), a rede neural treinada requer um baixo esforço computacional em razão das operações matemáticas básicas (somas e multiplicações) realizadas pelo modelo resultante (por exemplo, 662 kB da DNN proposta neste trabalho). As DNNs podem ser usadas no estágio principal de processamento para reconhecer padrões (LECUN; BENGIO; HINTON, 2015). Esses modelos computacionais podem identificar harmônicos no lugar do conjunto de DFT e filtro passa-baixas a fim de melhorar a velocidade de processamento e facilitar a detecção de componentes harmônicos (TEMURTAS et al., 2004). Os trabalhos de Shi e Liu (2021) e Key et al. (2021), por exemplo, empregam técnicas de redes profundas na detecção de harmônicos e na compensação da corrente de saturação de transformadores, respectivamente.

Diante do contexto exposto, torna-se clara a importância, como tema de pesquisa, a estimativa seletiva do conteúdo harmônico por meio de DNNs, a qual é considerada uma contribuição em relação ao trabalho realizado por Nascimento (2007).

## 1.4 Objetivos

Este trabalho tem como objetivo principal a proposição de uma abordagem baseada em uma DNN para a estimativa de amplitudes e ângulos de fase de componentes harmônicos de corrente, de baixa frequência, mais especificamente os de 3<sup>a</sup>, 5<sup>a</sup>, 7<sup>a</sup> e 9<sup>a</sup> ordens.

Além do objetivo principal, os objetivos específicos são:

- ❑ Construir um conjunto de amostras de formas de onda sintéticas representativas de correntes presentes em ponto de conexão comum (PCC) de baixa tensão;
- ❑ Utilizar o conjunto de amostras para determinar uma arquitetura de DNN ótima;
- ❑ Comparar o modelo proposto com outros métodos de regressão comumente utilizados na literatura;
- ❑ Realizar testes de desempenho na estimativa de harmônicos utilizando correntes de cargas reais;
- ❑ Efetuar estudos de caso utilizando o modelo proposto como identificador de amplitudes e ângulos de fase para atenuação harmônica e consequente redução do DHT.

## 1.5 Justificativa

A identificação harmônica é de grande relevância em sistemas elétricos comerciais e industriais, sendo as perdas por efeito Joule uma das principais razões para a compensação desses componentes (NASCIMENTO et al., 2013).

Há vários métodos de identificação harmônica divulgados na literatura consultada (ALCARAZ et al., 2006; SUPRIYA; NAMBIAR, 2012; VERMA; GOSWAMI, 2021; SRIVASTAVA; TIWARI; SINGH, 2021). Alguns requerem um esforço computacional elevado (ARRILLAGA; WATSON, 2004), enquanto outros necessitam de uma amostra de tensão ou corrente com mais de um ciclo de onda (FERREIRA et al., 2019; JAIN; SINGH, 2012), o que gera maior tempo de resposta do algoritmo.

O método de estimativa harmônica proposto, que aplica o conceito de rede neural artificial (RNA) de aprendizado profundo (por exemplo, DNN), justifica-se pelo baixo esforço computacional na fase de operação e pelo baixo tempo de resposta, quando comparado a alguns métodos reconhecidos na literatura consultada (PEDREGOSA et al., 2011). A estimativa realizada valendo-se de um quarto de ciclo de uma forma de onda distorcida, com a possibilidade de se obter amplitudes e ângulos de fase de harmônicos individuais, é mais uma vantagem desse método. Quando empregado como gerador de referência para a corrente de compensação de um FAP, esse método pode apresentar uma vantagem em relação ao atraso de compensação inerente a outros métodos.

Uma metodologia para a definição da configuração final da DNN foi descrita. Foram descritos a geração de um conjunto de amostras para treinamento, validação e testes do modelo computacional; o processo de busca exaustiva de parâmetros para a escolha da quantidade de camadas neurais e neurônios; a comparação do método de estimativa harmônica proposto com outros métodos de regressão geralmente utilizados na literatura; os testes realizados para se verificar a capacidade de estimativa harmônica a partir de correntes de cargas experimentais e, por fim, a análise de desempenho da DNN ao fornecer

a referência para geração da corrente de compensação por um FAP ideal operando para atenuar a DHT de cargas experimentais.

## 1.6 Principais Contribuições

A principal contribuição deste trabalho é a proposta de uma ferramenta baseada em DNNs com baixo esforço computacional e período de amostragem reduzido para a estimativa de componentes harmônicos, incluindo as suas amplitudes e ângulos de fase.

Essa ferramenta poderá ser utilizada em aplicações de análise harmônica em redes e microrredes inteligentes, assim como em filtros ativos de potência, que necessitam dessas referências para atenuar componentes harmônicos presentes no PCC de redes elétricas.

Como contribuições secundárias, pode-se citar a descrição de uma metodologia de implementação de redes neurais profundas, iniciando pela criação de um conjunto de amostras de formas de onda para treinamento, passando pelo processo de busca por uma arquitetura otimizada e treinamento do modelo, e finalmente a realização de testes para avaliação de desempenho. Também foram realizadas comparações entre o modelo proposto e outros métodos de regressão frequentemente utilizados na literatura. Os estudos de caso demonstraram a capacidade de atenuação da DHT quando do uso da DNN proposta em conjunto com um FAP ideal.



---

## Capítulo 2

# Detecção do Conteúdo Harmônico

---

A forte tendência do aumento da poluição harmônica em redes elétricas tem atraído a atenção de engenheiros para desenvolver sistemas dinâmicos e soluções flexíveis para os problemas relacionados à QEE (BANA et al., 2019; SINGH; AL-HADDAD; CHANDRA, 1999).

Um dos requisitos presentes em normas de sistemas conectados à rede é a manutenção da DHT em níveis determinados. Esse indicador de QEE deve respeitar os limites determinados pelo PRODIST - Módulo 8 (ANEEL, 2021), no caso de instalações elétricas brasileiras. Sendo assim, é importante identificar/estimar componentes harmônicos para posterior atenuação. Uma das formas de promover a atenuação harmônica é por meio de FAPs que utilizam, por exemplo, a Teoria de Potência Ativa e Reativa Instantânea (Teoria p-q) (AKAGI; WATANABE; AREDES, 2007). Outras formas utilizam IA no reconhecimento de distúrbios por meio de análise de dados aplicada à eletrônica de potência.

Este capítulo traz os conceitos de harmônicos, expõe alguns métodos de identificação harmônica e mostra aplicações de DNNs em QEE.

### 2.1 Distorção Harmônica em Baixa Tensão

Harmônicos são tensões ou correntes senoidais cujas frequências são múltiplas inteiras da frequência fundamental (FUCHS; MASOUM, 2015). Os harmônicos podem se originar a partir da não-linearidade da magnetização de transformadores, de máquinas elétricas rotativas, da distorção provocada por dispositivos à arco elétrico, de retificadores monofásicos, de conversores fonte de corrente trifásicos, de conversores fonte de tensão trifásicos, de drives CA alimentados por inversor de frequência, de reatores controlados por tiris-

tores, de controles de fase modulada, de reguladores CA, entre outros (ARRILLAGA; WATSON, 2004).

Os principais efeitos provocados por harmônicos são mal funcionamento de dispositivos de controle, interferências telefônicas, perdas adicionais em linhas elétricas, redução da vida útil e aumento de perdas elétricas em equipamentos do sistema elétrico de potência e em equipamentos dos consumidores (FUCHS; MASOUM, 2015). As tensões e correntes harmônicas circulando no sistema elétrico também podem provocar ressonâncias, efeitos em máquinas rotativas, efeitos em usinas de eletricidade, interferências na proteção dos sistemas elétricos e ruídos em motores elétricos (ARRILLAGA; WATSON, 2004; RAY; RAY; DASH, 2022).

Os harmônicos são classificados como fenômenos relacionados à distorção da forma de onda de correntes ou tensões. Formas de onda periódicas distorcidas de tensão ou corrente podem ser decompostas em uma soma do componente fundamental e dos componentes harmônicos por meio de séries de Fourier, definida como

$$f(t) = F_{cc} + \sum_{n=1}^N F_n \cos(n\omega t + \phi_n) \quad (1)$$

em que  $F_{cc}$  é componente contínuo,  $F_n$  é o valor da amplitude do componente de ordem  $n$ ,  $N$  é a máxima ordem harmônica considerada,  $\phi_n$  é o ângulo de fase do componente de ordem  $n$ ,  $\omega$  é a velocidade angular fundamental e  $t$  é o tempo.

O componente contínuo  $F_{cc}$  em (1) pode ser expresso como

$$F_{cc} = \frac{1}{T} \int_0^T f(t) dt \quad (2)$$

em que o valor de  $F_{cc}$  é igual ao valor médio da função não senoidal no período  $T$  desde que todos os harmônicos sejam senoidais (ARRILLAGA; WATSON, 2004; DUGAN et al., 2012).

As correntes harmônicas instantâneas, por exemplo, podem ser expressas de acordo com

$$i(t) = I_{cc} + I_1 \cos(\omega t) + \sum_{n=2}^N I_n \cos(n\omega t + \phi_n) \quad (3)$$

em que  $I_{cc}$  é a componente contínua da corrente,  $I_1$  é a amplitude do componente fundamental,  $\omega$  é a velocidade angular fundamental,  $t$  é o instante de tempo considerado,  $N$  é a ordem harmônica máxima considerada,  $I_n$  é a amplitude do componente harmônico de ordem  $n$  e  $\phi_n$  é o ângulo de fase do componente harmônico de ordem  $n$ .

Uma das formas de quantificar o fenômeno harmônico é por meio do chamado monitoramento harmônico (ARRILLAGA; WATSON, 2004). Isso envolve capturar e processar sinais de tensão e corrente em vários pontos do sistema elétrico. Uma vez capturadas, essas informações são passadas ao sistema de monitoramento para o processo de apresentação de informações harmônicas e de tomada de decisão (KALAIR et al., 2017).

A partir da identificação dos componentes harmônicos, pode-se obter um número único para quantificação da distorção harmônica de correntes ou tensões. O índice mais utilizado para quantificação do conteúdo harmônico é a DHT (ARRILLAGA; WATSON, 2004), que pode ser definida, no caso de correntes harmônicas, como

$$\text{DHT} = \frac{\sqrt{\sum_{h=2}^H (I_{ef(h)})^2}}{I_{ef(1)}} \quad (4)$$

em que  $I_{ef(h)}$  é o valor eficaz do componente harmônico de  $h$ -ésima ordem,  $H$  é a máxima ordem harmônica considerada e  $I_{ef(1)}$  é o valor eficaz do componente fundamental de corrente.

Algumas normas e recomendações, como IEEE 1547 (IEEE, 2018), IEC 61727 (IEC, 2004), IEC 61000-3-2, (IEC, 2018) e PRODIST - Módulo 8 (ANEEL, 2021) determinam a limitação da circulação de harmônicos em redes elétricas e microrredes a fim de garantir que a distorção harmônica fique dentro de padrões estabelecidos. Para alcançar esse nível, pode ser necessário realizar a atenuação de harmônicos. Isso pode ser feito a partir das informações de amplitudes e ângulos de fase dos harmônicos.

Algumas das maneiras de compensação harmônica mais observadas na literatura consultada são as que utilizam filtros passivos (BAITHA; GUPTA, 2015), filtros amortecidos (DOVGUN; EGOROV; TEMERBAEV, 2020), filtros CC (LIU et al., 2020) ou filtros ativos (SINGH; AL-HADDAD; CHANDRA, 1999). Os filtros ativos, por exemplo, são projetados para atenuar harmônicos específicos e, geralmente, precisam de alguma forma de identificação instantânea destes componentes presentes no ponto de instalação. Essa identificação pode ser realizada com a utilização de métodos de identificação harmônica.

## 2.2 Métodos de Identificação Harmônica

Uma variedade de técnicas vêm sendo aplicadas para extrair o espectro de frequências de formas de onda de tensão ou corrente, como:

- ❑ Séries e coeficientes de Fourier;
- ❑ Simplificações resultantes de simetria da forma de onda;
- ❑ Forma complexa da série de Fourier;
- ❑ Convolução de fasores harmônicos;
- ❑ Transformada de Fourier;
- ❑ Funções temporais amostradas;
- ❑ Transformada discreta de Fourier;

- ❑ Frequência de Nyquist e Aliasing;
- ❑ Transformada rápida de Fourier;
- ❑ Funções de janela;
- ❑ Transformada Wavelet;
- ❑ Automação do reconhecimento de distúrbios (por exemplo, redes neurais artificiais).

Para aplicações digitais, nas quais o tempo é discretizado, o método da DFT/FFT é vastamente utilizado (ASIMINOAEI; BLAABJERG; HANSEN, 2007; ZHENG et al., 2012; XIA et al., 2017; SILVA; NASCIMENTO, 2018). Nesses casos, em que o espectro do domínio da frequência é uma função amostrada, assim como a função no domínio do tempo, obtém-se um par de transformadas de Fourier cujos componentes são discretos, tal que

$$\begin{cases} X(f_k) = 1/N \sum_{n=0}^{N-1} x(t_n) e^{-j2\pi kn/N} \\ x(t_n) = \sum_{k=0}^{N-1} X(f_k) e^{j2\pi kn/N} \end{cases} \quad (5)$$

em que  $N$  é o número de amostras por período,  $X(f_k)$  representa o componente da função no domínio da frequência,  $x(t_n)$  representa uma amostra da função no domínio do tempo. O elemento  $2n\pi/N$  representa uma rotação no sentido horário, tal que  $n = 0, 1, 2, \dots, (N - 1)$  (ARRILLAGA; WATSON, 2004).

Para um  $N$  elevado, as multiplicações envolvidas na DFT podem levar muito tempo e ter um alto custo computacional. A FFT surge como uma alternativa, visto que reduz consideravelmente o número de multiplicações para obter a solução (ARRILLAGA; WATSON, 2004). Na prática, um algoritmo matemático é usado para a solução da FFT.

O uso de técnicas de aprendizado de máquina era restrito, no início, devido a indisponibilidade de recursos computacionais capazes de processar a quantidade de informações necessárias. Mas, com a maior disponibilidade de recursos, é possível ampliar o uso de técnicas heurísticas que exigem muito esforço computacional, como RNA, no processamento de sinais de sistemas de potência (SHUKL; SINGH, 2020). Algumas propostas de automatização do processo de reconhecimento e identificação de distúrbios vêm sendo desenvolvidas na tentativa de melhorar a velocidade, a confiabilidade e a facilidade de obtenção e armazenamento de informações (ARRILLAGA; WATSON, 2004), conforme é exposto na seção seguinte.

## 2.3 Aplicação de Redes Neurais Artificiais

Há diversas pesquisas publicadas nos últimos anos que aplicam as técnicas de aprendizado de máquina, redes neurais artificiais e aprendizado profundo na identificação de

distúrbios relacionados à QEE.

Em Temurtas et al. (2004), Han et al. (2009), Dai, Venayagamoorthy e Harley (2009), Nguyen et al. (2011), Jain e Singh (2014), os autores expuseram abordagens de aplicação de DNNs para o processo de detecção harmônica com a geração da corrente de referência para um FAP. Os resultados de testes sustentam que os métodos são capazes de estimar precisamente harmônicos de baixa frequência. Em Ghazanfarpour et al. (2013), Ucar et al. (2019), foram aplicadas técnicas baseadas em aprendizado de máquina para aumentar a velocidade de detecção de eventos do sistema, como afundamentos de tensão, surtos de tensão, interrupções e harmônicos.

Em Abdeslam et al. (2006), os autores introduziram uma técnica de identificação e compensação harmônica. Nessa técnica, os componentes podem ser selecionados individualmente e a potência reativa também pode ser compensada. Em Temurtas e Temurtas (2011), Jain e Singh (2012), Jain e Singh (2013), Garanayak e Panda (2017), Žnidarec et al. (2019), os autores empregaram uma rede neural na identificação de amplitudes e ângulos de fase de sinais distorcidos. O algoritmo proposto alcançou maior acurácia, rapidez de convergência, estabilidade em regime permanente quando comparado a métodos convencionais, geralmente utilizados para identificar harmônicos.

Em Nascimento et al. (2011), Nascimento et al. (2013), as RNAs foram usadas para identificar correntes harmônicas de uma carga não-linear monofásica. O modelo foi capaz de estimar eficientemente os componentes presentes no sistema elétrico.

Em Flores-Garrido, Salmerón e Gómez-Galán (2021), uma RNA foi desenvolvida para estimar os coeficientes de Fourier correspondentes ao componente fundamental de formas de onda de tensão ou corrente. Já em Manito et al. (2018), os autores apresentaram um método para estimar os impactos causados na distorção harmônica de tensão pela presença de múltiplas cargas não-lineares em redes elétricas.

O trabalho de Xu et al. (2011) considerou uma solução a partir do uso de um método de controle baseado em RNAs para a situação de um conversor eletrônico de potência conectados a uma microrrede (MR) industrial. Em Puthenpurakel e Subadhra (2016), os autores detectaram, por meio de RNAs e transformada Wavelet, problemas de ilhamento e de QEE em um sistema híbrido de geração distribuída composto por sistemas fotovoltaica (PV) e eólicos conectados ao PCC.

Gong e Ruan (2020) apresentaram uma estrutura de rede neural profunda mirando em problemas de baixa velocidade de convergência, baixa acurácia e pouca habilidade de generalização de métodos tradicionais de identificação e classificação de distúrbios elétricos. Além disso, os autores desenvolveram um novo método de identificação de distúrbios específico para uma MR. Quando comparado a outros métodos geralmente utilizados para o mesmo fim, o proposto apresentou alta acurácia, maior velocidade de convergência e forte capacidade de generalização.

Em Kumar et al. (2018), os autores utilizaram um modelo baseado em RNAs para

realizar previsão de carregamento elétrico de sistemas. Já em Kumar e Bansal (2019), Kumar, Singh e Panigrahi (2019), Faria et al. (2019), Alsaidan et al. (2021) foram desenvolvidas estratégias de gerenciamento energético baseadas em RNAs para sistemas PV e apresentados os benefícios do seu uso.

O estudo realizado por Ciabattoni et al. (2020) tratou da inserção de IA no setor residencial e a possibilidade da implementação da flexibilidade pelo lado da demanda. As abordagens baseadas em IA, quando aplicadas a estimativa, previsão e agregação de padrões de consumo energético do consumidor, irão transformar as aplicações inteligentes e o modo de consumo. Concluiu-se que, em um curto período de tempo, os consumidores se tornarão mais ativos e suas ações terão maior impacto no setor energético.

No estudo realizado por Çetin, Dalcalı e Temurtaş (2020), os parâmetros do circuito equivalente de um motor de indução gaiola de esquilo foram estimados com sucesso por meio de uma rede neural retro-alimentada. De acordo com os resultados obtidos, a utilização de redes neurais retro-alimentadas para a previsão de parâmetros de circuito equivalente do motor de indução gaiola de esquilo é suficiente.

O uso de técnicas de aprendizado profundo e aprendizado de máquina mostra-se adequado em relação a identificação de distúrbios de QEE. É possível notar que esse tipo de solução oferece vantagens como baixo esforço computacional e simplificação do processo de identificação de harmônicos. No capítulo seguinte são abordados os conceitos de redes neurais artificiais assim como a sua implementação computacional.

---

## Capítulo 3

# Síntese de Redes Neurais Artificiais

---

Uma rede neural padrão é formada por várias unidades processadoras simples, conectadas entre si, chamadas de neurônios, que produzem uma sequência de ativações de valores reais (SCHMIDHUBER, 2015). Os neurônios de entrada são ativados por meio de suas conexões ponderadas com os neurônios ativados da camada anterior (SCHMIDHUBER, 2015). Essas conexões ponderadas são denominadas pesos sinápticos. Dependendo do caso, são necessários vários estágios de processamento para que ocorra a agregação de informação no modelo, no caso deste trabalho, as amplitudes e ângulos de fase esperados na saída da DNN. A principal vantagem do aprendizado profundo é que os valores internos da rede neural podem ser definidos automaticamente por meio de um procedimento de aprendizado de propósito geral, que agrega a informação com precisão em muitos estágios de processamento da rede neural (LECUN; BENGIO; HINTON, 2015).

### 3.1 Definições e Características Gerais

O aprendizado de máquina é um termo utilizado para se referir a qualquer tipo algoritmo e aos métodos que realizam tarefas que, tradicionalmente, necessitariam de inteligência humana (THEODORIDIS, 2020). O desenvolvimento de modelos que aplicam as técnicas de aprendizado de máquina processam, geralmente, um grande volume de dados e se adaptam a eles, fazendo previsões que podem embasar decisões (AGGARWAL, 2018). O aprendizado de DNNs por meio de dados proporciona estimativas precisas, fazendo com que essas redes neurais possam ser utilizadas em uma gama de aplicações (THEODORIDIS, 2020), como a classificação de distúrbios relacionados a QEE e a estimativa de amplitudes e ângulos de fase de harmônicos individuais.

As RNAs são baseadas em técnicas de aprendizado de máquina que simulam o me-

canismo de aprendizagem humano (PARK; LEK, 2016). O sistema nervoso humano é composto por células chamadas de neurônios. Estas células são conectadas entre si por meio dos axônios e dendritos, e a região de conexão entre eles é referida como sinapse. A força das conexões sinápticas muda constantemente, dependendo dos estímulos externos (AGGARWAL, 2018).

