

Desenvolvimento de um Classificador Inteligente para Variações de Tensão de Curta Duração

Gabriel Humberto Andrade Freitas * Danilo Hernane Spatti **

* *Departamento de Engenharia Elétrica e de Computação, Escola de Engenharia de São Carlos - Universidade de São Paulo, SP, (e-mail: gabhaf123@hotmail.com).*

** *Departamento de Sistemas de Computação, Instituto de Ciências Matemáticas e de Computação - Universidade de São Paulo, SP (e-mail: spatti@icmc.usp.br)*

Abstract: Nowadays, keep Power Quality (PQ) has become a necessary factor in many social and economic environments, becoming a concern not only of engineers and regulatory agencies, but also of system agents, consumers and companies. Besides, the power quality disturbances presence it's more often due to the addition of new kinds of loads in the electric system, those with non-linear features, from converters, new kinds of generation (photovoltaic and eolic), etc. In this bias, the developed work presents an identification and classification method for the PQ issues using an Artificial Neural Network (ANN) Multilayer Perceptron (MLP); whose inputs are a reduced set of electrical features extracted from these signal's samples. The system, trained and validated, presented an excellent classification performance for four signal patterns (reference signal plus three disturbances) using five attributes as inputs.

Resumo: Atualmente, a garantia da Qualidade de Energia elétrica (QEE) vem se tornando um fator indispensável em diversos setores sociais e econômicos, fazendo-se preocupação não somente de engenheiros e órgãos reguladores, mas de agentes do sistema, consumidores e empresas. Ademais, a presença de distúrbios de qualidade de energia está cada vez mais frequente devido à adição de novos tipos de cargas no sistema elétrico, estas com características não lineares, provenientes de conversores, novos tipos de geração (fotovoltaica e eólica), entre outros. Neste viés, o trabalho desenvolvido apresenta um método de identificação e classificação destes distúrbios utilizando uma rede neural artificial Perceptron Multicamadas (PMC); cujas entradas são um conjunto reduzido de características elétricas extraídas a partir amostras desses sinais. O sistema, treinado e validado, apresentou uma performance de excelência para a classificação de quatro padrões de sinais (sinal de referência mais três distúrbios) utilizando cinco atributos como entradas.

Keywords: Power Quality (PQ); Electrical Disturbances; Classification; Artificial Neural Networks (ANN); Electrical Signal Processing

Palavras-chaves: Qualidade de Energia Elétrica (QEE); Distúrbios elétricos; Classificação; Redes Neurais Artificiais (RNA); Processamento de sinais elétricos

1. INTRODUÇÃO

Atualmente, a Qualidade de Energia Elétrica (QEE), ciência responsável pelo estudo dos problemas e distúrbios relacionados à desvios de tensão, corrente ou frequência; vem se tornando um fator indispensável visto que é intrínseca ao funcionamento de diversos setores da economia, principalmente os setores industrial, comercial e de serviços, tornando-se preocupação não somente de engenheiros e órgãos reguladores, mas de agentes do sistema, consumidores e empresas, como menciona de Araújo et al. (2016).

E a preocupação com a garantia da QEE foi revivida devido aos danos oriundos da inserção de novos tipos de cargas no sistema, estas de características não lineares tais como dispositivos semicondutores chaveados, inversores e controladores; novas formas de geração, tais como a eólica e fotovoltaica, entre outros, implicando em consequências

tais como queima ou danos de eletrônicos e sistemas computadorizados, inoperância de equipamentos, perda do conjugado de motores, decaimento do fator de potência, o aquecimento de condutores, queima de fusíveis (Bollen and Gu, 2006).

A detecção precisa dos fenômenos de QEE é essencial para a solução dos distúrbios e garantida da qualidade do produto. No entanto, é uma tarefa que exige a utilização de equipamentos de alto custo e que são limitados quanto aos recursos que oferecem, cabendo ao profissional o estudo dos gráficos e veredito final.

Neste íterim, para a resolução desta questão, é necessário uma estratégia de classificação que tenha uma boa relação custo-benefício entre complexidade computacional e qualidade da resposta. Sistemas padronizadores possuem como etapas a extração de parâmetros e a aplicação de

um algoritmo que realize a detecção baseada nestes, tal como propõe Pinho and Garcia (2020) e Monteiro et al. (2019) através de novas métricas de características e tal como propõe de Paula Faria et al. (2019) em relação a novos métodos de classificação.

Então, a motivação da realização deste trabalho se dá na problemática do método de classificação, visando assim propor, primeiramente, um método de extração de atributos dos sinais que seja pequeno e completo o suficiente para caracterizá-los e permitir classificação e, em segunda instância, propor um classificador de padrões baseado na utilização de um sistema inteligente Perceptron Multicamadas (PMC), capaz de identificar, através dos atributos, a classe de distúrbios de QEE do qual o sinal faz parte.

2. DEFINIÇÃO DO PROBLEMA

A literatura que aborda estudos sobre os eventos que perturbam o funcionamento padrão dos sistemas elétricos de potência classifica de formas distintas os eventos. Em contraponto à ANEEL (2021), no padrão IEEE (1995), os fenômenos são divididos em cinco grupos distintos: transitórios (impulsivo e oscilatório); variações de curta duração (interrupção, afundamento e elevação); variações na frequência; variações de longa duração (subtensões e sobretensões) e variações de regime permanente (harmônicos, notch e flicker). No entanto, estão de acordo ao estabelecer uma padronização do evento baseada na duração e amplitude do fenômeno.

Na literatura há diversos trabalhos e métodos distintos que abordam soluções para a classificação automática de fenômenos de QEE. Tal como em Alcântara et al. (2019), a maior parte dos métodos consiste de duas etapas: etapa de extração de parâmetros, onde há a transformação dos dados em janelas ou métricas calculáveis no domínio da frequência ou no domínio do tempo que são capazes de promover resalto da diferença entre os sinais distorcidos; e a etapa de classificação, cujas ferramentas são destinadas à separar os dados em conjuntos específicos de saída. Como bem define também Mahela et al. (2014), a estrutura dos conjuntos padronizadores obedece uma sequência de pré-processamento e pós-processamento, tal como mostra a figura 1

A etapa de pré-processamento é classicamente realizada de duas formas: a segmentação do sinal e a extração de métricas do sinal (janelado ou não) no domínio da frequência ou do tempo; podendo ser realizadas distintamente ou em conjunto. Há uma vasta gama de trabalhos que fazem uso da transformada wavelet Decanini et al. (2015), transformada de Fourier Discreta ou Transformada Rápida de Fourier Souza et al. (2014) e outros recursos de extração de características do sinal no domínio da frequência. Já trabalhos como de Araújo et al. (2016) utilizam-se de janelamento de sinal para compor o vetor de entrada do sistema de classificação. Mesmo em Pinho and Garcia (2020), é possível destacar a miscelânea entre a uso de atributos temporais e do espectro do sinal.

No pós-processamento, é comum a utilização de sistemas inteligentes na forma de classificadores, tais como as redes neurais artificiais (RNA) e suas derivações Fortunato et al. (2019); de Araújo et al. (2016); Souza et al. (2014),