A habilidade de precisamente gerar funções valendo-se de dados desconhecidos a partir de um aprendizado por meio de dados finitos de entrada e saída é chamada de capacidade de generalização do modelo. A principal utilidade de todo modelo de aprendizado de máquina é a sua capacidade de generalização adquirida de dados conhecidos aplicada a exemplos desconhecidos (AGGARWAL, 2018).

A capacidade de aprendizagem das RNAs pode ser aumentada quando as unidades neurais elementares são combinadas e os pesos sinápticos são treinados usando a dependência mútua entre eles. Quando essa combinação ocorre, o poder de aprendizagem de o modelo aprender funções complicadas a partir de dados aumenta em relação aos modelos puramente elementares (TANG; DENG; HUANG, 2016). Esse método de combinação de múltiplas unidades, com diversas camadas de processamento, é chamado de aprendizagem profunda, que são utilizados, por exemplo, para identificar objetos em imagens, transcrever falas para textos, e recomendar produtos a clientes (LECUN; BENGIO; HINTON, 2015).

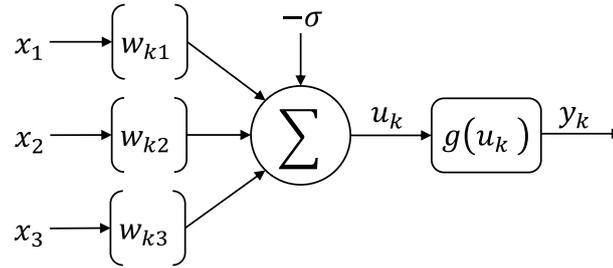
As técnicas de aprendizagem profunda permitem que os modelos digitais compostos por múltiplas camadas de processamento extraiam características dos dados em múltiplos níveis de abstração (LECUN; BENGIO; HINTON, 2015). O processo de aprendizagem é composto por uma série de métodos que permitem que o modelo seja alimentado com informações não tratadas e automaticamente realize a inferência necessária para a identificação ou classificação (LECUN; BENGIO; HINTON, 2015).

Todo o modelo de rede neural é simulado por meio de unidades computacionais, também chamadas de neurônios. Essas unidades são conectadas entre si por meio de pesos sinápticos, que cumprem o mesmo papel da sinapse biológica (SCHMIDHUBER, 2015; LECUN; BENGIO; HINTON, 2015; AGGARWAL, 2018), ou seja, os pesos mudam de valor constantemente durante o processo de aprendizagem para se adaptarem aos dados. Cada entrada do neurônio é submetida a um peso, o que afeta o resultado da função daquele neurônio.

### 3.1.1 Neurônio Artificial

Os neurônios artificiais (Figura 1) empregados nas RNAs são não-lineares, geram saídas ( $y$ ) contínuas e realizam funções simples como agregar os sinais presentes nas suas entradas ( $x$ ) e gerar uma saída que varia de acordo com a função de ativação utilizada ( $g(u)$ ) (SILVA; SPATTI; FLAUZINO, 2019).

Figura 1 – Neurônio Artificial.



Fonte: Autor.

O funcionamento do neurônio artificial é regido matematicamente por

$$\begin{cases} u = \sum_{i=1}^n w_i \cdot x_i - \sigma \\ y = g(u) \end{cases} \quad (6)$$

em que  $u$  é o resultado do somatório das multiplicações entre as entradas  $x$  e os respectivos pesos sinápticos  $w$ , combinados com o limite de ativação  $\sigma$ . O valor  $u$  é submetido à função de ativação  $g(\cdot)$ , gerando a saída  $y$ . A função de ativação é utilizada para limitar a amplitude da saída do neurônio (HAYKIN, 2009).

### 3.1.2 Funções de Ativação

Segundo Braga, Carvalho e Ludemir (2007), as funções de ativação permitem a produção de uma saída qualquer, não necessariamente zero ou um. Elas limitam a amplitude da saída de um neurônio a uma faixa permissível do sinal de saída para algum valor finito (HAYKIN, 2009). Algumas das funções de ativação mais utilizadas na literatura consultada são a unidade linear retificada (ReLU), a sigmoide, a tangente hiperbólica, e a softmax (CHOLLET, 2017). Quando não se deseja restringir a saída de uma unidade neural, pode-se optar pela função de ativação linear, que é definida como

$$y = x \quad (7)$$

em que o valor da saída ( $y$ ) é igual ao valor da entrada ( $x$ ). A função linear é geralmente aplicada na camada de saída de RNAs que realizam regressão para valores arbitrários, conforme ilustra a Tabela 2.

A função de ativação ReLU, também chamada de retificadora, retorna o maior valor entre zero e o valor da entrada (Figura 2). Seu comportamento é descrito por (8). Essa função tem substituído a sigmoide e a tangente hiperbólica em redes neurais modernas devido à facilidade em treinar redes neurais multicamadas (AGGARWAL, 2018).

$$y = \begin{cases} 0, & \text{para } x < 0; \\ u, & \text{para } x \geq 0. \end{cases} \quad (8)$$

Figura 2 – Função de Ativação ReLU.



Fonte: Autor.

Chollet (2017) faz sugestões de funções de ativação para alguns tipo de problema, as quais podem ser observadas na Tabela 2.

Tabela 2 – Função de ativação recomendada por tipo de problema.

Tipo de problema	Ativação
Classificação binária	Sigmoide
Classificação multi classe, rótulo único	Softmax
Classificação multi classe, rótulos múltiplos	Sigmoide
Regressão para valores arbitrários	Linear
Regressão para valores entre 0 e 1	Sigmoide

Fonte: baseado em Chollet (2017).

Tendo concluído a conceituação das principais características do neurônio artificial, passar-se-á ao conceito de arquitetura de RNAs.

### 3.1.3 Arquiteturas de Redes Neurais Artificiais

Segundo Haykin (2009), a arquitetura das RNAs é a forma como os neurônios estão dispostos dentro do modelo. Essa análise é feita por meio do direcionamento das conexões sináptica destes. Silva, Spatti e Flauzino (2019) explicam que a topologia da RNA é definida como as diversas composições estruturais que se pode ter. Ou seja, esta se refere, por exemplo, à quantidade de neurônios e camadas e à função de ativação aplicada, enquanto aquela se refere ao modo com que essas estruturas são organizadas dentro do modelo.

O conjunto de neurônios que recebe a mesma informação em determinado instante é denominado camada. Adotando a nomenclatura de Silva, Spatti e Flauzino (2019), as camadas podem ser definidas como:

1. Camada de entrada: responsável pelo recebimento das informações do meio externo;

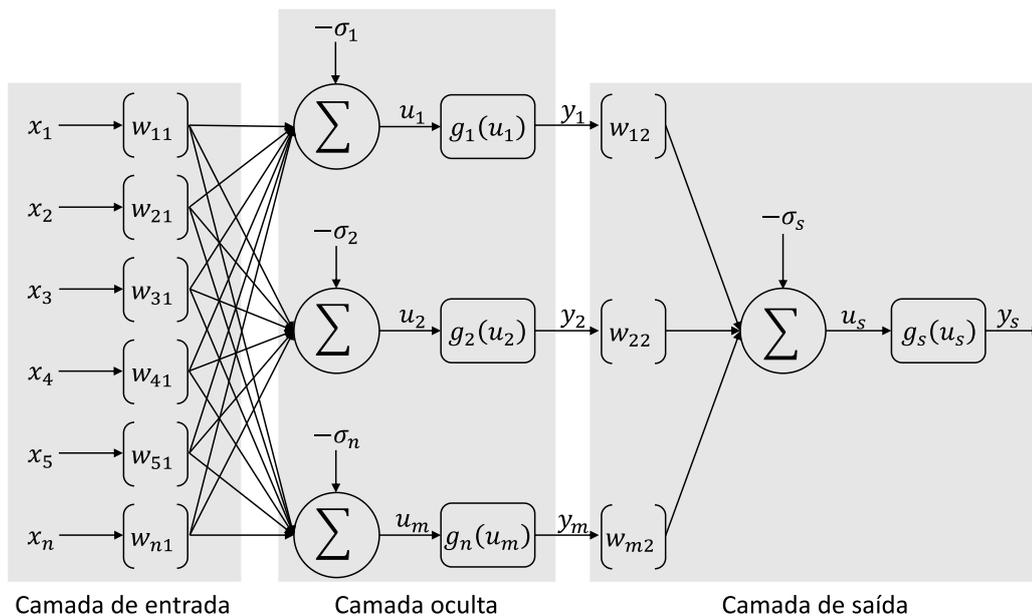
2. Camadas escondidas, intermediárias, ocultas ou invisíveis: onde se localizam os neurônios responsáveis por quase todo o processamento interno. A função é de extrair as características associadas às informações de entrada;
3. Camada de saída: é incumbida de produzir e apresentar os resultados da RNA.

A forma mais simples de uma rede em camadas é aquela em que a camada de entrada projeta diretamente os dados amostrais na camada de saída, mas não ocorre o contrário (HAYKIN, 2009). Essa arquitetura é chamada de camada simples devido ao fato de que a camada de entrada não é contada por não realizar processamento algum.

O conceito de aprendizagem profunda permite que os modelos sejam compostos por múltiplas camadas para aprendizagem dos padrões representativos contidos nos dados. Uma rede que apresente mais de uma camada escondida é chamada de rede neural profunda. Nessa arquitetura, os neurônios das camadas escondidas estão totalmente conectados à camada de entrada e a camada de saída está totalmente conectada à camada escondida, respectivamente.

Nas RNAs de camadas múltiplas (Figura 3), os neurônios são organizados em camadas, de forma que a camada de entrada e a camada de saída sejam separadas por uma ou mais camadas escondidas (AGGARWAL, 2018). Segundo Arrillaga e Watson (2004), o tipo de RNA mais utilizado no reconhecimento de padrões é o *perceptron* de múltiplas camadas (PMC). Esses modelos geralmente são treinadas por meio da técnica de retropropagação do erro (HAGAN; MENHAJ, 1994; HAYKIN, 2009).

Figura 3 – Exemplo de arquitetura de múltiplas camadas com uma camada oculta.



Fonte: Autor.

A técnica mais conhecida para definição dos hiper parâmetros (quantidade de camadas e quantidade de neurônios, por exemplo) é a busca em grade (AGGARWAL, 2018). Ela

realiza um processo exaustivo de treinamento e avaliação de modelos com hiper parâmetros pré-definidos, no qual todas as possibilidades configuradas são testadas para a escolha de uma DNN otimizada, que, no caso de regressão, gere o menor erro absoluto médio (MAE), do inglês *mean absolute error* (AGGARWAL, 2018).

O aprendizado de padrões e a capacidade de generalização das DNNs são adquiridos durante o processo de treinamento do modelo, que é detalhado na próxima seção.

### 3.1.4 Treinamento e Aprendizado de Máquina

Treinamento é o processo de ajuste dos pesos sinápticos. Esse ajuste é realizado por meio da verificação de convergência das saídas do modelo em relação aos rótulos esperados quando amostras de treinamento são submetidas às entradas da DNN (PAL; MITRA, 1992).

Os estímulos externos, ou dados (amostras) de treinamento, são frequentemente organizados em pares. Os dados de entrada, que representam as características dos estímulos externos, têm como par um rótulo correspondente de saída. O processo de treinamento pode ser realizado tanto com informações sintéticas (TREMBLAY et al., 2018) quanto com dados reais.

O treinamento supervisionado relaciona o conjunto de entradas com as respectivas saídas. Para isso, é necessária uma tabela de dados que contenham as informações de entradas e saídas representativas do sistema. Os pesos sinápticos são ajustados continuamente até que a diferença entre a saída obtida e a saída desejada seja aceitável, conforme a exigência da aplicação.

O conjunto de etapas para realização do treinamento de redes neurais é chamado de algoritmo de aprendizagem (ALANIS, 2019). O algoritmo de aprendizagem utiliza amostras de dados do sistema para atingir seu objetivo. Para isso, pode-se dividir as amostras em três conjuntos: treinamento, validação e teste (CHOLLET, 2017). O conjunto de treinamento é utilizado para o aprendizado do modelo, ou seja, para ajuste dos pesos sinápticos. Já o conjunto de validação é utilizado durante o processo de treinamento para avaliar o modelo. Quando o processo de treinamento estiver finalizado, utiliza-se o conjunto de testes é utilizado para verificar a capacidade de generalização da DNN e se essa capacidade está em níveis considerados aceitáveis (THEODORIDIS, 2020).

Segundo Chollet (2017), a razão para se ter o conjunto de testes juntamente com o conjunto de validação é que o desenvolvimento de redes neurais envolve o ajuste da sua topologia, por exemplo, determinando a quantidade de neurônios e camadas. Esse ajuste é feito com base na resposta da rede frente ao conjunto de validação, o que torna a análise mais rápida e eficiente, visto que este conjunto é utilizado ainda na etapa de treinamento.

Durante a execução do algoritmo de aprendizagem, as amostras, principalmente do subconjunto de treinamento, são apresentadas ao modelo. Cada apresentação completa dessas amostras é denominado época de treinamento (SILVA; SPATTI; FLAUZINO, 2019).

Basicamente, esse método consiste em se apresentar previamente as amostras de entrada e respectivas saídas à DNN e esta, após o treinamento, se torna capaz de inferir as saídas (AGGARWAL, 2018).

Uma das possibilidades de implementação computacional de redes neurais é por meio de Python (BEAZLEY, 2009). O desenvolvimento desses modelos utilizando a referida linguagem de programação é abordado na próxima seção.

## 3.2 Implementação de RNAs em Python

A partir do lançamento de estruturas como o TensorFlow (ABADI et al., 2016) e o Keras (CHOLLET et al., 2015), que simplificaram significativamente a implementação de modelos de DNNs, a linguagem de programação Python (BEAZLEY, 2009) se tornou uma das principais para a realização pesquisas em aprendizado profundo (CHOLLET, 2017).

### 3.2.1 Pacotes e Bibliotecas para RNAs em Python

O Python (PYTHON, 2021) é uma linguagem de programação orientada a objetos, interpretada e interativa que possui módulos, classes, exceções, tipos de dados dinâmicos de nível muito alto e tipagem dinâmica (BEAZLEY, 2009). Existem interfaces para muitas chamadas de sistema e bibliotecas como Numpy (HARRIS et al., 2020), TensorFlow e Keras.

O NumPy (NUMPY, 2022) é um pacote fundamental para aplicações computacionais científicas em Python. Essa é uma biblioteca que oferece objetos do tipo vetor multi-dimensional e vários outros derivados deste, como matrizes (HARRIS et al., 2020). A biblioteca proporciona maior agilidade em operações matemáticas e lógicas, na manipulação de dimensão dos objetos, na aplicação da Transformada de Fourier, e é de extrema importância quando da aplicação em DNNs (HARRIS et al., 2020).

Segundo Abadi et al. (2016), o TensorFlow é uma plataforma de código aberto para aprendizagem de máquina. Possui ferramentas, bibliotecas e recursos que permitem a pesquisa, criação e implementação de aplicativos com a tecnologia de aprendizado de máquina.

A biblioteca Keras (KERAS, 2021) é uma interface de programação de aplicações (API), do inglês *application programming interface*, de alto nível para redes neurais escrita em Python e que opera na plataforma TensorFlow 2. É um ambiente acessível e altamente produtivo para aprendizado de máquina, com foco em aprendizado profundo (CHOLLET et al., 2015). O Keras pode manipular modelos com topologia não-linear, camadas compartilhadas e com várias entradas ou saídas (CHOLLET et al., 2015). A classe *Model* oferece um processo de treinamento integrado, chamado *fit*, e um processo

de avaliação, chamado *evaluate*. É possível ajustar as rotinas de treinamento e os métodos de aprendizado e avaliação dentro dessa classe (CHOLLET et al., 2015).

### 3.2.2 A Interface Keras na Implementação de RNAs em Python

O Keras foi desenvolvido com foco em proporcionar uma experimentação rápida. Isso permite que vários testes sejam realizados com DNNs de forma ágil e flexível (KERAS, 2021).

#### 3.2.2.1 Métodos e Classes

A classe *Model* agrupa as camadas em um objeto com atributos de treinamento e inferência. Os argumentos desse objeto são as entradas do modelo, as saídas e o nome.

A classe *Sequential* agrupa um conjunto de camadas linearmente distribuídas em um objeto do tipo *Model*.

O método *compile* configura o modelo para treinamento. Seus argumentos são:

- ❑ *optimizer*: recebe o nome do otimizador utilizado no modelo;
- ❑ *loss*: recebe o nome da função para calcular as perdas no modelo. Essa função retorna um valor correspondente à perda ponderada. A perda a ser minimizada pelo modelo é a soma de todas as perdas individuais;
- ❑ *metrics*: recebe o nome da métrica a ser avaliadas pelo modelo durante o treinamento e teste;
- ❑ *loss\_weights*: opcional, recebe uma lista ou um dicionário de valores para pesos e perdas de diferentes saídas do modelo;
- ❑ *weighted\_metrics*: lista de métricas a serem avaliadas e ponderadas durante o treinamento e teste;
- ❑ *run\_eagerly*: recebe um valor booleano. O padrão deste atributo é FALSO. Se for atribuído um valor VERDADEIRO, a lógica do modelo não é envolvida na função de ativação;
- ❑ *steps\_per\_execution*: recebe um valor inteiro que por padrão é 1. É o número de lotes (*batches*) para processar em cada época de treinamento.

O método *fit* ajusta o modelo por meio do conjunto de amostras e dos rótulos equivalentes durante uma quantidade de épocas definidas previamente. Seus argumentos são:

- ❑ *x*: dados amostrais de entrada;
- ❑ *y*: rótulos dos dados amostrais;

- ❑ *batch\_size*: recebe valores inteiros ou nulo referente ao número de amostras aplicadas ao modelo por atualização do gradiente. Por padrão, esse argumento recebe o valor 32;
- ❑ *epochs*: recebe um número inteiro de épocas de treinamento do modelo;
- ❑ *verbose*: recebe os valores 0, 1 ou 2. É a prolixidade do treinamento (0 equivale ao modo silencioso, ou seja, durante o treinamento não há retorno; 1 equivale ao modo com barra de progresso retornada durante o treinamento; 2 equivale ao modo com retorno de uma linha de informações por época de treinamento);
- ❑ *callbacks*: É utilizado para realizar ações específicas durante o treinamento do modelo;
- ❑ *validation\_split*: recebe um valor real entre 0 e 1. É a fração do conjunto de amostras de treinamento que é destinada ao conjunto de validação. Esse atributo separa uma quantidade de amostras que não são usadas para treinar o modelo, mas para avaliar a perda deste baseada nas métricas definidas, no final de cada época;
- ❑ *validation\_data*: recebe o conjunto de amostras de validação;
- ❑ *shuffle*: recebe um valor booleano. É utilizado para embaralhar as amostras do conjunto de treinamento;
- ❑ *class\_weight*: opcional. Utilizado para ponderar a função de perda durante o treinamento;
- ❑ *sample\_weight*: opcional. Matriz do NumPy contendo pesos sinápticos para as amostras de treinamento, usado para ponderar a função de perda durante o treinamento;
- ❑ *initial\_epoch*: recebe um valor inteiro. Época em que se pretende iniciar o treinamento;
- ❑ *steps\_per\_epoch*: recebe um valor inteiro ou nulo. Número total de passos (lotes de amostras) para se declarar uma época finalizada e iniciar a próxima época;
- ❑ *validation\_steps*: Número total de passos executados antes de executar a avaliação no final de cada época de treinamento;
- ❑ *validation\_batch\_size*: recebe um valor inteiro ou nulo. Número de amostras por validação do lote (*batch*);
- ❑ *validation\_freq*: especifica quantas épocas de treinamento executar antes de uma validação do modelo;

- ❑ *max\_queue\_size*: recebe um inteiro. É o valor máximo da fila na entrada do modelo;
- ❑ *workers*: recebe um inteiro. Número máximo de processos executados quando se adota processos baseados em execução simultânea;
- ❑ *use\_multiprocessing*: recebe um booleano. Utilizado para configurar o modo de processamento simultâneo de entradas.

O método *evaluate* retorna o valor da perda e os valores de métricas para o modelo no modo de teste. Os argumentos *x*, *y*, *batch\_size*, *verbose*, *sample\_weights*, *callbacks*, *workers*, *use\_multiprocessing*, e *max\_queue\_size* são semelhantes ao método *fit*. Além desses atributos, há também os seguintes:

- ❑ *steps*: recebe valores inteiros ou nulo. Número total de passos para se declarar o processo de avaliação finalizado;
- ❑ *return\_dict*: Se receber o valor verdadeiro (*True*), os resultados de perda e métricas são retornados em formato de dicionário. Se receber o valor falso (*False*), os valores são retornados em formato de lista.

O método *predict* aplica as amostras na entrada do modelo treinado e gera as respectivas saídas. Os argumentos *x*, *batch\_size*, *verbose*, *callbacks*, *max\_queue\_size*, *workers*, *use\_multiprocessing* são semelhantes ao método *fit*. O argumento *steps* é semelhante ao do método *evaluate*.

### 3.2.2.2 Camadas Neurais

A estrutura de dados fundamental em uma RNA é a camada neural, que é um módulo de processamento de dados que recebe uma entrada e gera uma saída. Os pesos sinápticos das camadas neurais são ajustados de tal forma que a RNA armazene o conhecimento a partir das informações de entradas e saídas.

As camadas centrais (*Core Layers*) possuem as seguintes características:

- ❑ Função *Input*: essa função é utilizada para configurar as entradas do modelo. Os argumentos são:
  - *shape*: recebe a dimensão do vetor utilizado como entrada do modelo;
  - *batch\_size*: tamanho do lote de amostras;
  - *name*: nome da camada (opcional);
  - *dtype*: tipo de dado a ser utilizado como entrada do modelo;
  - *sparse*: booleado que determina se o marcador a ser criado é do tipo esparsos;
  - *tensor*: tensor previamente existente para envolver a camada de entrada;

– *ragged*: booleado que determina se o marcador a ser criado é do tipo irregular.

- Classe *Dense*: cria uma camada neural densamente conectada, ou seja, todas as saídas da camada anterior são consideradas entradas da camada criada utilizando *Dense*. Esta classe implementa a operação

$$y = g((w \cdot x) + bias) \quad (9)$$

em que  $y$  é a saída do neurônio,  $x$  é o valor de entrada,  $w$  é o peso sináptico,  $g(\cdot)$  é a função de ativação, e  $bias$  é um vetor de tendências criado pela camada neural.

- Classe *Activation*: aplica uma função de ativação em uma saída. O único argumento dessa classe é o *activation*, que recebe o nome da função de ativação a ser utilizado.

No Keras, a camada convolucional de uma dimensão é denominada *Conv1D Layer*. Essa camada cria um núcleo de convolução que é convolvido com a camada de entrada sobre uma única dimensão temporal para produzir um tensor de saídas. Se houver função de ativação, ela será aplicada às saídas (CHOLLET et al., 2015).

Ela recebe vetores tridimensionais na forma (amostras, tempo, características) e também retorna vetores tridimensionais com a mesma forma (CHOLLET et al., 2015). Os argumentos principais dessa camada são:

- *filters*: dimensão do espaço de saída, ou seja, o número de filtros de saída da convolução;
- *kernel\_size*: tamanho da janela unidimensional de convolução;
- *strides*: tamanho do passo de convolução;
- *padding*: útil quando se está modelando dados temporais em que o modelo não deve violar a ordem temporal;
- *activation*: função de ativação escolhida.

### 3.2.2.3 Otimizadores

O otimizador é o mecanismo pelo qual a RNA atualizará seus próprios parâmetros internos baseando-se nos dados de entrada e não função de perda. Utiliza-se otimizadores em conjunto com os métodos *compile* e *fit*. O otimizador é um dos dois argumentos necessários para se compilar o modelo de RNA. Alguns otimizadores disponíveis no Keras são Adam (KINGMA; BA, 2014) e Adamax.

O Adam é um método de descida do gradiente estocástica baseado em estimativa adaptativa dos momentos de primeira e segunda ordem (KINGMA; BA, 2014). Esse método proporciona eficiência computacional, necessita de poucos requisitos de memória

e é adequado para problemas com grandes quantidades de dados e parâmetros (KINGMA; BA, 2014; CHOLLET et al., 2015).

O Adamax é uma variante do algoritmo Adam baseada na norma do supremo (CHOLLET et al., 2015). Em algumas aplicações, o Adamax apresenta melhores resultados em comparação com o Adam, especialmente em modelos com *embeddings*, que são vetores de alta dimensão em um espaço de baixa dimensão (KINGMA; BA, 2014; CHOLLET et al., 2015).

#### 3.2.2.4 Métricas e Funções de Perda

Métricas são funções empregadas para avaliar o desempenho do modelo. Estas são parecidas com as funções de perda, mas os seus resultados não são utilizados no processo de treinamento (CHOLLET et al., 2015; CHOLLET, 2017). Qualquer função de perda pode ser utilizada como métrica. No ambiente Keras existem métricas de precisão, de probabilidade, de regressão, dentre outras.

Um exemplo de métrica de precisão é a acurácia (*Accuracy*), que calcula a frequência em que as previsões equivalem aos objetivos de saída. Ela retorna a frequência com que as saídas do modelo correspondem às saídas verdadeiras.

Alguns exemplos de métricas probabilísticas (KERAS, 2021) são:

- ❑ *Categorical Crossentropy*: calcula a entropia cruzada entre os objetivos de saída e as previsões. É utilizada quando há diversas classes de objetivos e estes são representados números inteiros na saída do modelo;
- ❑ *Sparse Categorical Crossentropy*: calcula a entropia cruzada entre os objetivos de saída e as previsões. É utilizada quando as categorias de saída são representadas por valores reais (pontos flutuantes);
- ❑ *KL Divergence*: calcula a divergência pelo método de Kullback-Leibler (CHOLLET et al., 2015; KERAS, 2021);
- ❑ *Poisson*: calcula a diferença entre a saída verdadeira e a saída do modelo por meio de  $y_{modelo} - y_{verdadeiro} \cdot \log(y_{modelo})$ .

Algumas métricas de regressão disponíveis no Keras (KERAS, 2021) são:

- ❑ *Mean Squared Error*: calcula o erro quadrático médio entre a saída verdadeira e a saída prevista pelo modelo;
- ❑ *Root Mean Squared Error*: calcula a raiz quadrada do erro quadrado médio entre a saída verdadeira e a saída prevista pelo modelo;
- ❑ *Mean Absolute Error*: calcula o erro absoluto médio entre os objetivos de saída e as predições do modelo;

- ❑ *Mean Absolute Percentage Error*: calcula o erro percentual absoluto médio entre a saída verdadeira e a previsão do modelo;
- ❑ *Mean Squared Logarithmic Error*: calcula o erro logarítmico quadrático médio entre a saída verdadeira e a saída prevista pelo modelo.

As funções de perda são funções utilizadas para quantificar o desempenho da RNA durante o processo de treinamento e indicam a direção certa para a atualização dos seus parâmetros internos (CHOLLET, 2017). As funções de perda são mesmas funções aplicadas em métricas.

### 3.3 Aprendizado Profundo com Python

Conforme a Seção 2.3, algoritmos de RNAs são amplamente desenvolvidos em aplicações de indicadores de QEE. O Python é uma das linguagens mais populares da ciência de dados e é amplamente utilizado em pesquisas relacionadas a aprendizado profundo (CHOLLET, 2017). A biblioteca Keras (KERAS, 2021) é geralmente utilizada nas aplicações de aprendizado profundo devido a flexibilidade proporcionada e ao suporte do Python (CHOLLET, 2017).

O aprendizado profundo conta com três propriedades principais: simplicidade, escalabilidade e versatilidade. A simplicidade está relacionada ao uso de modelos simples e treináveis de ponta a ponta. A escalabilidade se refere a capacidade de paralelização entre unidades computacionais processadoras. A versatilidade se refere a capacidade dos modelos de aprendizado profundo poderem ser treinados em dados adicionais sem reiniciar do zero, tornando-os viáveis para aprendizado on-line (CHOLLET, 2017).

O próximo Capítulo demonstrará a implementação de RNAs de aprendizado profundo, em que o algoritmo foi escrito em Python 3.8 aplicando a biblioteca Keras, na estimativa do conteúdo harmônico referente aos componentes de 3<sup>a</sup>, 5<sup>a</sup>, 7<sup>a</sup> e 9<sup>a</sup> ordens.



---

## Capítulo 4

# Estimativa do Conteúdo Harmônico

---

Segundo Silva, Spatti e Flauzino (2019), a avaliação da QEE foi significativamente melhorada após o emprego de sistemas inteligentes. Araújo (2017) afirma que as DNNs têm a capacidade de reter informações, identificar e classificar padrões, e realizar previsões. Sabendo que a identificação de harmônicos requer a extração das características e peculiaridades do sinal elétrico, torna-se conveniente a utilização de DNNs para este fim, assim como mostram os trabalhos realizados, por exemplo, por Lima (2013), Andrade (2017), Gelves (2017).

Este Capítulo aborda o desenvolvimento de amostras de treinamento, validação e teste, assim como a metodologia de implementação da DNN proposta. Além disso, comparações entre o modelo proposto e outros regressores consolidados na literatura foram realizadas. A linguagem de programação utilizada para obtenção das informações contidas neste Capítulo é a Python 3.8, por meio do ambiente de desenvolvimento JupyterLab 3.0.14 (KLUYVER et al., 2016).

### 4.1 Amostras para Treinamento, Validação e Testes

Conforme o exposto no Capítulo 3, o treinamento das DNNs é realizado a partir de amostras representativas do sistema que se pretende modelar. Sendo assim, deve-se obter o conjunto de amostras contendo formas de onda de correntes distorcidas por harmônicos.

O objetivo definido é estimar (GRUS, 2016) amplitudes e ângulos de fase dos componentes harmônicos de ordem 3, 5, 7 e 9. As entradas do modelo computacional são alimentadas com formas de onda de um quarto de ciclo, no domínio do tempo. As correntes harmônicas individuais são geradas e somadas para formar a amostra de corrente,

tal que

$$\begin{cases} i_1(t) = I_1 \cos(\omega t + \phi_1) \\ i_3(t) = I_3 \cos(3\omega t + \phi_3) \\ i_5(t) = I_5 \cos(5\omega t + \phi_5) \\ i_7(t) = I_7 \cos(7\omega t + \phi_7) \\ i_9(t) = I_9 \cos(9\omega t + \phi_9) \end{cases} \quad (10)$$

$$i(t) = i_1(t) + i_3(t) + i_5(t) + i_7(t) + i_9(t) \quad (11)$$

em que  $i_n(t)$  é a corrente de ordem harmônica  $n$  no domínio do tempo,  $I_n$  é a amplitude máxima da corrente harmônica de ordem  $n$  em pu,  $\phi_n$  é o ângulo de fase em radianos,  $\omega$  é a velocidade angular em radianos por segundo, e  $t$  é o tempo em segundos.

O alcance das amplitudes e dos ângulos de fase (Tabela 3) utilizados no conjunto de amostras foi definido com base na metodologia descrita em Temurtas et al. (2004) e nas correntes de carga descritas em Fuchs, Masoum e Ladjevardi (2005), Dugan et al. (2012), Michalec et al. (2021). Apesar de o objetivo da DNN ser estimar os harmônicos de ordens 3, 5, 7 e 9, incluiu-se amostras os demais harmônicos ímpares e os pares até a 13ª ordem para que estas fossem mais representativas das correntes de carga observadas na literatura.

Deve-se evitar a presença de formas de onda iguais no conjunto de amostras para que o desempenho do processo de treinamento seja otimizado (GUPTA et al., 2022). Consequentemente, quando a amplitude dos harmônicos gerados é 0,00 pu, somente o ângulo de fase 0,0000 rad é utilizado, ignorando-se os demais. Destaca-se que o tamanho do conjunto de amostras foi limitado pela capacidade de armazenamento da RAM (16 GB) e pela capacidade de processamento da CPU (Intel(R) Core(TM) i7-10750H) do computador usado neste trabalho. Entretanto, seria possível, teoricamente, sintetizar um conjunto de amostras com uma variação maior de amplitudes e ângulos de fase.

A quantidade de formas de onda contidas no conjunto de amostras é calculada por meio da combinação do número de possibilidades de amplitudes e ângulos de fase de cada harmônico e pela quantidade de posições amostrais contidas na forma de onda de um quarto de ciclo. A dimensão total do conjunto de amostras é de 10.692.864 formas de onda de um quarto de ciclo, armazenadas em vetores de 64 posições cada.

O número de posições amostrais de uma forma de onda, ou o número de posições de um vetor de amostra, é definido pela taxa de amostragem. De acordo com o Guia de Implementação de Interface Digital para Instrumentos de Transformação usando a IEC 61850-9-2 (UCA, 2004), a taxa de amostragem recomendada para uma tensão com frequência fundamental de 60 Hz é de 15,36 kHz, o que resulta em um sinal discretizado em 256 amostragens por ciclo de onda e, consequentemente, em um vetor de 64 amostragens por quarto de ciclo. Sendo assim, cada amostra do conjunto é armazenada em um vetor de 64 posições.

Tabela 3 – Amplitudes e ângulos de fase dos harmônicos presentes no conjunto de amostras de treinamento e validação.

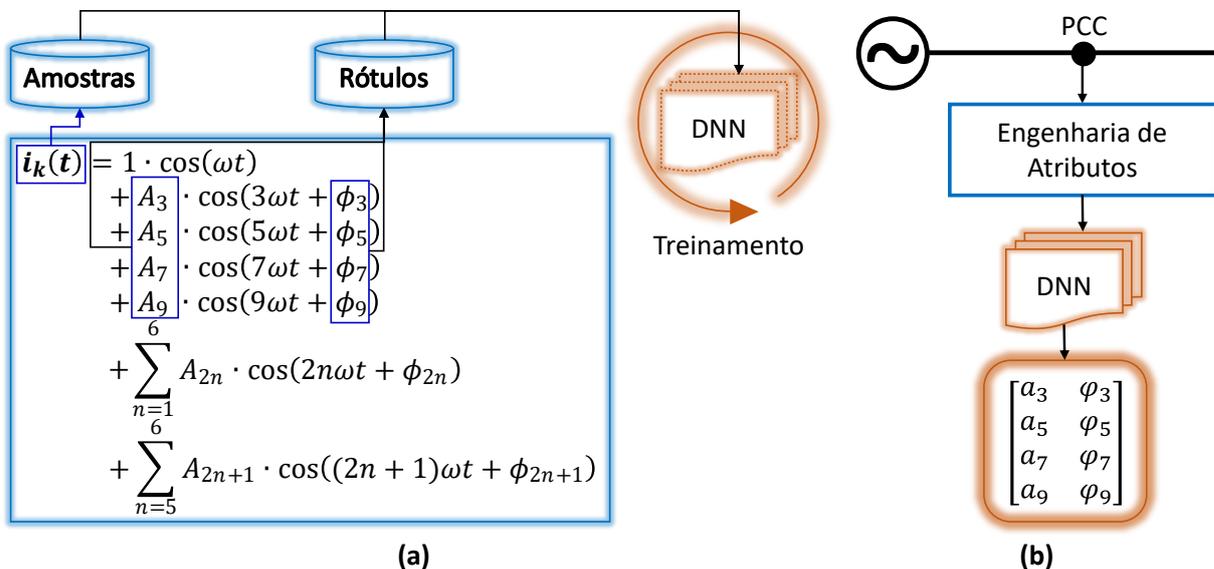
Harmônico	Amplitudes [pu]	Ângulos de fase [rad]
1	1,00	0,0000
2	0,00; 0,025	0,1309
3	0,00; 0,05; 0,10; ... ; 0,35	0,0000; 0,0873; 0,1745; 0,2618
4	0,00; 0,025	0,1309
5	0,00; 0,05; 0,10; ... ; 0,30	0,0000; 0,0873; 0,1745; 0,2618
6	0,00; 0,025	0,1309
7	0,00; 0,05; 0,10; ... ; 0,25	0,0000; 0,0873; 0,1745; 0,2618
8	0,00; 0,025	0,1309
9	0,00; 0,05; 0,10; 0,15; 0,20	0,0000; 0,0873; 0,1745; 0,2618
10	0,00; 0,025	0,1309
11	0,00; 0,025	0,1309
12	0,00; 0,025	0,1309
13	0,00; 0,025	0,1309

Fonte: Autor.

O conjunto de amostras utilizado para treinamento, validação e testes da DNN proposta neste trabalho foi gerado por meio de um algoritmo que gera um sinal cossenoidal, na frequência fundamental, com amplitude de 1 pu e ângulo de fase de 0 radiano, e soma sinais de frequências harmônicas ímpares e pares de ordens 2 a 13, conforme ilustrado na Figura 4(a). Foram gerados conjuntos de sinais de cada ordem harmônica, que são somados entre si por meio de uma rotina de cálculo.

Em seguida, o conjunto de amostras é submetido a um pré-processamento que nor-

Figura 4 – Procedimentos de geração de amostras e rótulos e de treinamento e aplicação da DNN.



Fonte: Autor.

maliza as formas de onda, mantendo a média de cada amostra próxima a zero e o desvio padrão próximo à unidade (BA; KIROS; HINTON, 2016). Com o conjunto de amostras pronto, pode-se iniciar o processo de configuração do modelo de DNN.

## 4.2 Arquitetura do Modelo da DNN

O objetivo deste trabalho é a proposição de uma abordagem baseada em redes neurais profundas para identificação de amplitudes e ângulos de fase dos harmônicos de ordem 3, 5, 7 e 9. Observa-se que esse objetivo não envolve a classificação das formas de onda em grupos, mas a obtenção de um valor numérico em cada saída que seja próximo ao valor esperado de amplitudes e ângulos de fase. Por isso, a rede neural realizará uma tarefa de regressão a valores numéricos.

Para DNNs de regressão, o otimizador Adamax (ver Seção 3.2.2.3) é conveniente em aplicações que envolvem uma grande quantidade de dados e parâmetros, além de ser computacionalmente eficiente (KINGMA; BA, 2014). Conforme mencionado na Seção 3.2.2.4, existem diversas funções de perda e métricas adequadas para DNNs de regressão. Entretanto, segundo Chollet (2017), a função de perda e a métrica geralmente utilizadas em redes de regressão são, respectivamente, erro quadrático médio (MSE), do inglês *mean squared error*, e MAE, que podem ser definidas como:

$$\text{MSE} = \sqrt{y_v - y_p} \quad (12)$$

$$\text{MAE} = |y_v - y_p| \quad (13)$$

em que  $y_v$  é a saída verdadeira, ou esperada, e  $y_p$  é a saída prevista, ou estimada, pela DNN. A métrica MAE informa quão próximas estão as estimativas em relação aos rótulos.

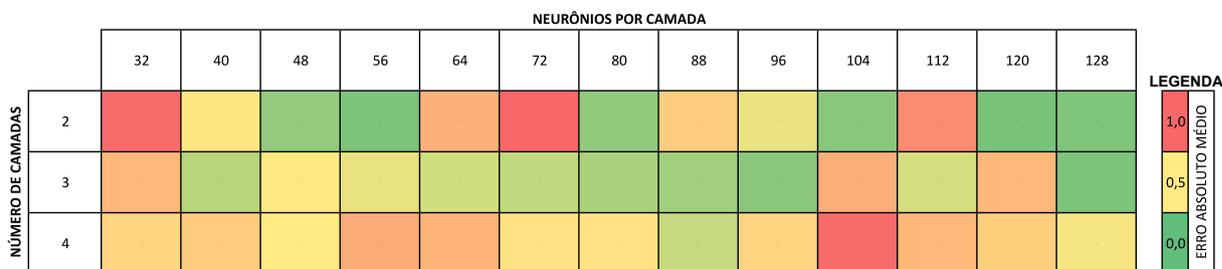
É possível determinar as características das camadas de entrada e saída da rede neural, respectivamente, com base no formato do conjunto de amostras e nos objetivos definidos. Cada forma de onda do conjunto de amostras é representada por um vetor de 64 posições. Por isso, a camada de entrada do modelo também terá um formato de 64 posições. Já a camada de saída deverá ter um formato de 8 posições, ou 8 neurônios, visto que cada valor corresponderá a uma estimativa de amplitude e ângulo de fase realizada das quatro frequências harmônicas analisadas. A função de ativação mais utilizada (Tabela 2) para realizar regressão é a função linear (CHOLLET, 2017).

A rede neural proposta terá camadas totalmente conectadas entre si, chamadas de camadas densas, do inglês *dense layers*. É preciso determinar a quantidade de camadas e o número de neurônios em cada uma dessas camadas. Para isso, utiliza-se o método de busca em grade, que significa realizar uma pesquisa exaustiva sobre valores de parâmetros (PEDREGOSA et al., 2011). Esse método implementa um treinamento e uma pontuação para cada modelo criado dentro de critérios preestabelecidos. A busca em grade com

validação cruzada, uma função disponível na interface de programação *Scikit Learn* (Scikit Learn, 2021), utiliza o método de validação cruzada de  $k$ -dobras ( $K$ -Fold). Esse método fornece índices de treinamento e teste para dividir o conjunto de amostras em treinamento e teste. O método divide o conjunto em 5 dobras ( $k = 5$ ), sendo que cada dobra é usada como validação e as restantes formam o conjunto de treinamento.

Além do  $K$ -Fold, existem outros métodos de validação cruzada como o  $K$ -Fold Estratificado, que é aplicado em redes neurais de classificação, e a Divisão Aleatória Estratificada, do inglês *Stratified Shuffle Split*, que cria divisões preservando a mesma porcentagem para cada classe de destino do conjunto completo (PEDREGOSA et al., 2011), usada para dividir as amostras em um conjunto de treinamento e um conjunto de teste, que são empregados, respectivamente, no treinamento da rede neural e na sua avaliação.

Figura 5 – Exemplo de resultado da busca em grade (busca por parâmetros).



Fonte: Autor.

Os parâmetros buscados são o número de neurônios ( $n$ ) nas camadas escondidas e o número de camadas escondidas ( $c$ ), tal que  $n = \{32, 40, 48, \dots, 120, 128\}$  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 ReLU, que é adotada nas camadas ocultas desse modelo. O modelo é treinado e avaliado a cada mudança de parâmetros, conforme o exemplo ilustrado na Figura 5.

Tabela 4 – Resultado da busca por parâmetros.

Classificação	Configuração das camadas ocultas	Erro Absoluto Médio
1	(120, 120, 120, 120)	0.030348
2	(80, 80, 80, 80)	0.030856
3	(128, 128, 128, 128)	0.031301
4	(88, 88, 88, 88)	0.031316
5	(32, 32, 32, 32)	0.031931

Fonte: Autor.

Os resultados da busca foram ordenados em ordem crescente do erro absoluto médio de avaliação. As cinco configurações que apresentaram os menores erros estão ilustradas na Tabela 4. A configuração com menor MAE foi a adotada para realizar a estimativa de amplitudes e ângulos de fase dos componentes harmônicos, conforme proposto neste

trabalho. O modelo final é descrito por meio da Tabela 5. As camadas da DNN receberam o inicializador de pesos sinápticos *Glorot Uniform* (GLOROT; BENGIO, 2010), que é o padrão do Keras, com semente definida (*seed* = 333), para que a sequência de valores inicializados nos pesos sinápticos das camadas seja sempre a mesma e possibilite uma melhor reprodutibilidade desta rede.

Tabela 5 – Configuração final da DNN.

Camada (tipo)	Ativação	Formato de saída	Parâmetros
entrada	-	(None, 64)	-
oculta_1 (Densa)	ReLU	(None, 120)	7800
oculta_2 (Densa)	ReLU	(None, 120)	14520
oculta_3 (Densa)	ReLU	(None, 120)	14520
oculta_4 (Densa)	ReLU	(None, 120)	14520
saída (Densa)	Linear	(None, 8)	968

Fonte: Autor.

Após a definição da configuração do modelo de rede neural profunda, o passo seguinte é realizar o treinamento.

### 4.3 Método de Treinamento da DNN

O conjunto geral de amostras foi separado em conjunto de treinamento e conjunto de testes para o treinamento do modelo. Dois métodos de separação foram inicialmente utilizados: o método de divisão aleatória de amostras em treinamento e testes (Scikit Learn, 2021) e o método de divisão estratificada (Scikit Learn, 2021), que cria divisões preservando a mesma porcentagem para cada grupo de destino do conjunto completo. Em ambos os casos, 95% das amostras do conjunto geral foram destinadas ao conjunto de treinamento e 5% para o conjunto de teste.

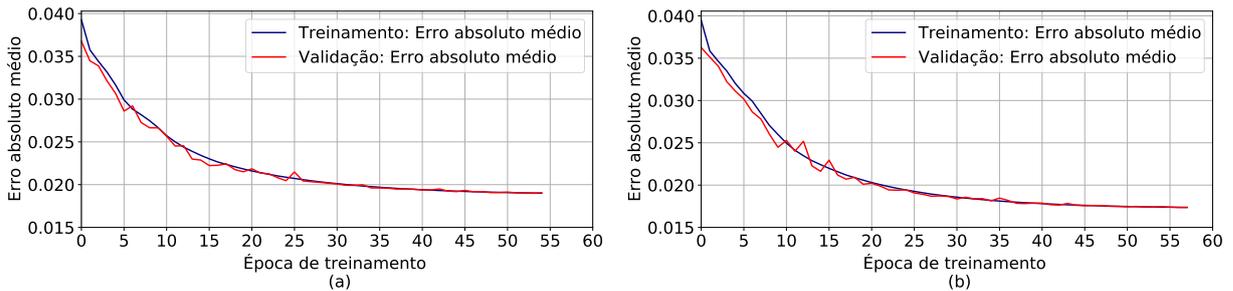
Na interface Keras, o treinamento é realizado por meio do método *fit* (vide Seção 3.2.2.1) (KERAS, 2021). Foram selecionadas 15% das amostras de treinamento para a validação durante o processo de ajuste dos pesos sinápticos. O método foi configurado para realizar o ajuste por 200 épocas, podendo ser interrompido antecipadamente por um critério de parada que estabelece como condição uma variação mínima no erro absoluto médio de 0,0001 em 5 épocas. Uma função de agendamento da taxa de aprendizagem foi estabelecida, de tal forma que a taxa de aprendizagem seja, inicialmente, 0,001 até a 10<sup>a</sup> época e, a partir desta, passa a ser atualizada de acordo com a função

$$lr_a = lr_c \cdot e^{-0,1} \quad (14)$$

em que  $lr_a$  é a taxa de aprendizagem atualizada,  $lr_c$  é a taxa de aprendizagem corrente e  $e$  é a constante de Euler.

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 utilizando a divisão aleatória pode ser observado na Figura 6(a), assim como o histórico de treinamento utilizando a divisão estratificada pode ser visto na Figura 6(b).

Figura 6 – Histórico de treinamento: (a) utilizando divisão aleatória de amostras e (b) com divisão estratificada de amostras.



Fonte: Autor.

O treinamento com divisão aleatória ocorreu até a época 54, quando o critério de parada foi acionado para evitar um esforço computacional desnecessário, visto que o erro absoluto médio não decresceu na taxa especificada de 0,0001 em 5 épocas. Já o treinamento com divisão estratificada foi até a época 57, quando ocorreu a interrupção pelo critério de parada.

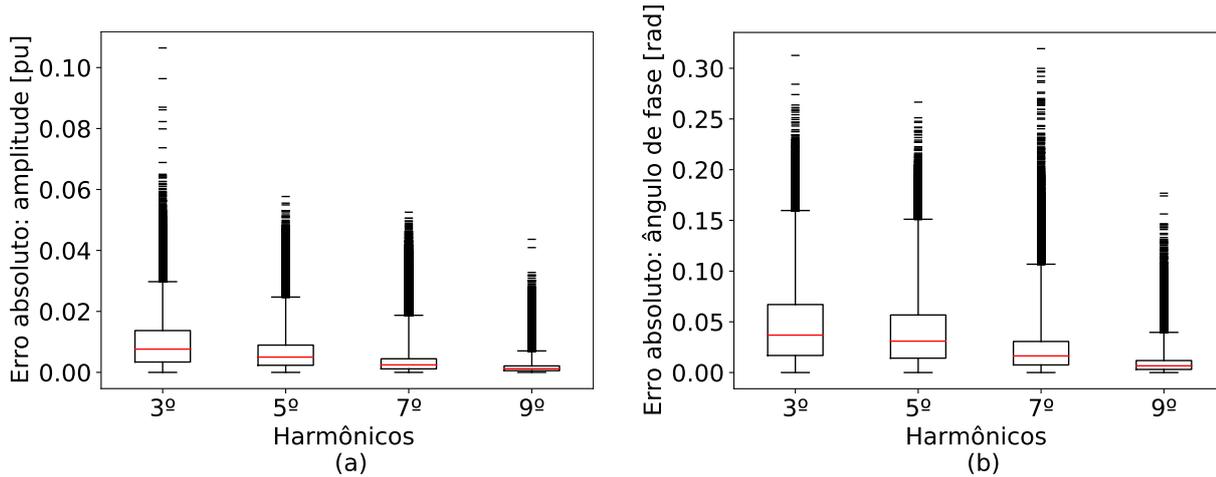
A avaliação com amostras do conjunto de teste foi realizado com os dois modelos treinados. O modelo treinado com amostras divididas aleatoriamente atingiu um MAE de 0,0190; enquanto o modelo treinado com amostras divididas de forma estratificada alcançou um MAE de 0,0174; valores considerados estabilizados de acordo com a Figura 6 e aceitáveis para a aplicação (VINAYAGAM et al., 2021). A partir destes resultados, optou-se pelo modelo treinado com as amostras divididas de forma estratificada, visto que os erros médios foram menores.

Avaliando-se exclusivamente a estimativa de amplitudes, o erro absoluto médio obtido foi de 0,0051 pu, que representa 29,3% do erro absoluto médio do treinamento. Já a avaliação exclusiva dos ângulos de fase apurou um erro médio de 0,0296 rad, correspondendo a 170,1% do erro médio de treinamento. Esse resultado pode indicar que a DNN apresenta 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 de diagrama de caixa (*boxplot*) (MENDES; MOSLEY, 2001) na Figura 7, que representa o agrupamento de erros individuais, por ordem harmônica, observados na saída do modelo de DNN por meio de quartis.

Nos diagramas da Figura 7, observa-se que as medianas de todos os erros de amplitude ficaram menores que 0,01 pu e as medianas de todos os erros de ângulo de fase ficaram menores que 0,05 rad. Os erros de 99% das estimativas de amplitude do 3º, 5º, 7º, e 9º

harmônicos foram, respectivamente, menores que 0,0296 pu, 0,0246 pu, 0,0188 pu, e 0.007 pu. Já os erros de 99% das estimativas de ângulo de fase do 3º, 5º, 7º e 9º harmônicos foram, respectivamente, menores que 0,1599 rad, 0,1511 rad, 0,1065 rad, 0,0368 rad. O 1% dos maiores erros de estimativa, representados por traços no diagrama, são denominados *outliers*.

Figura 7 – Diagramas de caixa dos erros absolutos individuais da DNN em relação a (a) amplitudes e a (b) ângulos de fase.



Fonte: Autor.

## 4.4 Comparação entre Métodos de Regressão

A fim de se justificar a aplicação de DNNs para a estimativa de harmônicos por meio de regressão, outros métodos consolidados na literatura foram testados e comparados ao método proposto neste trabalho. Pelo tipo de problema a ser modelado neste trabalho, é sabido que a DNN realiza uma regressão para valores arbitrários.

O principal critério para a escolha destes outros métodos foi a sua capacidade de produzir uma saída com múltiplos rótulos, já que a DNN proposta tem essa propriedade. Optou-se, então, por utilizar os métodos Ridge, k-ésimos vizinhos mais próximos, árvores de decisão, e florestas de decisão aleatórias, todos disponíveis na biblioteca *scikit-learn* (PEDREGOSA et al., 2011), do Python.

O conjunto de amostras utilizado foi extraído de 1% das amostras geradas de acordo com a seção 4.1, totalizando 106.928 formas de onda. A busca em grade foi utilizada em todos os métodos para determinação dos parâmetros necessários em cada caso. O coeficiente de determinação ( $R^2$ ) foi utilizado como critério de pontuação, tal que

$$R^2 = 1 - \frac{\sum_i (y_{vi} - y_{pi})^2}{\sum_i (y_v - \frac{1}{n} \sum_i y_{vi})^2} \quad (15)$$

em que  $y_v$  é o rótulo de saída,  $y_p$  é a estimativa realizada pela rede neural e  $n$  é o número de estimativas realizadas. A melhor pontuação é 1,0.

Empregou-se, como forma de classificação, o MAE, de tal forma que a configuração com menor erro foi considerada no resultado final da análise.

#### 4.4.1 Regressão Ridge

A regressão Ridge aborda alguns dos problemas dos mínimos quadrados ordinários, impondo uma penalidade no tamanho dos coeficientes (PEDREGOSA et al., 2011). Esse método resolve um modelo de regressão em que a função de perda é a função de mínimos quadrados lineares e a regularização é dada pela norma l2 (PEDREGOSA et al., 2011). Também conhecida como regressão de cume ou regularização de Tikhonov.

Realizou-se a busca por parâmetros para determinação de uma penalidade (alpha) que proporciona o menor MAE. Determinou-se, com base na classificação alcançada (Tabela 6), que a penalidade seria de 1,50. Com o parâmetro definido, o modelo foi treinado e executado. A média das diferenças entre amplitudes verdadeiras e estimadas foi de 0,013398 pu. Entre os ângulos de fase, o erro médio foi de 0,070651 radianos.

Tabela 6 – Busca em grade para a regressão Ridge.

Classificação	Alpha	Pontuação	MAE
1	1,50	0,596893	0,041797
2	1,75	0,595492	0,041892
3	2,00	0,594384	0,041969
4	2,25	0,593478	0,042035
5	2,50	0,592715	0,042092

Fonte: Autor.

#### 4.4.2 Vizinhos Mais Próximos

O princípio por trás dos métodos do vizinho mais próximo é encontrar um número predefinido de amostras de treinamento mais próximas em distância do novo ponto e prever o rótulo a partir delas. O número de amostras pode ser uma constante definida pelo usuário (aprendizado de  $K$ -vizinho mais próximo), ou variar com base na densidade local de pontos (aprendizado de vizinho baseado em raio). A distância pode, em geral, ser qualquer medida métrica: a distância euclidiana padrão é a escolha mais comum (Scikit Learn, 2021).

A regressão baseada em vizinhos pode ser usada em casos em que os rótulos de dados são contínuos. O rótulo atribuído a um ponto de consulta é calculado com base na média dos rótulos de seus vizinhos mais próximos (PEDREGOSA et al., 2011). A aprendizagem é implementada com base em  $K$  vizinhos mais próximos de cada ponto de consulta, em que  $K$  é um valor inteiro especificado pelo usuário.

Utilizou-se o algoritmo de busca exaustiva para determinação do número de vizinhos ( $K$ ) e da métrica que proporcionam menor MAE (Tabela 7). Treinando o modelo com a

métrica euclidiana e 5 vizinhos, o MAE na identificação de amplitudes foi 0,013746 pu e na identificação de ângulos de fase foi de 0,083748 rad.

Tabela 7 – Busca em grade para Vizinhos Mais Próximos.

Classificação	Métrica	$K$	Pontuação	MAE
1	euclidean	5	0,506460	0,043637
1	minkowski	5	0,506460	0,043637
3	euclidean	4	0,494220	0,043654
3	minkowski	4	0,494220	0,043654
5	minkowski	3	0,472730	0,043767
5	euclidean	3	0,472730	0,043767
7	minkowski	2	0,426658	0,044112
7	euclidean	2	0,426658	0,044112
9	manhattan	5	0,492669	0,044459
10	manhattan	4	0,479548	0,044514
11	manhattan	3	0,455360	0,044685
12	manhattan	2	0,405545	0,045256
13	euclidean	1	0,252745	0,046507
13	minkowski	1	0,252745	0,046507
15	manhattan	1	0,228932	0,047716

Fonte: Autor.

### 4.4.3 Árvore de Decisão

O método de árvores de decisão é aplicado no aprendizado supervisionado não paramétrico usado para classificação e regressão. Esse método, geralmente, representa uma tabela no formato de árvore (ABUD, 2018; ARAUJO, 2017). O objetivo é criar um modelo que preveja o valor de uma variável de destino aprendendo regras de decisão simples inferidas a partir dos recursos de dados. Uma árvore pode ser vista como uma aproximação constante por partes (Scikit Learn, 2021). As árvores de decisão são usadas para ajustar uma curva senoidal com observação adicional de ruído. Como resultado, o modelo aprende regressões lineares locais que se aproximam da curva seno (PEDREGOSA et al., 2011). Os aprendizes de árvores de decisão podem criar árvores supercomplexas que não generalizam bem os dados. Isso é chamado de sobre ajuste. Definir a profundidade máxima da árvore é necessário para evitar esse problema (Scikit Learn, 2021).

Dentre os critérios disponíveis neste método, optou-se pelo erro quadrático médio, o mesmo utilizado na DNN proposta. Utilizou-se o algoritmo de busca exaustiva de parâmetros para determinação da profundidade máxima da árvore (*max\_depth*) que proporciona o menor MAE (Tabela 8). Um modelo com profundidade máxima de 10 foi treinado e executado. Os MAEs de identificação referentes a amplitudes e aos ângulos de fase são respectivamente 0,020137 pu e 0,086628 rad.

Tabela 8 – Busca em grade para Árvore de Decisão.

Classificação	<i>max_depth</i>	Pontuação	MAE
1	10	0,445989	0,048663
2	20	0,143038	0,052913
3	30	0,093631	0,053568

Fonte: Autor.

#### 4.4.4 Floresta de Decisão Aleatória

O método de florestas de decisão aleatória é composto por classificadores e/ou regressores cuja decisão é tomada considerando decisões individuais dos classificadores e/ou regressores que o compõem (ABUD, 2018). Em florestas aleatórias, cada árvore no conjunto é construída a partir de uma amostra retirada com substituição do conjunto de treinamento (PEDREGOSA et al., 2011). A função utilizada como critério neste método também foi o MAE, pelo mesmo motivo do método anterior.

Tabela 9 – Busca em grade para Floresta de Decisão Aleatória.

Classificação	<i>max_depth</i>	<i>n_estimators</i>	Pontuação	MAE
1	30	100	0,557278	0.043300
2	30	50	0,553282	0.043367
3	20	100	0,556035	0.043455
4	20	50	0,550981	0.043621
5	30	20	0,540413	0.043707
6	20	20	0,538808	0.043932
7	20	10	0,514939	0.044621
8	30	10	0,511628	0.044666
9	10	100	0,504732	0.047305
10	10	50	0,503401	0.047352
11	10	20	0,502290	0.047388
12	10	10	0,497629	0.047511

Fonte: Autor.

A busca de parâmetros foi realizada em torno da profundidade máxima da árvore (*max\_depth*) e do número de árvores na floresta (*n\_estimators*) que proporcionam maior pontuação (Tabela 9). Um modelo com profundidade máxima de 30 e número de árvores igual a 100 foi treinado e executado. O MAE a partir da identificação de amplitudes foi de 0,012640 pu e a partir da identificação de ângulos de fase foi de 0,075097 rad.

#### 4.4.5 Classificação dos Métodos Comparados

Um modelo de DNN foi construído com 4 camadas ocultas com função de ativação ReLU e 120 neurônios em cada camada oculta. A camada de saída apresenta 8 neurônios e função de ativação linear. Esse modelo é a referência para os testes, visto que possui as

mesmas características da DNN treinada na seção 4.3. O mesmo conjunto de amostras utilizado nos métodos de regressão anterior é aplicado no modelo de rede neural densa. Esse modelo obteve um erro médio na estimativa de ângulos de 0,011462 pu e 0,064639 radianos em relação aos ângulos de fase.

O resultado (Tabela 10) indica que a rede densa obteve menor erro de estimativa de amplitudes e ângulos de fase. Esse resultado reforça a capacidade de DNN realizarem estimativa de conteúdo harmônico, o que também está em consonância com a literatura consultada (Seção 2.3).

Tabela 10 – Classificação baseada no MAE obtido entre os métodos comparados.

<b>Classificação</b>	<b>Método</b>	<b>Execução [s]</b>	<b>MAE [pu]</b>
1	DNN	0,274272	0,039556
2	Ridge	0,001294	0,041797
3	Floresta de Decisão Aleatória	0,214537	0,043300
4	Vizinhos Próximos	0,377839	0,043637
5	Árvore de Decisão	0,000554	0,048663

Fonte: Autor.

---

## Capítulo 5

# Resultados e Discussões

---

Testes realizados com a submissão de correntes obtidas nos trabalhos de Fuchs, Masoum e Ladjevardi (2005), Dugan et al. (2012), Michalec et al. (2021) são apresentados para validar o modelo de DNN descrito no capítulo anterior. As amplitudes expostas nos referidos trabalhos foram extraídas por meio de medições em cargas usadas nos respectivos testes experimentais.

### 5.1 Testes com Correntes de Cargas Experimentais

Por meio de pesquisa bibliográfica, teve-se acesso a experimentos realizados por Fuchs, Masoum e Ladjevardi (2005), Dugan et al. (2012), Michalec et al. (2021), nos quais as correntes de algumas cargas foram medidas e os resultados, incluindo as formas de onda, foram publicados. Essas cargas são descritas na Tabela 11.

Tabela 11 – Descrição das cargas.

Carga	Descrição
a	forno de micro-ondas de última geração em operação nominal
b	manipulador de ar com motor de indução de velocidade constante em maior potência de resfriamento
c	lâmpada incandescente de 65W
d	lâmpada a arco voltaico
e	acionador de velocidade ajustável de seis pulsos
f	conjunto de equipamentos domésticos

Fonte: Autor.

A partir de cada amplitude extraída da forma de onda, construiu-se as respectivas formas de onda de corrente, cujas características harmônicas estão descritas na Tabela 12.

Os valores de ângulos de fase foram adotados de acordo com o treinamento da DNN. A variação do ângulo depende do sistema elétrico em que o equipamento se encontra instalado. Em uma situação prática, seria possível alterar os dados de treinamento disponíveis com o objetivo de adaptar a DNN ao local de aplicação.

Tabela 12 – Características harmônicas das correntes de carga.

Carga	Amplitudes por harmônico [pu]												
	1	2	3	4	5	6	7	8	9	10	11	12	13
a	1,0	0,086	0,205	0,046	0,153	0,011	0,041	0,069	0,056	0,020	0,038	0,052	0,040
b	1,0	0,040	0,021	0,014	0,026	0,009	0,006	0,003	0,004	0,006	0,002	0,004	0,002
c	1,0	0,026	0,057	0,016	0,126	0,009	0,125	0,065	0,091	0,066	0,030	0,018	0,057
d	1,0	0,000	0,200	0,000	0,070	0,000	0,003	0,000	0,024	0,000	0,018	0,000	0,008
e	1,0	0,000	0,000	0,000	0,180	0,000	0,120	0,000	0,000	0,000	0,060	0,000	0,040
f	1,0	0,018	0,250	0,008	0,070	0,005	0,040	0,000	0,013	0,000	0,010	0,000	0,005

Carga	Ângulos de fase por harmônico [rad]												
	1	2	3	4	5	6	7	8	9	10	11	12	13
a-f	0,0	0,020	0,040	0,114	0,171	0,173	0,206	0,131	0,037	0,021	0,163	0,210	0,129

Fonte: Autor.

Foram realizados doze testes. Nestes testes, cada carga serviu como base para a corrente de teste por duas vezes. A primeira análise foi feita com a corrente contendo o componente fundamental e os harmônicos ímpares e pares, até a 13<sup>a</sup> ordem. A intenção foi avaliar a capacidade do modelo de se adaptar a um sinal com harmônicos que não são estimados pela DNN, como os de ordem par. Em seguida, um segundo teste foi operado somente com os harmônicos que se pretende estimar com a DNN a fim de se obter uma referência comparativa e verificar a capacidade de generalização de soluções do modelo. A ordem dos testes, as cargas utilizadas e o conteúdo harmônico da corrente estão expostos na Tabela 13.

Tabela 13 – Descrição dos testes.

Teste	Carga	Harmônicos
1	a	1-13
2	a	1, 3, 5, 7, 9
3	b	1-13
4	b	1, 3, 5, 7, 9
5	c	1-13
6	c	1, 3, 5, 7, 9
7	d	1-13
8	d	1, 3, 5, 7, 9
9	e	1-13
10	e	1, 3, 5, 7, 9
11	f	1-13
12	f	1, 3, 5, 7, 9

Fonte: Autor.

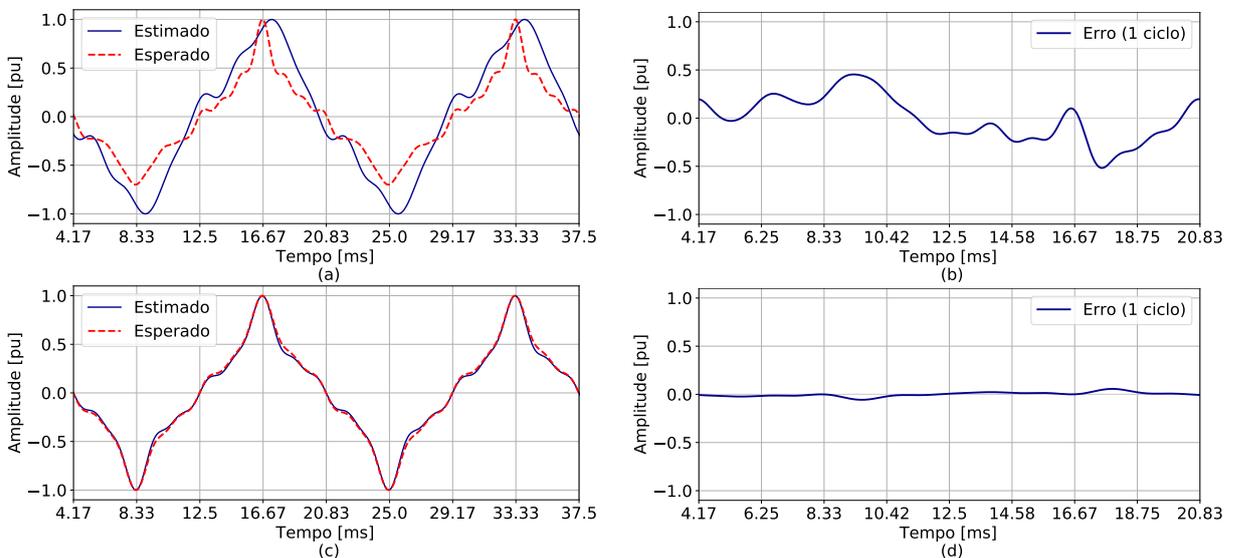
Tabela 14 – Erros de amplitude [pu] e ângulos de fase [rad], e diferença média e máxima entre amplitudes das formas de onda apresentadas nos testes.

Teste	$A_3$	$A_5$	$A_7$	$A_9$	$\phi_3$	$\phi_5$	$\phi_7$	$\phi_9$	$\Delta_{med}$	$\Delta_{max}$
1	0,0128	0,1679	0,1111	0,0402	0,8577	0,7090	1,0269	0,2377	0,1964	0,5182
2	0,0194	0,0170	0,0138	0,0071	0,0844	0,0540	0,0991	0,0858	0,0175	0,0572
3	0,0214	0,0032	0,0084	0,0011	0,1454	0,1139	0,2035	0,0582	0,0648	0,1185
4	0,0361	0,0033	0,0082	0,0047	0,1089	0,0925	0,2610	0,0367	0,0256	0,0620
5	0,0454	0,1138	0,0278	0,1160	1,3067	0,3259	1,5786	0,1078	0,2030	0,6353
6	0,0180	0,0402	0,0294	0,0117	0,2019	0,0270	0,1242	0,0650	0,0313	0,0854
7	0,0481	0,0424	0,0075	0,0201	0,2139	0,0874	0,1349	0,1463	0,0384	0,1248
8	0,0651	0,0264	0,0104	0,0274	0,0784	0,2214	0,0402	0,0742	0,0497	0,0942
9	0,0569	0,1014	0,0557	0,0039	0,6742	0,5796	0,2309	0,1011	0,0895	0,2746
10	0,0147	0,0184	0,0216	0,0052	0,0506	0,1332	0,1529	0,0126	0,0187	0,0541
11	0,0304	0,0310	0,0207	0,0353	0,0911	0,2309	0,0355	0,0886	0,0325	0,0799
12	0,0168	0,0024	0,0195	0,0316	0,0587	0,0004	0,0005	0,0429	0,0250	0,0750

Fonte: Autor.

Por meio da Tabela 14, pode-se observar o erro absoluto entre o valor real e o valor estimado por amplitude e ângulo de fase em cada teste. Também foi calculada a diferença média ( $\Delta_{med}$ ) e a diferença máxima ( $\Delta_{max}$ ) entre as amplitudes instantâneas das formas de onda das Figuras 8, 9 e 10. O valor médio do erro referente às amplitudes mostrado na Tabela 14 é de 0,0331 pu. Levando-se em conta somente os testes realizados com os harmônicos que a DNN é capaz de identificar, o valor médio é de 0,0195 pu, o que representa um erro médio 58,33% menor em relação aos testes com harmônicos pares e ímpares entre a 2<sup>a</sup> e a 13<sup>a</sup> ordem. O erro médio relacionado aos ângulos de fase é de 0,2373 rad. Quando observa-se somente os harmônicos que a DNN é treinada para estimar

Figura 8 – Testes 1: (a) formas de onda comparativas e (b) erro em 1 ciclo da forma de onda. Teste 2: (c) formas de onda comparativas e (d) erro em 1 ciclo.



Fonte: Autor.

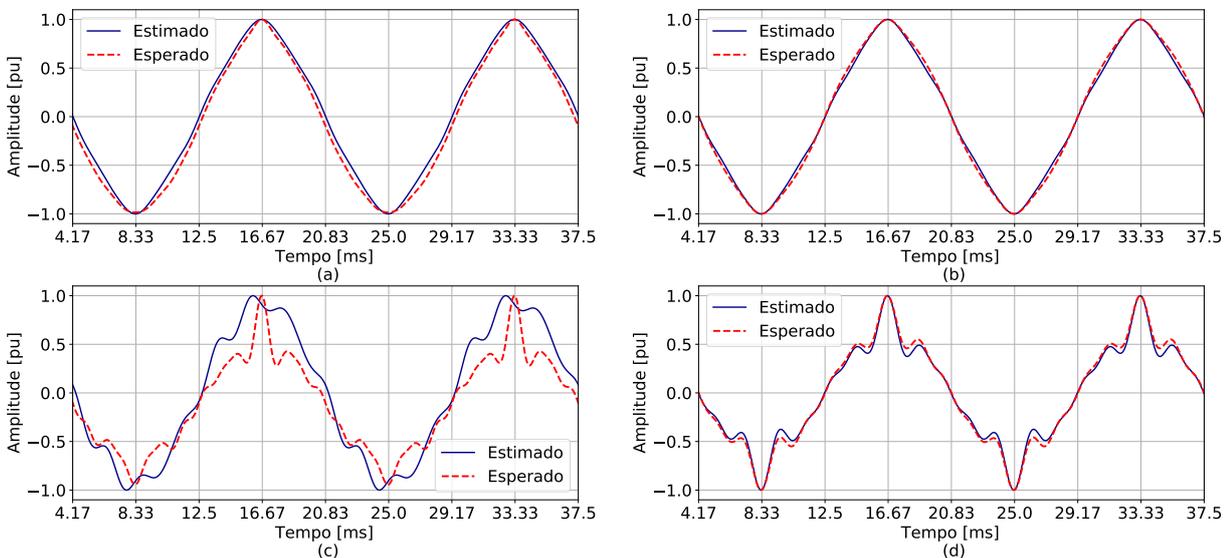
(3<sup>o</sup>, 5<sup>o</sup>, 7<sup>o</sup> e 9<sup>o</sup>), o erro médio é de 0,0878 radianos, o que corresponde a uma redução de 77,31% do erro em relação aos testes com o espectro harmônico completo até a 13<sup>a</sup> ordem.

Já em relação à diferença entre amplitudes das curvas ilustradas nas Figuras 8, 9 e 10, o valor médio de  $\Delta_{med}$  é de 0,0660 pu e a média dos valores máximos é de 0,1816 pu. Restringindo a análise dos resultados para os testes com os harmônicos treinados para serem identificados, o valor médio de  $\Delta_{med}$  é de 0,0280 pu, correspondendo a uma redução de 73,1% em relação ao valor médio relacionado aos testes com harmônicos pares e ímpares. A média de  $\Delta_{max}$  também foi menor quando os testes foram feitos somente com harmônicos que podem ser estimados pela DNN: 0,0713 pu contra 0,2919 pu, referente aos testes com harmônicos pares e ímpares.

As formas de onda das correntes esperadas e estimadas pela DNN são exibidas nas Figuras 8, 9 e 10. Nota-se, na Figura 8, que o erro médio de amplitude quando estima-se o conteúdo harmônico a partir de um sinal que apresenta apenas frequências treinadas equivale a uma redução de 91,09% do erro quando o sinal de entrada contém todo o espectro até a 13<sup>o</sup> ordem. O teste 1 (Figura 8(a)) foi o que apresentou maior erro médio de amplitudes entre as formas de onda comparadas (Figura 8(b)).

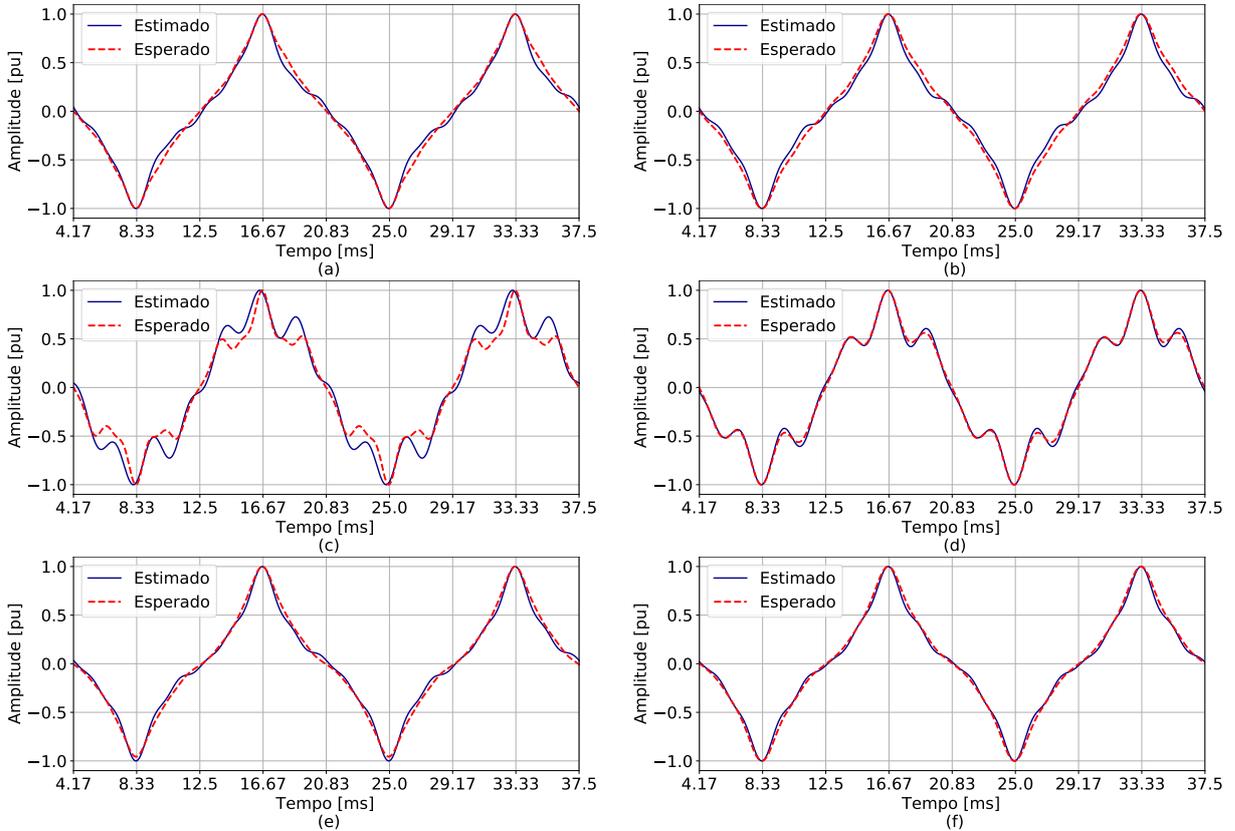
Pode ser observado por meio dos testes 3 a 12 (Figuras 9 e 10) que a DNN conseguiu rastrear, com um erro médio de 5,785%, as formas de onda esperadas de corrente. Para expandir a análise da aplicação, realizar-se-á um estudo de caso da DNN proposta operando em conjunto com um FAP ideal, com a finalidade de atenuar a DHT de corrente no PCC da carga conjunto de equipamentos domésticos (CED).

Figura 9 – Formas de onda comparativas referentes aos testes (a) 3, (b) 4, (c) 5, (d) 6.



Fonte: Autor.

Figura 10 – Formas de onda comparativas referentes aos testes (a) 7, (b) 8, (c) 9, (d) 10, (e) 11, (f) 12.



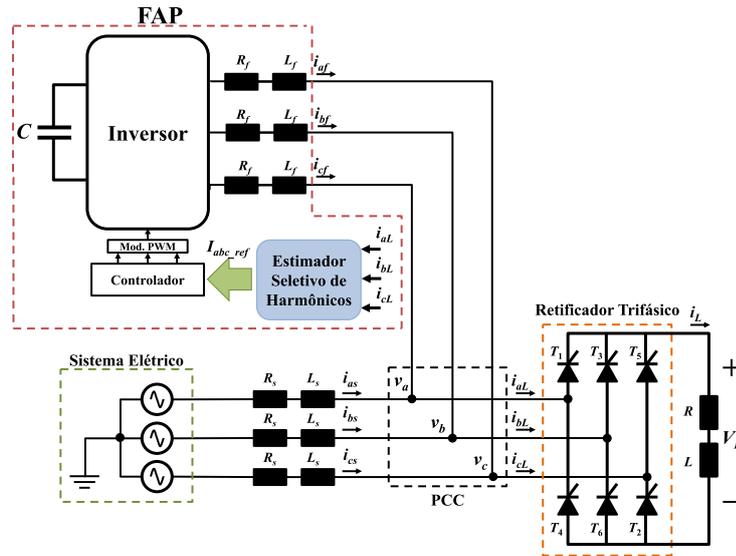
Fonte: Autor.

## 5.2 Compensação Seletiva de Harmônicos Estimados por DNN

Os efeitos demonstrativos de uma compensação harmônica ideal (BERNARDINO et al., 2021; SINGH et al., 2011) em baixa tensão, realizada no PCC entre a carga e o FAP (Figura 11), são investigados por meio da simulação de um FAP ideal, que gera uma corrente de compensação baseada nos referenciais de amplitude e ângulo de fase fornecidos pela DNN (Figura 12). Essa compensação harmônica é realizada com a finalidade de exemplificar a aplicação e o funcionamento do método de estimativa harmônica proposto em um caso de atenuação da DHT. Com base na IEEE 519:2014 (IEEE, 2014), considera-se que uma DHT de corrente, verificada no PCC da instalação elétrica de baixa tensão, de até 5% está dentro dos limites dessa recomendação técnica.

O funcionamento do método de estimativa harmônica baseado na DNN proposta neste trabalho está ilustrado na Figura 12. O bloco “a” mostra a corrente no PCC antes da compensação. Essa corrente é submetida ao bloco “1”, que representa o processo de sensoriamento, condicionamento e digitalização do sinal, o qual promove a aquisição do sinal e o seu condicionamento para a conversão analógica-digital. Esse sinal de corrente digita-

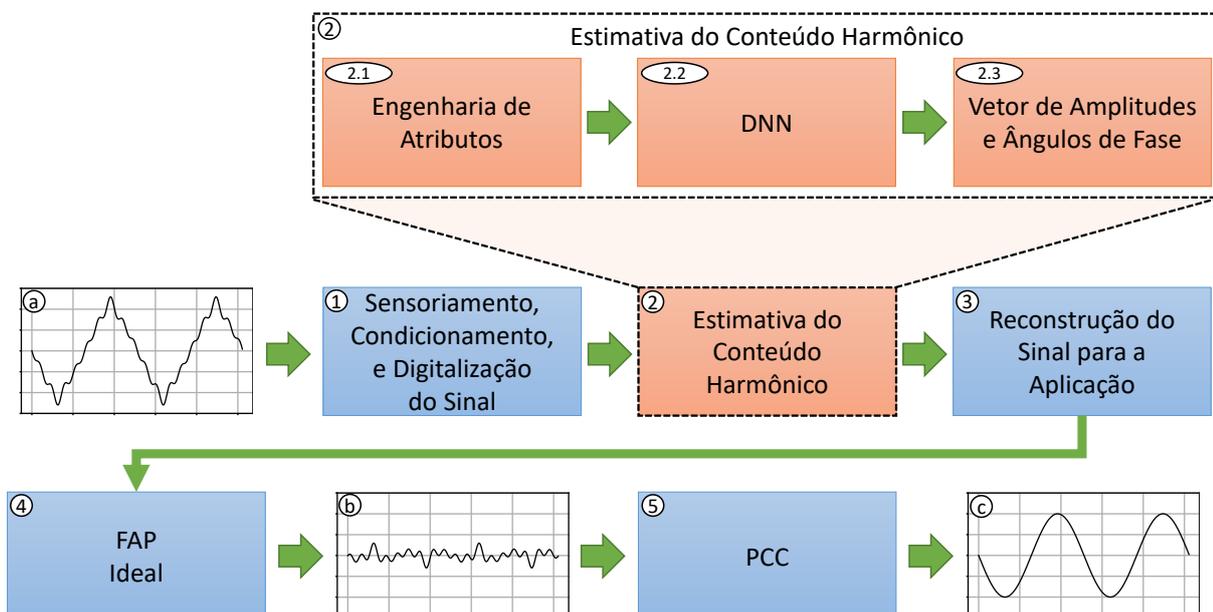
Figura 11 – Aplicação da DNN como estimador seletivo de harmônicos do FAP.



Fonte: Autor.

lizado é submetido ao bloco “2” para a estimativa do conteúdo harmônico. O bloco “2” subdivide-se em 3 etapas: engenharia de atributos (SOUZA et al., 2022), DNN e vetor de amplitudes e ângulos de fase. A etapa de engenharia de atributos, representada pelo bloco “2.1”, é responsável pela adequação do sinal digital às entradas da DNN, o que inclui a normalização e a agregação de 64 amostragens por quarto de ciclo em um vetor (frequência amostral de 15,36 kHz). Esse vetor é, então, submetido à DNN, representada pelo bloco “2.2”, para a realização da estimativa dos componentes harmônicos de amplitude e ângulo de fase de 3<sup>a</sup>, 5<sup>a</sup>, 7<sup>a</sup> e 9<sup>a</sup> ordens. A DNN retorna outro vetor contendo as amplitudes e os ângulos de fase estimados, que é representado pelo bloco “2.3”. Os

Figura 12 – Exemplo de aplicação: FAP.



Fonte: Autor.

componentes estimados são usados pelo bloco “3” para a reconstrução do sinal de acordo com a aplicação, que neste exemplo é a corrente de referência de um FAP ideal. O FAP (bloco “4”), emprega o sinal reconstruído como referência para a geração da corrente de compensação seletiva (bloco “b”), que é injetada no PCC (bloco “5”). Essa corrente pode atenuar a DHT neste ponto. Por último, a corrente compensada pelo FAP ideal é apresentada no bloco “c”.

Os componentes harmônicos das correntes de carga foram obtidas do trabalho de Michalec et al. (2021). Dois estudos de caso foram realizados por carga, sendo que o primeiro empregará o espectro harmônico completo até a 13<sup>a</sup> ordem e o segundo utilizará somente o espectro de harmônicos ímpares até a 9<sup>a</sup> ordem, visto que estes são os harmônicos treinados. As cargas deste estudo estão conectadas em baixa tensão e são denominadas como CED, conjunto de equipamentos de escritório (CEE) e conjunto de equipamentos de iluminação (CEI).

De acordo com Michalec et al. (2021), o CED é composto por cargas domésticas, como um monitor LCD de 20 polegadas, uma cafeteira, lâmpadas fluorescentes compactas, um forno de micro-ondas, um carregador de notebooks, e um aspirador de pó. O CEE é formado por um monitor LCD de 20 polegadas, lâmpadas fluorescentes T8, lâmpadas fluorescentes compactas, uma copiadora, um carregador de notebook e um carregador adaptativo rápido de celular. O CEI é construído a partir de lâmpadas fluorescentes compactas, lâmpadas fluorescentes T8, lâmpadas de descarga de alta intensidade, dimerizadores e lâmpadas incandescentes. A Tabela 15 descreve as amplitudes e ângulos de fase considerados neste estudo.

Tabela 15 – Características harmônicas das correntes de carga.

Carga	Amplitudes por harmônico [pu]												
	1	2	3	4	5	6	7	8	9	10	11	12	13
CED	1,0	0,018	0,250	0,008	0,070	0,005	0,040	0,000	0,013	0,000	0,010	0,000	0,005
CEE	1,0	0,000	0,460	0,000	0,320	0,000	0,280	0,000	0,290	0,000	0,200	0,000	0,100
CEI	1,0	0,010	0,350	0,000	0,160	0,000	0,135	0,000	0,138	0,000	0,039	0,000	0,080
Carga	Ângulos de fase por harmônico [rad]												
	CED												
CEE	0,0	0,020	0,040	0,114	0,171	0,173	0,206	0,131	0,037	0,021	0,163	0,210	0,129
CEI													

Fonte: Autor.

Para a realização dos estudos, as cargas receberam uma numeração indicativa da descrição do conteúdo harmônico. O número 1 refere-se à corrente de carga contendo harmônicos pares e ímpares até a 13<sup>a</sup> ordem. O número 2 indica que a corrente contém os harmônicos ímpares até a 9<sup>a</sup> ordem, conforme a Tabela 16.

Tabela 16 – Descrição dos casos estudados.

Caso	Carga	Descrição
1	CED1	Corrente contendo harmônicos pares e ímpares até a 13 <sup>a</sup> ordem.
2	CED2	Corrente contendo harmônicos ímpares até a 9 <sup>a</sup> ordem.
3	CEE1	Corrente contendo harmônicos pares e ímpares até a 13 <sup>a</sup> ordem.
4	CEE2	Corrente contendo harmônicos ímpares até a 9 <sup>a</sup> ordem.
5	CEI1	Corrente contendo harmônicos pares e ímpares até a 13 <sup>a</sup> ordem.
6	CEI2	Corrente contendo harmônicos ímpares até a 9 <sup>a</sup> ordem.

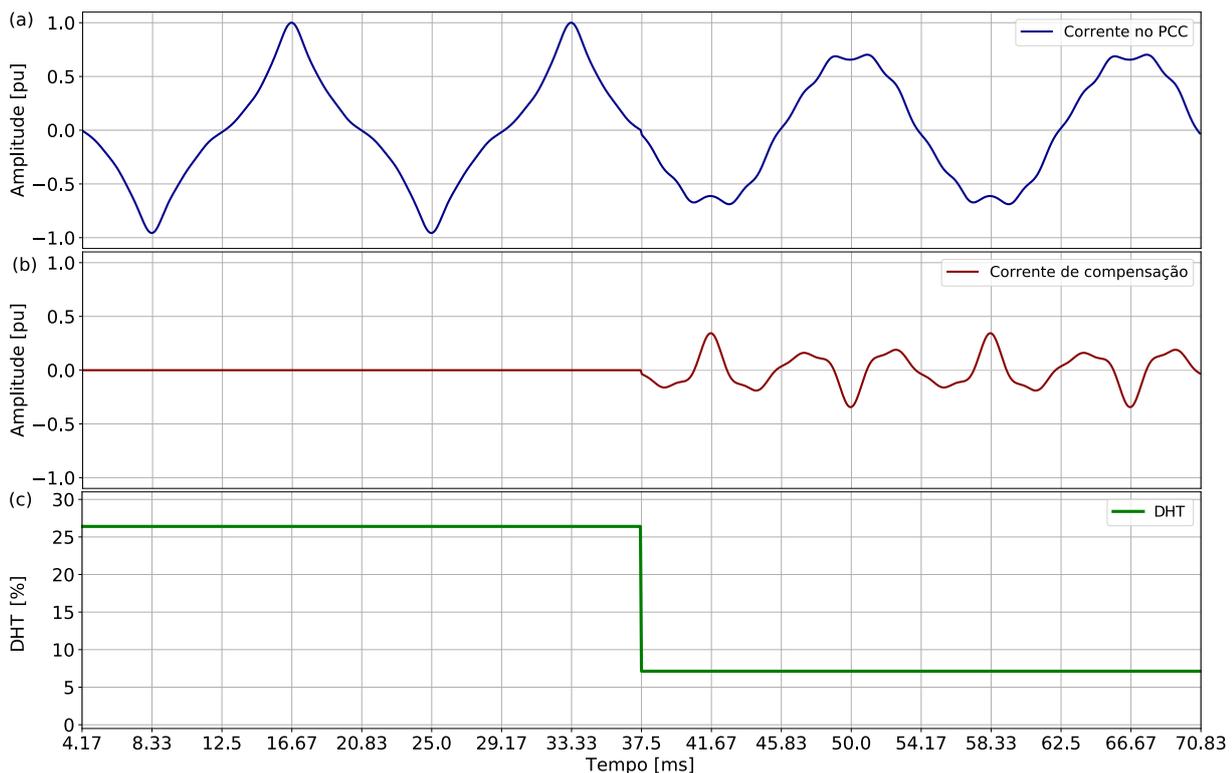
Fonte: Autor.

### 5.2.1 Caso 1: Conjunto de Equipamentos Domésticos 1

Considera-se que a carga CED1 está conectada ao PCC juntamente com um FAP ideal. A corrente de carga no PCC é apresentada na Figura 13(a), e é composta pelos componentes pares e ímpares descritos na Tabela 15. A DNN recebe o sinal de um quarto de ciclo da corrente no PCC e estima as amplitudes e ângulos de fase do 3<sup>o</sup>, 5<sup>o</sup>, 7<sup>o</sup> e 9<sup>o</sup> harmônicos. Utilizando esse referencial, o FAP começa a injetar a corrente de compensação no PCC em 37,5 ms, conforme ilustrado na Figura 13(b).

Pode-se avaliar a evolução da DHT por meio da Figura 13(c), na qual o valor da distorção parte de 26,40%, antes da compensação, para 7,13%, após a compensação, proporcionando uma redução de 72,97% na DHT. Observa-se que, mesmo com harmônicos

Figura 13 – Caso 1: (a) corrente no PCC, (b) corrente de compensação, (c) DHT.



Fonte: Autor.

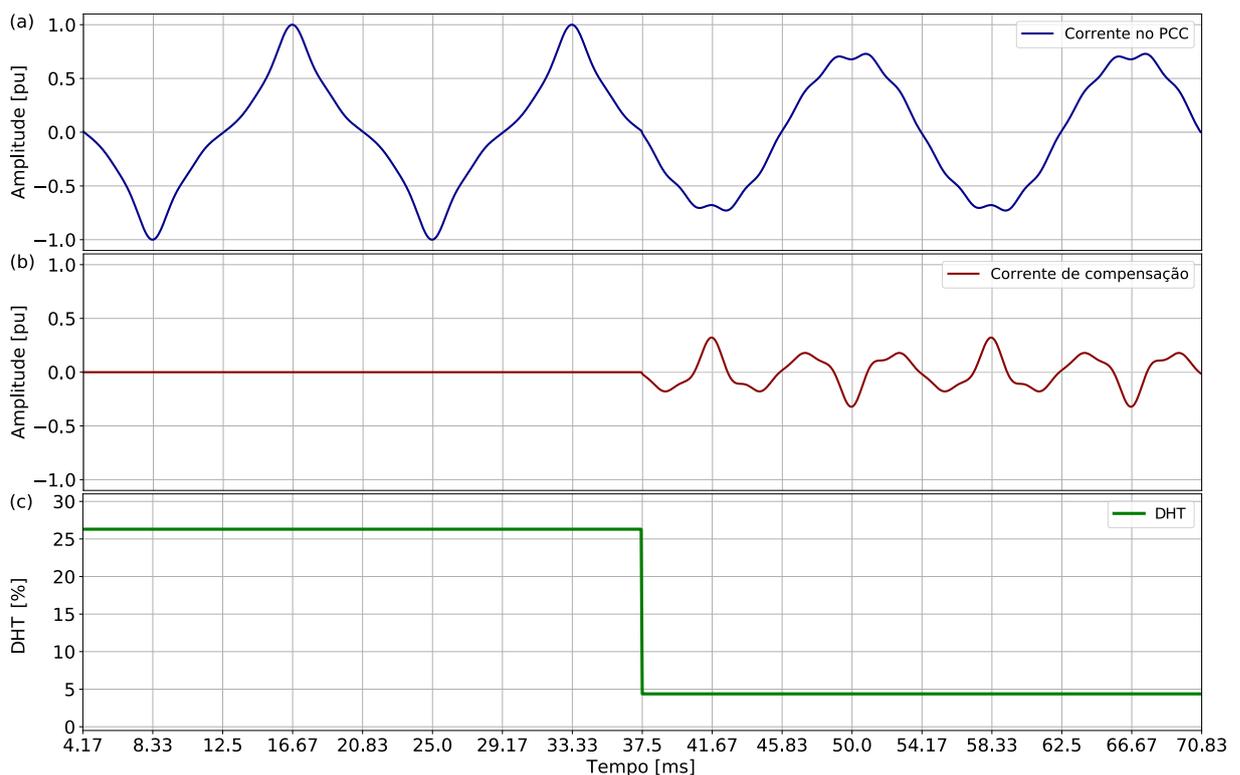
pares, que estão fora do escopo de identificação da DNN, a corrente de compensação foi gerada de tal forma a reduzir a DHT de corrente para um valor equivalente a 27% do valor inicial. A compensação, neste caso, pode ser considerada como satisfatória, de acordo com os critérios estabelecidos.

### 5.2.2 Caso 2: Conjunto de Equipamentos Domésticos 2

Considera-se que a carga CED2 está conectada ao PCC juntamente com um FAP ideal. A corrente de carga no PCC (Figura 14(a)) é composta apenas pelos componentes ímpares até o 9º harmônico, conforme a Tabela 15. A DNN recebe o sinal de corrente e estima as amplitudes e ângulos de fase do 3º, 5º, 7º e 9º harmônicos. Utilizando o referencial fornecido pela DNN, o FAP começa a injetar a corrente de compensação no PCC em 37,5 ms, conforme ilustrado na Figura 14(b).

Pode-se observar a evolução da DHT na Figura 14(c), que começa em 26,3% e passa a ser 4,3784% após a compensação, provocando uma redução de 83,35% na distorção total. A DHT final atingiu 16,65% do valor inicial, o que demonstra a capacidade de redução das distorções utilizando a DNN proposta. Considerando a DHT após a compensação, o Caso 2 obteve um melhor desempenho em relação ao Caso 1. Isso pode ser explicado pela ausência de componentes harmônicos desconhecidos para a DNN, como os componentes pares, por exemplo. O desempenho da compensação realizada no Caso 2 foi ainda mais satisfatório, de acordo com o patamar estabelecido em 5.2.

Figura 14 – Caso 2: (a) corrente no PCC, (b) corrente de compensação, (c) DHT.



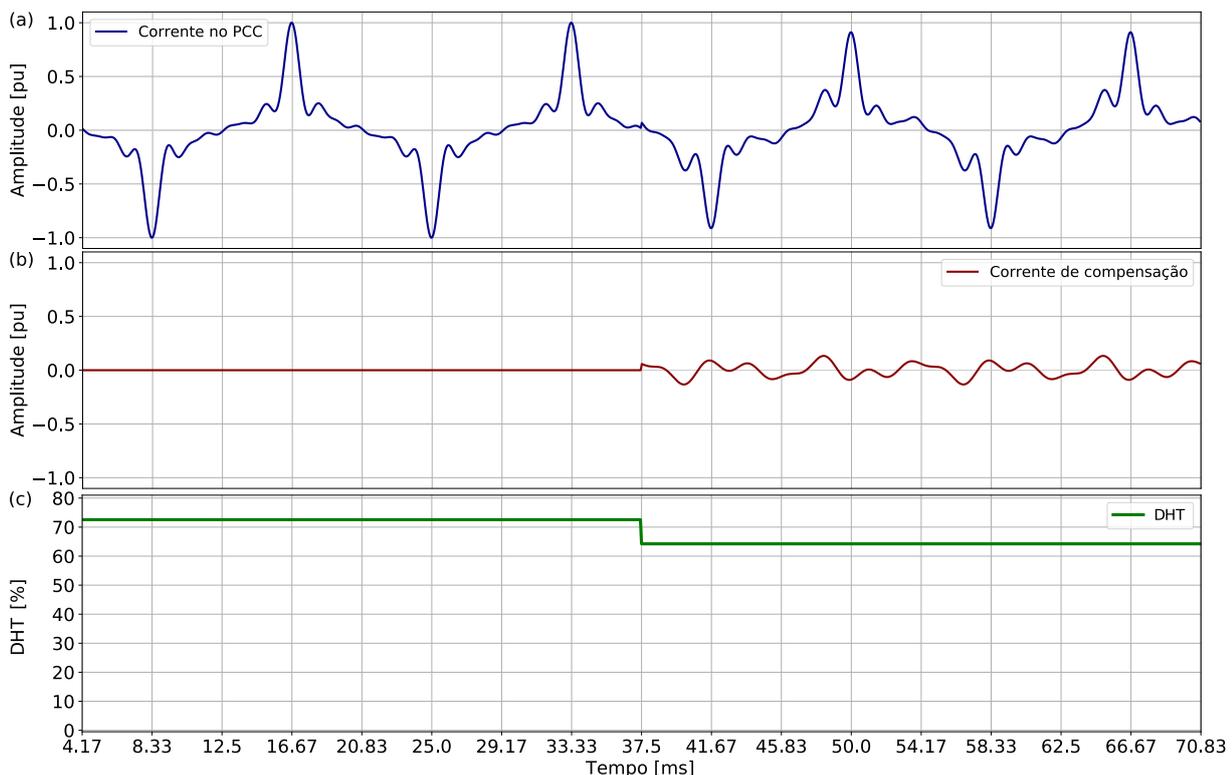
Fonte: Autor.

### 5.2.3 Caso 3: Conjunto de Equipamentos de Escritório 1

Considera-se que a carga CEE1 está conectada ao PCC juntamente com um FAP ideal. A corrente de carga no PCC (Figura 15(a)) é composta pelos componentes harmônicos ímpares descritos na Tabela 15. Entretanto, as amplitudes desses harmônicos estão fora da faixa das amplitudes treinadas. Ou seja, a DHT dessa forma de onda é maior do que a DHT das formas de onda usadas no processo de treinamento. A DNN recebe o sinal de corrente no PCC e estima as amplitudes e ângulos de fase do 3º, 5º, 7º e 9º harmônicos. Utilizando esse referencial, o FAP começa a injetar a corrente de compensação no PCC em 37,5 ms, conforme ilustrado na Figura 15(b). Quando a corrente de compensação é aplicada, nota-se uma redução da DHT de 11,48%, saindo de 72,5603% para 64,233% (Figura 15(c)).

Mesmo com a presença de amplitudes harmônicas superiores àquelas usadas no treinamento, o FAP utilizando DNN foi capaz de reduzir a DHT. Nota-se a influência negativa de amplitudes e ângulos de fase acima daqueles utilizados no treinamento do modelo quando compara-se os Casos 1 e 2 ao Caso 3. Conforme citado na Seção 4.1, o conjunto de amostras foi limitado devido à capacidade computacional da máquina utilizada neste trabalho. Para reduzir o erro de estimativas da DNN e melhorar a capacidade de atenuação da DHT, é possível construir um conjunto de amostras com faixas mais amplas de amplitudes e ângulos de fase e utilizar, por exemplo, as soluções de treinamento em

Figura 15 – Caso 3: (a) corrente no PCC, (b) corrente de compensação, (c) DHT.



Fonte: Autor.

nuvem, citadas na Seção 1.3, que têm a capacidade de processamento e armazenamento suficientes para ajustar o modelo a um maior conjunto de treinamento.

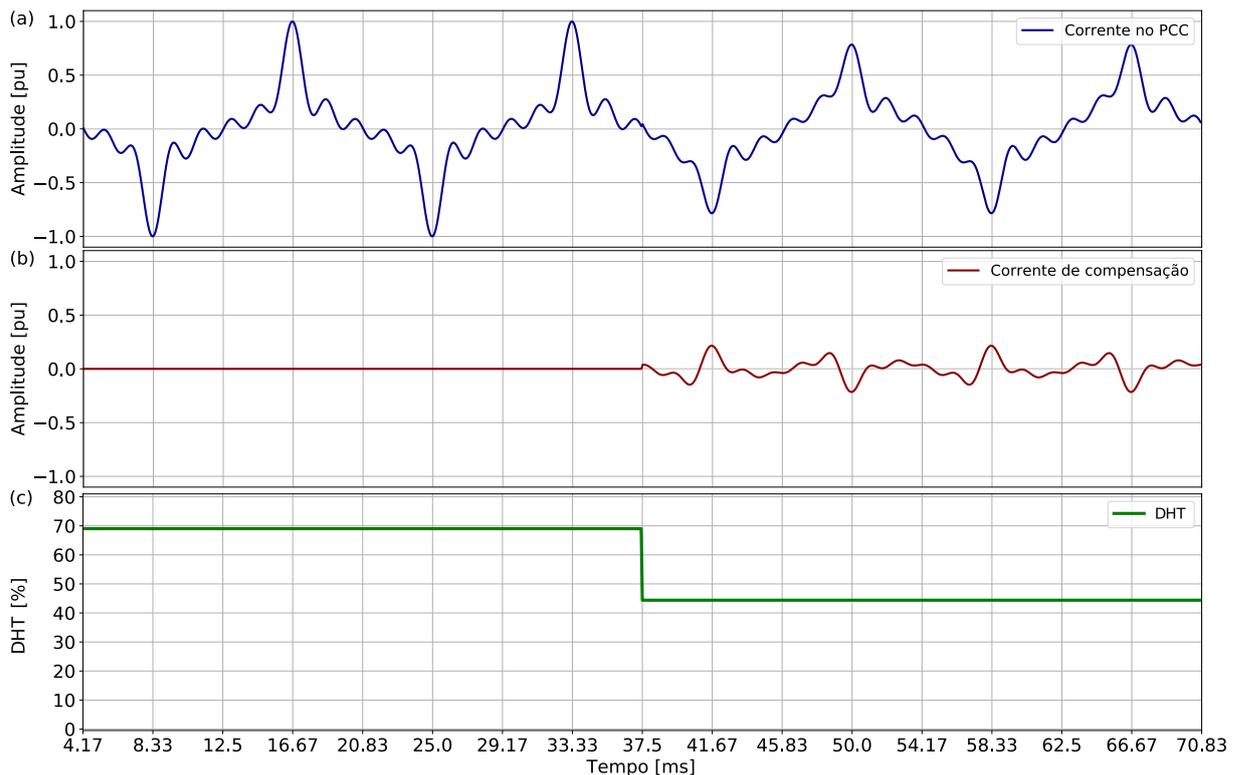
#### 5.2.4 Caso 4: Conjunto de Equipamentos de Escritório 2

Considera-se que a carga CEE2 está conectada ao PCC juntamente com um FAP ideal. A corrente de carga no PCC é apresentada na Figura 16(a), e é composta apenas pelos componentes ímpares até o 9º harmônico, conforme descrito na Tabela 15. Assim como no Caso 3, as amplitudes desses componentes extrapolam os limites superiores das amplitudes de treinamento. A DNN recebe o sinal de um quarto de ciclo da corrente no PCC e estima as amplitudes e ângulos de fase do 3º, 5º, 7º e 9º harmônicos.

Utilizando o referencial fornecido pela DNN, o FAP começa a injetar a corrente de compensação no PCC em 37,5 ms, conforme ilustrado na Figura 16(b). Analisando-se a evolução da DHT na Figura 16(c), é possível visualizar que o indicador parte de 69,029% antes da compensação e atinge 44,3902% após a compensação. Houve uma redução de 35,69% na DHT, mesmo que a forma de onda da estimativa tenha um conteúdo harmônico superior ao treinado pela DNN.

O desempenho da compensação da distorção harmônica é significativamente mais efetivo neste caso quando comparado ao Caso 3. Houve uma redução de DHT 296% maior, quando comparada ao caso anterior. Percebe-se que amplitudes e ângulos de fase não

Figura 16 – Caso 4: (a) corrente no PCC, (b) corrente de compensação, (c) DHT.



Fonte: Autor.

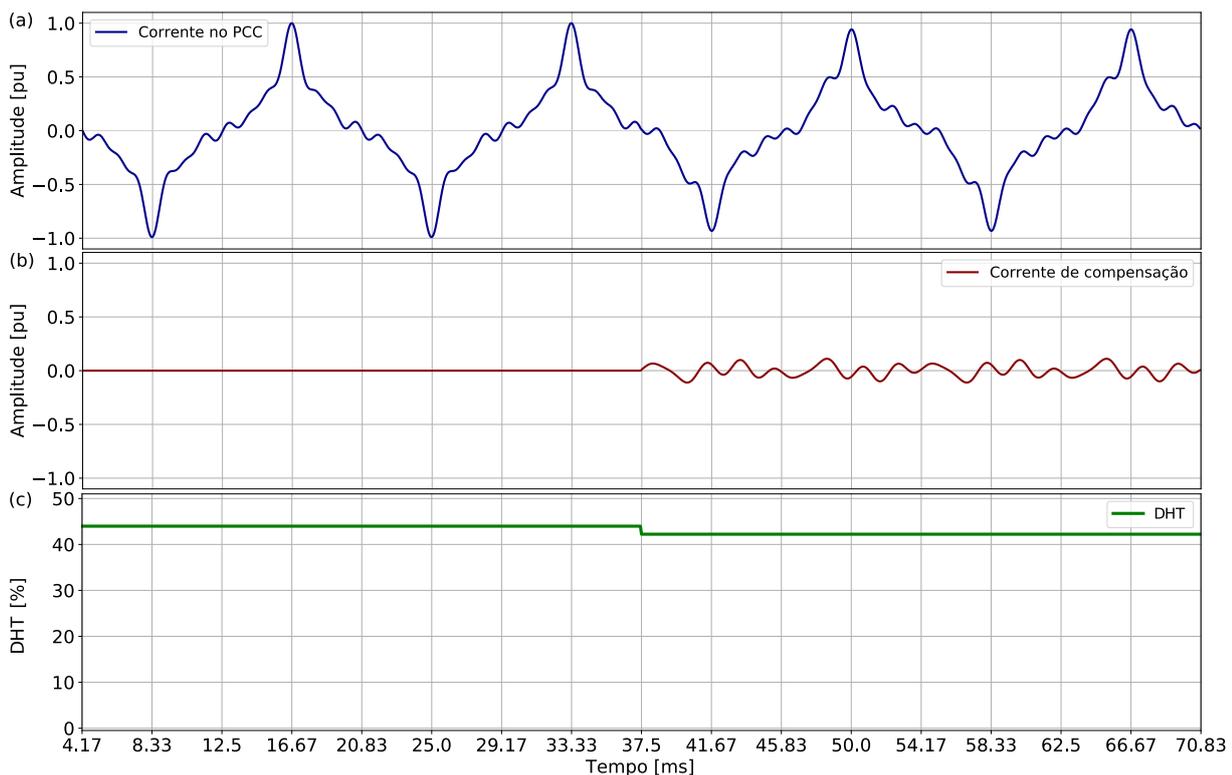
treinados prejudicam o desempenho de estimativa da DNN, mas, ainda assim, observou-se redução de DHT em todos os casos estudados até aqui. Mesmo que essa compensação não tenha atingido o patamar final de DHT de 5%, a redução do indicador deve provocar a redução de perdas ôhmicas causadas por correntes harmônicas circulando no PCC.

### 5.2.5 Caso 5: Conjunto de Equipamentos de Iluminação 1

Considera-se que a carga CEI1 está conectada ao PCC juntamente com um FAP ideal. A corrente de carga no PCC é apresentada na Figura 17(a), e é composta pelos componentes de 3<sup>a</sup>, 5<sup>a</sup>, 7<sup>a</sup> e 9<sup>a</sup> ordens, que estão dentro da faixa de treinamento da DNN, e os componentes de 11<sup>o</sup> e 13<sup>o</sup> harmônicos, cujas amplitudes estão fora da faixa utilizada para o treinamento da rede neural. Além desses componentes, a amplitude do 2<sup>a</sup> harmônico equivale a 0,01 pu. A DNN recebe o sinal de um quarto de ciclo da corrente no PCC e estima as amplitudes e ângulos de fase do 3<sup>o</sup>, 5<sup>o</sup>, 7<sup>o</sup> e 9<sup>o</sup> harmônicos. Utilizando o referencial gerado a partir dessas amplitudes e ângulos, o FAP inicia a injeção da corrente de compensação no PCC em 37,5 ms, conforme ilustrado na Figura 17(b).

Na Figura 17(c), pode-se observar a evolução da DHT durante o procedimento narrado. O indicador apresenta o valor de 43,9761% antes da compensação e 42,2287% após a compensação. Houve uma redução de 1,7474 pontos percentuais neste caso, visto que, com presença de componentes harmônicos em amplitudes 3 vezes superiores à amplitude

Figura 17 – Caso 5: (a) corrente no PCC, (b) corrente de compensação, (c) DHT.



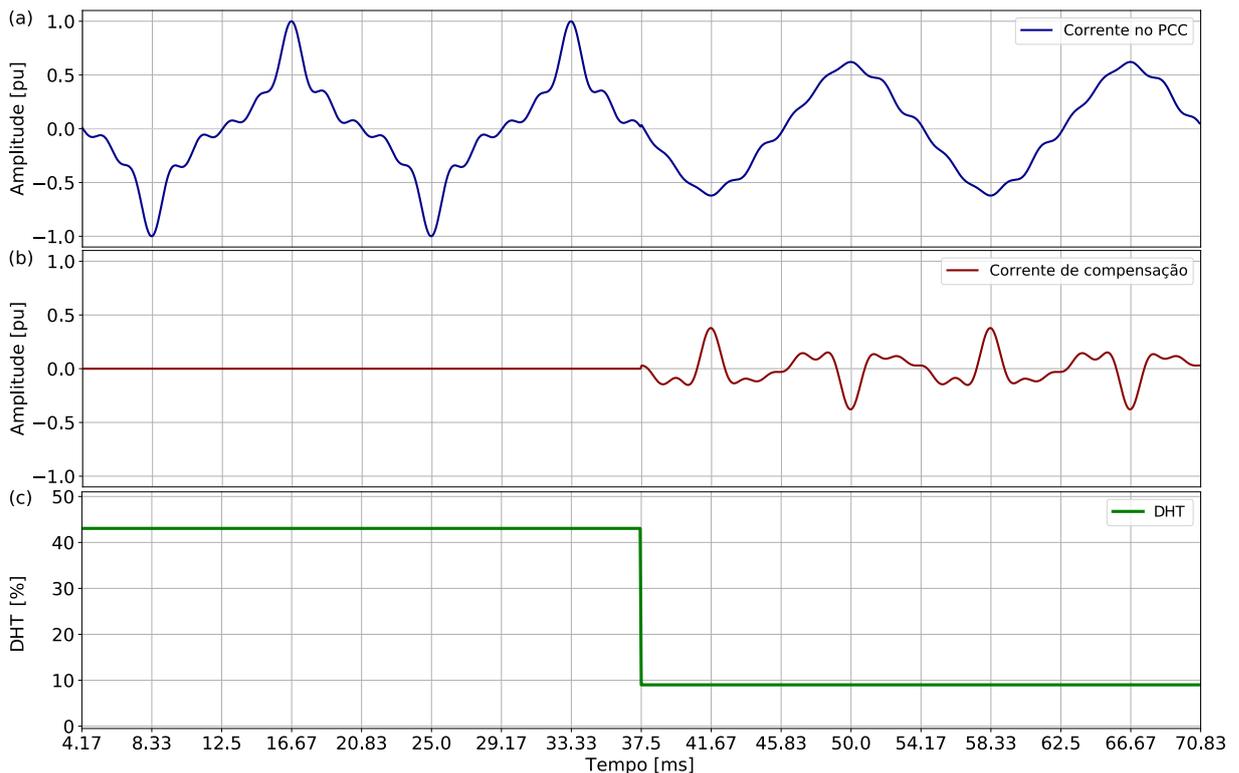
Fonte: Autor.

máxima treinada, a DNN teve seu desempenho prejudicado. Uma solução para aumentar a capacidade de atenuação harmônica seria por meio da expansão do conjunto de amostras e retreinamento da DNN, o que, porém, demandaria uma maior capacidade computacional durante o treinamento. O motivo disso é que a inclusão de novas possibilidades de amplitudes e ângulos de fase aumenta exponencialmente o tamanho do conjunto de amostras por conta das combinações realizadas entre esses valores.

### 5.2.6 Caso 6: Conjunto de Equipamentos de Iluminação 2

Considera-se que a carga CEI2 está conectada ao PCC juntamente com um FAP ideal. A corrente de carga no PCC é apresentada na Figura 18(a), e é composta apenas pelos componentes ímpares até o 9º harmônico, conforme descrito na Tabela 15, desprezando-se, assim, os componentes de 2ª, 11ª e 13ª ordens. A DNN recebe o sinal de um quarto de ciclo da corrente no PCC e estima as amplitudes e ângulos de fase do 3º, 5º, 7º e 9º harmônicos. Utilizando o referencial fornecido pela DNN, o FAP começa a injetar a corrente de compensação no PCC em 37,5 ms, conforme ilustrado na Figura 18(b). Pode-se observar a evolução da DHT na Figura 18(c), na qual percebe-se que o índice corresponde a 43,0545% antes da compensação. A injeção da corrente de compensação provoca uma redução da DHT em 34,0484 pontos percentuais, resultando em um valor de 9,0061%.

Figura 18 – Caso 6: (a) corrente no PCC, (b) corrente de compensação, (c) DHT.



Fonte: Autor.

Com a exclusão do 11<sup>o</sup> e do 13<sup>o</sup> harmônicos da forma de onda de corrente, o desempenho do conjunto de FAP utilizando a DNN como método de estimativa harmônica foi significativamente melhorado, com uma redução de DHT 11 vezes maior do que o caso anterior. Esse método foi capaz de atenuar o indicador para um valor adequado, segundo os padrões estabelecidos na Seção 5.2, podendo, o resultado, ser considerado satisfatório.

### 5.3 Conclusões Parciais

O modelo de DNN para realizar a estimativa de amplitudes e ângulos de fase dos componentes harmônicos de 3<sup>a</sup>, 5<sup>a</sup>, 7<sup>a</sup> e 9<sup>a</sup> ordens foi avaliado neste Capítulo com a utilização de correntes obtidas em Fuchs, Masoum e Ladjevardi (2005), Dugan et al. (2012), Michalec et al. (2021). Os testes mostram que o modelo estima os componentes harmônicos com precisão. As Figuras 8, 9 e 10 demonstram a capacidade de reprodução das formas de onda das correntes por meio das amplitudes e ângulos de fase obtidos por meio da DNN.

É notório que o MAE, em geral, é menor quando as correntes na entrada da DNN são compostas por amplitudes e ângulos de fase de harmônicos treinados e, ainda, quando estes estão dentro da variação utilizada para gerar o conjunto de amostras de treinamento. O desempenho do modelo na presença de amplitudes e ângulos de fase fora da variação treinados também foi satisfatório na maioria dos casos, visto que observou-se uma redução de DHT em todos os estudos de caso quando da aplicação da corrente de compensação gerada por um FAP ideal com harmônicos estimados pela DNN.

Percebe-se que amplitudes e ângulos de fase que não foram usados no processo de treinamento da DNN prejudicam o seu desempenho de estimativa, mas, ainda assim, observou-se redução de DHT em todos os casos estudados. Verifica-se que os resultados obtidos nos testes de estimativa harmônica com a DNN estão de acordo com as conclusões observadas em Temurtas e Temurtas (2011), Jain e Singh (2012), Jain e Singh (2013), Garanayak e Panda (2017), Žnidarec et al. (2019) sobre o uso de redes neurais para realizar estimativas individuais de amplitudes e ângulos de fase de harmônicos e compensação harmônica por meio de FAPs.

A Tabela 17 mostra o resultado de um teste comparativo entre o tempo médio de execução da DNN proposta e da DFT. Esse teste é realizado a partir da estimativa harmônica de 53.465 amostras de formas de onda de corrente. No etapa de avaliação da DNN, as amostras contém um quarto de ciclo (BERNARDINO et al., 2021). Já na etapa de avaliação da DFT, as amostras contém 12 ciclos de onda, conforme recomendado pela IEC 61850 (UCA, 2004). Nota-se que o tempo de estimativa do conteúdo harmônico requerido pela DNN é menor do que o tempo necessário para que a DFT determine o mesmo conteúdo, considerando o tempo médio calculado em 1.000 execuções de cada processo, tanto com a DNN quanto com a DFT, realizados na mesma estrutura computacional.

Tabela 17 – Comparação do tempo médio de 1.000 execuções de DNN e DFT.

<b>Caso</b>	<b>Ciclos de onda</b>	<b>Tempo</b>
DNN	$1/4$	0,4652 s
DFT	12	3,8286 s

Fonte: Autor.



---

## Conclusão

---

O incremento de cargas não-lineares conectadas a redes e microrredes elétricas pode afetar negativamente indicadores de QEE, como a distorção harmônica total, podendo estes extrapolar os limites estabelecidos em normas e recomendações técnicas. Os filtros ativos de potência são utilizados como uma solução para atenuar distorções harmônicas, com o objetivo de melhorar a DHT. Estes equipamentos precisam de uma corrente de referência para gerar a corrente (ou tensão) de compensação. Algumas formas de se obter essa referência podem ser complexas e lentas, o que reduz a efetividade do filtro. Por meio de uma extensa revisão bibliográfica, concluiu-se que as RNAs podem realizar estimativa harmônica em aplicações de melhoria dos indicadores de QEE.

A principal contribuição deste trabalho é a implementação de uma rede neural de aprendizado profundo para estimar, com precisão e seletividade, as amplitudes e ângulos de fase do 3º, 5º, 7º e 9º harmônicos por meio de amostras de um quarto de ciclo de uma forma de onda desconhecida de corrente e/ou tensão. Há relativamente poucos estudos publicados detalhando a implementação de DNNs na mitigação de distúrbios harmônicos. Este trabalho expõe uma metodologia completa para a implementação desse método, desde a geração de amostras para treinamento até a realização de testes avaliativos.

A configuração da DNN com 4 camadas ocultas e 120 neurônios por camada foi definida por meio de uma busca exaustiva por hiper parâmetros capazes de minimizar o erro absoluto médio entre os valores reais de amplitudes e ângulos de fase e os valores estimados. Essa DNN foi treinada com um conjunto de amostras de formas de onda com um quarto de ciclo e frequência amostral de 15,36 kHz, formado por 10.692.864 amostras, que são armazenada em um arquivo de 2,67 GB. No modo de operação, a DNN treinada requer baixo esforço computacional por empregar descomplicadas operações matemáticas no modelo. O arquivo da DNN treinada e pronta para operação tem apenas 662 kB e, em tese, pode ser embarcado para aplicações de mitigação harmônica.

As amplitudes e ângulos de fase utilizados na geração do conjunto de amostras de treinamento poderiam ser incrementadas, mas isso provocaria um aumento exponencial

do número de amostras do conjunto, inviabilizando o treinamento da DNN no computador disponível para realização deste trabalho. Uma solução, passível de implementação em trabalhos futuros, seria a utilização do treinamento em nuvem ou o uso de clusters, com maior capacidade de processamento e memória.

Para justificar o uso de DNNs em processos de regressão, do qual a estimativa de amplitudes e ângulos faz parte, comparou-se este método a outros métodos de regressão geralmente utilizados, e a DNN atingiu o menor erro absoluto médio nos testes, sendo recomendada para realizar a estimativa de conteúdo harmônico.

Os estudos realizados com correntes de cargas obtidas em experimentos de bibliografias relevantes (MICHALEC et al., 2021; FUCHS; MASOUM; LADJEVARDI, 2005; DUGAN et al., 2012) indicam que o modelo de rede neural treinado é capaz de fornecer as amplitudes e ângulos de fase para reprodução de formas de onda, com uma diferença média de amplitudes entre as formas de onda reais e as estimadas de 0,0663 pu. Os resultados ainda indicam que a média dos MAEs relacionados apenas às amplitudes equivalem a 0,0331 pu, enquanto a média dos MAEs relacionados a estimativa de ângulos de fase foi de 0,2373 rad.

Nos estudos de caso, em que o objetivo é atenuar a DHT por meio da injeção de uma corrente de compensação injetada no PCC de uma carga experimental e um FAP ideal com referências harmônicas geradas pela DNN, houve a redução da DHT em todos os casos abordados. O método de estimativa harmônica adaptou-se às situações, sobretudo àquelas em que a corrente de carga era composta pela componente fundamental e harmônicos treinados com amplitudes dentro da faixa utilizada para geração do conjunto de amostras. Houve redução de até 95,63% na DHT (evoluindo de 18,54%, antes da compensação, para 0,81% após a compensação), o que demonstra que esse método pode ser aplicado para compensação harmônica.

A DNN implementada possui limitações em relação às amplitudes e ângulos de fase dos harmônicos contidos nas formas de onda analisada. Por haver uma limitação do tamanho do conjunto de amostras gerada pela capacidade da RAM e pela capacidade de processamento da CPU utilizadas neste trabalho, a operação da DNN dentro da faixa treinada pode ser considerada adequada. A operação com sinais contendo harmônicos cujas amplitudes ou ângulos de fase estejam fora da faixa treinada fica prejudicada, podendo a estimativa dos componentes não ser precisa neste caso. Essa limitação poderia ser atenuada empregando-se um treinamento da DNN com um conjunto de amostras contendo faixas maiores de amplitudes e ângulos de fase, o que gera, entretanto, uma maior capacidade de RAM e CPU.

Os resultados apontam, portanto, que a DNN pode ser usada tanto no monitoramento de redes e microrredes inteligentes quanto em outras aplicações nas quais as técnicas de processamento rápido de dados são cruciais para estimar os componentes harmônicos de amplitudes e ângulos de fase. Em princípio, o método de estimativa harmônica proposto

também poderia ser usado para estimar componentes de tensão, visto que as entradas do modelo recebem um sinal elétrico (preprocessado e normalizado) proveniente de uma forma de onda que pode ser de tensão e/ou corrente. Utilizar essa DNN no estágio operacional de conversores eletrônicos de potência poderia reduzir o tamanho do equipamento em comparação, por exemplo, com métodos de compensação total de harmônicos e com métodos que aplicam controle DQ. A DNN requer menor esforço computacional quando comparada à DFT, por exemplo, por conta das operações matemáticas básicas utilizadas no modelo neural.

## Artigos Advindos deste Trabalho

Este trabalho resultou na publicação do artigo intitulado *Neural-network-based approach applied to harmonic component estimation in microgrids* (BERNARDINO et al., 2021), no 16º Congresso Brasileiro de Eletrônica de Potência (COBEP), que é um dos mais importantes eventos para pesquisadores em eletrônica de potência do hemisfério sul, e é o mais importante e tradicional fórum brasileiro de eletrônica de potência.

Este trabalho também gerou uma contribuição ao artigo *Deep Learning Model to Estimate and Predict the Solar Irradiance in Brazil*, que foi submetido em 15 de março de 2022 a *IEEE Latin America Transactions*, cujos autores são W.A. Souza, K. Tavares, M.F. Castoldi, L.G.R. Bernardino, A.M.S. Alonso e C.F. Nascimento.

Em 25 de abril de 2022, o artigo *Estimador Seletivo de Componentes Harmônicos de Corrente Baseado em Rede Neural Profunda* foi submetido ao XXIV Congresso Brasileiro de Automática - CBA 2022, cujos autores são L.G.R. Bernardino, C.F. Nascimento, W.A. de Souza, A.M.S. Alonso, F.P. Marafão e E.H. Watanabe.

## Trabalhos Futuros

Como trabalhos futuros, pretende-se reduzir ainda mais o MAE obtido pelo modelo de DNN, limitando, assim, a diferença entre as correntes de carga e as correntes estimadas. Além disso, tem-se a intenção de expandir a análise para outras topologias de redes neurais, como redes recorrentes e redes convolucionais, para se avaliar o desempenho destas na estimativa de componentes harmônicos. Tem-se a intenção de ampliar a aplicação de DNNs para outros distúrbios relacionadas à QEE, como o desequilíbrio de tensão. Outras questões para trabalhos futuros estão relacionadas a investigação de técnicas de análise de dados para melhorar o alcance do modelo neural e embarcar o algoritmo proposto nesta dissertação em um hardware.



---

# Referências

---

ABADI, M. et al. Tensorflow: Large-scale machine learning on heterogeneous distributed systems. mar. 2016.

ABDESLAM, D. O. et al. Power harmonic identification and compensation with an artificial neural network method. In: **2006 IEEE International Symposium on Industrial Electronics**. [S.l.]: IEEE, 2006.

ABUD, L. de Melo e. **Modelos computacionais prognósticos de lesões traumáticas do plexo braquial em adultos**. Dissertação (Dissertação de Mestrado) — Instituto de Matemática e Estatística, 2018.

AGGARWAL, C. C. **Neural Networks and Deep Learning**. [S.l.]: Springer International Publishing, 2018. ISBN 3319944622.

AKAGI, H.; WATANABE, E. H.; AREDES, M. **Instantaneous power theory and applications to power conditioning**. Hoboken, N.J. Piscataway, N.J.: Wiley IEEE Press, 2007. ISBN 9780470107614.

ALANIS, A. **Artificial neural networks for engineering applications**. St. Louis, Missouri: Elsevier, 2019. ISBN 9780128182475.

ALCARAZ, R. et al. Comparison of voltage harmonic identification algorithms for three-phase systems. In: **IECON 2006 - 32nd Annual Conference on IEEE Industrial Electronics**. [S.l.: s.n.], 2006. p. 5179–5184.

ALSAIDAN, I. et al. An intelligent approach to active and reactive power control in a grid-connected solar photovoltaic system. **Sustainability**, MDPI AG, v. 13, n. 8, p. 4219, apr 2021.

ANDRADE, L. C. M. de. **Transformada Wavelet e técnicas de inteligência computacional aplicadas à identificação, compressão e armazenamento de sinais no contexto de qualidade da energia elétrica**. Tese (Doutorado) — Universidade de São Paulo (USP), 2017.

ANEEL. Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - Módulo 8 – Qualidade da Energia Elétrica. **PRODIST**, 2021.

ARAUJO, M. A. de. **Metodologia baseada em medidas dispersas de tensão e árvores de decisão para localização de faltas em sistemas de distribuição modernos**. Tese (Doutorado) — Escola de Engenharia de São Carlos, 2017.

- ARAÚJO, M. M. C. d. **Metodologia baseada em redes neurais artificiais para a detecção de danos estruturais**. Tese (Doutorado em Engenharia Elétrica) — Universidade de Brasília, 2017. Disponível em: <<https://repositorio.unb.br/handle/10482/32151>>.
- ARRILLAGA, J.; WATSON, N. R. **Power System Harmonics**. [S.l.]: John Wiley & Sons, 2004. ISBN 9780470871218.
- ASIMINOAEL, L.; BLAABJERG, F.; HANSEN, S. Detection is key - harmonic detection methods for active power filter applications. *Institute of Electrical and Electronics Engineers (IEEE)*, v. 13, n. 4, p. 22–33, jul 2007.
- BA, J. L.; KIROS, J. R.; HINTON, G. E. **Layer Normalization**. [S.l.]: arXiv, 2016.
- BAITHA, A.; GUPTA, N. A comparative analysis of passive filters for power quality improvement. *In: 2015 International Conference on Technological Advancements in Power and Energy (TAP Energy)*. [S.l.: s.n.], 2015. p. 327–332.
- BANA, P. R. et al. Recently developed reduced switch multilevel inverter for renewable energy integration and drives application: Topologies, comprehensive analysis and comparative evaluation. *IEEE Access*, v. 7, p. 54888–54909, 2019.
- BEAZLEY, D. **Python essential reference**. Upper Saddle River, NJ: Addison-Wesley, 2009. ISBN 9780672329784.
- BERNARDINO, L. G. R. et al. Neural-network-based approach applied to harmonic component estimation in microgrids. *In: 2021 Brazilian Power Electronics Conference (COBEP)*. [S.l.: s.n.], 2021. p. 1–6.
- BRAGA, A. d. P.; CARVALHO, A. P. d. L. F. d.; LUDEMIR, T. B. **Redes neurais artificiais : teoria e aplicações**. Rio de Janeiro: LTC Editora, 2007. ISBN 9788521615644.
- ÇETIN, O.; DALCALI, A.; TEMURTAŞ, F. A comparative study on parameters estimation of squirrel cage induction motors using neural networks with unmemorized training. *Engineering Science and Technology, an International Journal*, Elsevier BV, v. 23, n. 5, p. 1126–1133, oct 2020.
- CHANG, G. W.; CHEN, C.-I. An accurate time-domain procedure for harmonics and interharmonics detection. *IEEE Transactions on Power Delivery*, Institute of Electrical and Electronics Engineers (IEEE), v. 25, n. 3, p. 1787–1795, jul 2010.
- CHEN, C. et al. Deepdriving: Learning affordance for direct perception in autonomous driving. *In: 2015 IEEE International Conference on Computer Vision (ICCV)*. [S.l.: s.n.], 2015. p. 2722–2730.
- CHOLLET, F. **Deep Learning with Python**. [S.l.]: Manning, 2017. ISBN 1617294438.
- CHOLLET, F. et al. **Keras**. 2015. Disponível em: <<https://keras.io>>.
- CIABATTONI, L. et al. AI-powered home electrical appliances as enabler of demand-side flexibility. *IEEE Consumer Electronics Magazine*, Institute of Electrical and Electronics Engineers (IEEE), v. 9, n. 3, p. 72–78, may 2020.

- DAI, J.; VENAYAGAMOORTHY, G. K.; HARLEY, R. G. Harmonic identification using an echo state network for adaptive control of an active filter in an electric ship. In: **2009 International Joint Conference on Neural Networks**. [S.l.]: IEEE, 2009.
- DOVGUN, V.; EGOROV, D.; TEMERBAEV, S. Passive filtering systems for multipulse rectifiers. In: **2020 International Ural Conference on Electrical Power Engineering (UralCon)**. [S.l.: s.n.], 2020. p. 235–239.
- DUGAN, R. C. et al. **Electrical Power Systems Quality, Third Edition**. [S.l.]: MCGRAW HILL BOOK CO, 2012. ISBN 0071761551.
- ESTEVA, A. et al. Dermatologist-level classification of skin cancer with deep neural networks. **Nature**, Springer Science and Business Media LLC, v. 542, n. 7639, p. 115–118, jan 2017.
- FAINGNAERT, T.; BESARD, T.; SUTTER, B. D. Flexible performant gemm kernels on gpus. **IEEE Transactions on Parallel and Distributed Systems**, v. 33, n. 9, p. 2230–2248, 2022.
- FARIA, J. et al. Power management control strategy based on artificial neural networks for standalone PV applications with a hybrid energy storage system. **Energies**, MDPI AG, v. 12, n. 5, p. 902, mar 2019.
- FERREIRA, L. R. A. et al. Analysis of harmonic and interharmonic components by using an improved recursive algorithm. In: **2019 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)**. [S.l.: s.n.], 2019. p. 1–6.
- FLORES-GARRIDO, J. L.; SALMERÓN, P.; GÓMEZ-GALÁN, J. A. Nonlinear loads compensation using a shunt active power filter controlled by feedforward neural networks. **Applied Sciences**, MDPI AG, v. 11, n. 16, p. 7737, aug 2021.
- FUCHS, E.; MASOUM, M.; LADJEVARDI, M. Effects on distribution feeders from electronic loads based on future peak-load growth, part i: Measurements. In: **Proceedings of the IASTED International Conference on Power and Energy Systems (EuroPES 2005)**. [S.l.: s.n.], 2005. p. 449–454.
- FUCHS, E.; MASOUM, M. A. S. **Power Quality in Power Systems and Electrical Machines**. [S.l.]: Elsevier Science & Techn., 2015.
- GARANAYAK, P.; PANDA, G. An adaptive linear neural network with least mean m-estimate weight updating rule employed for harmonics identification and power quality monitoring. **Transactions of the Institute of Measurement and Control**, SAGE Publications, v. 40, n. 6, p. 1936–1949, mar 2017.
- GELVES, J. J. P. **Lógica Fuzzy e redes neurais aplicadas para previsão de curvas de carga de chuveiros elétricos em programas de eficiência energética no Brasil**. Tese (Doutorado em Engenharia Mecânica) — Universidade Estadual de Campinas, 2017. Disponível em: <<http://repositorio.unicamp.br/jspui/handle/REPOSIP/322819>>.
- GHAZANFARPOUR, B. et al. Adaptive unified neural network for dynamic power quality compensation. In: **2013 IEEE 7th International Power Engineering and Optimization Conference (PEOCO)**. [S.l.]: IEEE, 2013.

- GLOT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. In: TEH, Y. W.; TITTERINGTON, M. (Ed.). **Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics**. Chia Laguna Resort, Sardinia, Italy: PMLR, 2010. (Proceedings of Machine Learning Research, v. 9), p. 249–256. Disponível em: <<https://proceedings.mlr.press/v9/glot10a.html>>.
- GONG, R.; RUAN, T. A new convolutional network structure for power quality disturbance identification and classification in micro-grids. **IEEE Access**, Institute of Electrical and Electronics Engineers (IEEE), v. 8, p. 88801–88814, 2020.
- GRUS, J. **Data Science do Zero**. S.l.: Alta Books, 2016. ISBN 9788576089988.
- GU, J. et al. Tiresias: A {GPU} cluster manager for distributed deep learning. In: **16th USENIX Symposium on Networked Systems Design and Implementation (NSDI 19)**. [S.l.: s.n.], 2019. p. 485–500.
- GUPTA, S. et al. Adaptive sampling-based artificial neural network for surrogate modeling. In: **AIAA SCITECH 2022 Forum**. [S.l.]: American Institute of Aeronautics and Astronautics, 2022.
- HAGAN, M.; MENHAJ, M. Training feedforward networks with the marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989–993, 1994.
- HAN, Y. et al. Study on a novel approach to active power filter control using neural network-based harmonic identification scheme. **Electrical Engineering**, Springer Science and Business Media LLC, v. 91, n. 6, p. 313–325, nov 2009.
- HARRIS, C. R. et al. Array programming with NumPy. **Nature**, Springer Science and Business Media LLC, v. 585, n. 7825, p. 357–362, sep 2020.
- HAYKIN, S. **Neural networks and learning machines**. New York: Prentice Hall/Pearson, 2009. ISBN 9780131471399.
- HE, J. et al. Simultaneous microgrid voltage and current harmonics compensation using coordinated control of dual-interfacing converters. **IEEE Transactions on Power Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 32, n. 4, p. 2647–2660, apr 2017.
- HINTON, G. et al. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. **IEEE Signal Processing Magazine**, v. 29, n. 6, p. 82–97, 2012.
- IEC. IEC standard for photovoltaic (pv) systems - characteristics of the utility interface. **IEC 61727:2004**, p. 1–23, 2004.
- \_\_\_\_\_. IEC standard for electromagnetic compatibility (emc) - part 3-2: Limits - limits for harmonic current emissions (equipment input current  $\leq 16$  a per phase). **IEC 61000-3-2:2018**, p. 1–73, 2018.
- IEEE. Ieee recommended practice and requirements for harmonic control in electric power systems. **IEEE Std 519-2014 (Revision of IEEE Std 519-1992)**, p. 1–29, 2014.

\_\_\_\_\_. Ieee standard for interconnection and interoperability of distributed energy resources with associated electric power systems interfaces. **IEEE Std 1547-2018 (Revision of IEEE Std 1547-2003)**, p. 1–138, 2018.

\_\_\_\_\_. Ieee recommended practice for monitoring electric power quality. **IEEE Std 1159-2019 (Revision of IEEE Std 1159-2009)**, p. 1–98, 2019.

JAIN, S. K.; SINGH, S. N. ESPRIT assisted artificial neural network for harmonics detection of time-varying signals. In: **2012 IEEE Power and Energy Society General Meeting**. [S.l.]: IEEE, 2012.

\_\_\_\_\_. Fast harmonic estimation of stationary and time-varying signals using EA-AWNN. **IEEE Transactions on Instrumentation and Measurement**, Institute of Electrical and Electronics Engineers (IEEE), v. 62, n. 2, p. 335–343, 02 2013.

\_\_\_\_\_. Low-order dominant harmonic estimation using adaptive wavelet neural network. **IEEE Transactions on Industrial Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 61, n. 1, p. 428–435, 1 2014.

JIA, F. et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. **Mechanical Systems and Signal Processing**, Elsevier BV, v. 72-73, p. 303–315, may 2016.

KALAIR, A. et al. Review of harmonic analysis, modeling and mitigation techniques. **Renewable and Sustainable Energy Reviews**, Elsevier BV, v. 78, p. 1152–1187, oct 2017.

KERAS. **Keras API reference**. 2021. Available online: <<https://keras.io/api/>>. Accessed on 22 February 2022.

KEY, S. et al. Bayesian deep neural network to compensate for current transformer saturation. **IEEE Access**, v. 9, p. 154731–154739, 2021.

KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. dez. 2014.

KLUYVER, T. et al. Jupyter notebooks – a publishing format for reproducible computational workflows. In: LOIZIDES, F.; SCHMIDT, B. (Ed.). **Positioning and Power in Academic Publishing: Players, Agents and Agendas**. [S.l.], 2016. p. 87 – 90.

KUMAR, N.; SINGH, B.; PANIGRAHI, B. K. 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**, Institute of Electrical and Electronics Engineers (IEEE), v. 15, n. 6, p. 3732–3742, 6 2019.

KUMAR, R.; BANSAL, H. O. Real-time implementation of adaptive PV-integrated SAPF to enhance power quality. **International Transactions on Electrical Energy Systems**, Hindawi Limited, v. 29, n. 5, p. e12004, 5 2019.

KUMAR, S. et al. Energy load forecasting using deep learning approach-LSTM and GRU in spark cluster. In: **2018 Fifth International Conference on Emerging Applications of Information Technology (EAIT)**. [S.l.]: IEEE, 2018.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Springer Science and Business Media LLC, v. 521, n. 7553, p. 436–444, may 2015.

LIMA, M. A. A. **Uma nova metodologia para análise da qualidade da energia elétrica sob condições de ocorrência de múltiplos distúrbios**. Tese (Doutorado) — Universidade de São Paulo (USP), 2013.

LIN, H. C. Intelligent neural network-based fast power system harmonic detection. **IEEE Transactions on Industrial Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 54, n. 1, p. 43–52, feb 2007.

\_\_\_\_\_. Power harmonics and interharmonics measurement using recursive group-harmonic power minimizing algorithm. **IEEE Transactions on Industrial Electronics**, Institute of Electrical and Electronics Engineers (IEEE), v. 59, n. 2, p. 1184–1193, feb 2012.

LIU, H. et al. Research on design of dc filter systems of multiterminal dc transmission systems. In: **2020 4th International Conference on HVDC (HVDC)**. [S.l.: s.n.], 2020. p. 46–51.

MANITO, A. et al. Evaluating harmonic distortions on grid voltages due to multiple nonlinear loads using artificial neural networks. **Energies**, MDPI AG, v. 11, n. 12, p. 3303, nov 2018.

MENDES, E.; MOSLEY, N. Comparing effort prediction models for web design and authoring using boxplots. In: **Proceedings of 24th Australian Computer Science Conference. ACSC 2001**. [S.l.: s.n.], 2001. p. 125–133.

MICHALEC, Ł. et al. Impact of harmonic currents of nonlinear loads on power quality of a low voltage network—review and case study. **Energies**, MDPI AG, v. 14, n. 12, p. 3665, jun 2021.

NASCIMENTO, C. F. et al. Harmonic distortion monitoring for nonlinear loads using neural-network-method. **Applied Soft Computing**, Elsevier BV, v. 13, n. 1, p. 475–482, jan 2013.

\_\_\_\_\_. Analysis of noncharacteristic harmonics generated by voltage-source converters operating under unbalanced voltage. **IEEE Transactions on Power Delivery**, Institute of Electrical and Electronics Engineers (IEEE), v. 32, n. 2, p. 951–961, apr 2017.

NASCIMENTO, C. F. do. **Determinação do conteúdo harmônico de corrente baseada em redes neurais artificiais para cargas não-lineares monofásicas**. Tese (Doutorado em Engenharia Elétrica) — Universidade de São Paulo, 2007.

NASCIMENTO, C. F. do et al. Harmonic identification using parallel neural networks in single-phase systems. **Applied Soft Computing**, Elsevier BV, v. 11, n. 2, p. 2178–2185, mar 2011.

NGUYEN, N. K. et al. Harmonics identification with artificial neural networks: Application to active power filtering. **International Journal of Emerging Electric Power Systems**, Walter de Gruyter GmbH, v. 12, n. 5, aug 2011.

NUMPY. **NumPy Reference**. 2022. Available online: <<https://numpy.org/doc/stable/reference/>>. Accessed on 22 February 2022.

OH, S.; KIM, K.; SEO, E. A dynamic scaling scheme of cloud-based dnn training clusters. In: **2020 IEEE International Conference on Smart Cloud (SmartCloud)**. [S.l.: s.n.], 2020. p. 165–168.

PAL, S.; MITRA, S. Multilayer perceptron, fuzzy sets, and classification. **IEEE Transactions on Neural Networks**, v. 3, n. 5, p. 683–697, 1992.

PARK, Y.-S.; LEK, S. Artificial neural networks. In: **Developments in Environmental Modelling**. [S.l.]: Elsevier, 2016. p. 123–140.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

PUTHENPURAKEL, S. P.; SUBADHRA, P. R. Identification and classification of microgrid disturbances in a hybrid distributed generation system using wavelet transform. In: **2016 International Conference on Next Generation Intelligent Systems (ICNGIS)**. [S.l.]: IEEE, 2016.

**Python 3.8.12 documentation**. Accessed on 22 February 2022.

RAY, P.; RAY, P. K.; DASH, S. K. Power quality enhancement and power flow analysis of a pv integrated upqc system in a distribution network. **IEEE Transactions on Industry Applications**, v. 58, n. 1, p. 201–211, 2022.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. **Neural Networks**, Elsevier BV, v. 61, p. 85–117, jan 2015.

Scikit Learn. **User Guide**. 2021. Available online: <[https://scikit-learn.org/stable/user\\_guide.html](https://scikit-learn.org/stable/user_guide.html)>. Accessed on 22 February 2022.

SHI, J.; LIU, Z. Harmonic detection technology for power grids based on adaptive ensemble empirical mode decomposition. **IEEE Access**, v. 9, p. 21218–21226, 2021.

SHUKL, P.; SINGH, B. Delta-bar-delta neural-network-based control approach for power quality improvement of solar-pv-interfaced distribution system. **IEEE Transactions on Industrial Informatics**, v. 16, n. 2, p. 790–801, 2020.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. [S.l.]: Artliber, 2019. ISBN 9788588098879.

SILVA, K. M.; NASCIMENTO, F. A. O. Modified DFT-based phasor estimation algorithms for numerical relaying applications. **Institute of Electrical and Electronics Engineers (IEEE)**, v. 33, n. 3, p. 1165–1173, jun 2018.

SINGH, B.; AL-HADDAD, K.; CHANDRA, A. A review of active filters for power quality improvement. **IEEE Transactions on Industrial Electronics**, v. 46, n. 5, p. 960–971, 1999.

SINGH, B. et al. Implementation of neural-network-controlled three-leg VSC and a transformer as three-phase four-wire DSTATCOM. **IEEE Transactions on Industry Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 47, n. 4, p. 1892–1901, 07 2011.

- SOUZA, W. A. et al. Selection of features from power theories to compose NILM datasets. **Advanced Engineering Informatics**, Elsevier BV, v. 52, p. 101556, apr 2022.
- SRIVASTAVA, A. K.; TIWARI, A. N.; SINGH, S. N. Harmonic/inter-harmonic estimation: Key issues and challenges. In: **2021 IEEE 6th International Conference on Computing, Communication and Automation (ICCCA)**. [S.l.: s.n.], 2021. p. 842–853.
- SUPRIYA, P.; NAMBIAR, P. Review of harmonic source identification techniques. **International Review of Electrical Engineering**, v. 7, p. 4525–4531, 06 2012.
- SZE, V. et al. Efficient processing of deep neural networks: A tutorial and survey. **Proceedings of the IEEE**, v. 105, n. 12, p. 2295–2329, 2017.
- TANG, J.; DENG, C.; HUANG, G.-B. Extreme learning machine for multilayer perceptron. **IEEE Transactions on Neural Networks and Learning Systems**, v. 27, n. 4, p. 809–821, 2016.
- TEMURTAS, F. et al. Harmonic detection using feed forward and recurrent neural networks for active filters. **Electric Power Systems Research**, Elsevier BV, v. 72, n. 1, p. 33–40, nov 2004.
- TEMURTAS, H.; TEMURTAS, F. An application of neural networks for harmonic coefficients and relative phase shifts detection. **Expert Systems with Applications**, v. 38, n. 4, p. 3446–3450, 2011. ISSN 0957-4174.
- TEODORESCU, R.; LISERRE, M.; RODRIGUEZ, P. **Grid Converters for Photovoltaic and Wind Power Systems**. [S.l.]: John Wiley & Sons, 2011. ISBN 0470057513.
- THEODORIDIS, S. **Machine Learning**. [S.l.]: Elsevier LTD, Oxford, 2020. ISBN 0128188030.
- TREMBLAY, J. et al. Training deep networks with synthetic data: Bridging the reality gap by domain randomization. In: **2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)**. [S.l.: s.n.], 2018. p. 1082–10828.
- UCA. **Implementation Guideline for Digital Interface to Instrument Transformers Using IEC 61850-9-2**. 2004. Available online: <<https://iec61850.ucaiug.org/Implementation%20Guidelines/Forms/AllItems.aspx>>. Accessed on 16 October 2021.
- UCAR, F. et al. Bundle extreme learning machine for power quality analysis in transmission networks. **Energies**, MDPI AG, v. 12, n. 8, p. 1449, apr 2019.
- VERMA, P. K.; GOSWAMI, G. Power quality issues associated with smart grid: A review. In: **2021 10th International Conference on System Modeling Advancement in Research Trends (SMART)**. [S.l.: s.n.], 2021. p. 622–627.
- VINAYAGAM, A. et al. An ensemble approach of classification model for detection and classification of power quality disturbances in PV integrated microgrid network. **Applied Soft Computing**, Elsevier BV, v. 106, p. 107294, jul 2021.

- XIA, Y. et al. A complex least squares enhanced smart DFT technique for power system frequency estimation. *Institute of Electrical and Electronics Engineers (IEEE)*, v. 32, n. 3, p. 1270–1278, jun 2017.
- XU, J. et al. ANN-based control method implemented in a voltage source converter for industrial micro-grid. In: **2011 Sixth International Conference on Bio-Inspired Computing: Theories and Applications**. [S.l.]: IEEE, 2011.
- ZHENG, Z. et al. A transient harmonic current protection scheme for HVDC transmission line. *Institute of Electrical and Electronics Engineers (IEEE)*, v. 27, n. 4, p. 2278–2285, oct 2012.
- ZHU, T. X. Exact harmonics/interharmonics calculation using adaptive window width. **IEEE Transactions on Power Delivery**, *Institute of Electrical and Electronics Engineers (IEEE)*, v. 22, n. 4, p. 2279–2288, oct 2007.
- ŽNIDAREC, M. et al. Harmonic distortion prediction model of a grid-tie photovoltaic inverter using an artificial neural network. **Energies**, MDPI AG, v. 12, n. 5, p. 790, feb 2019.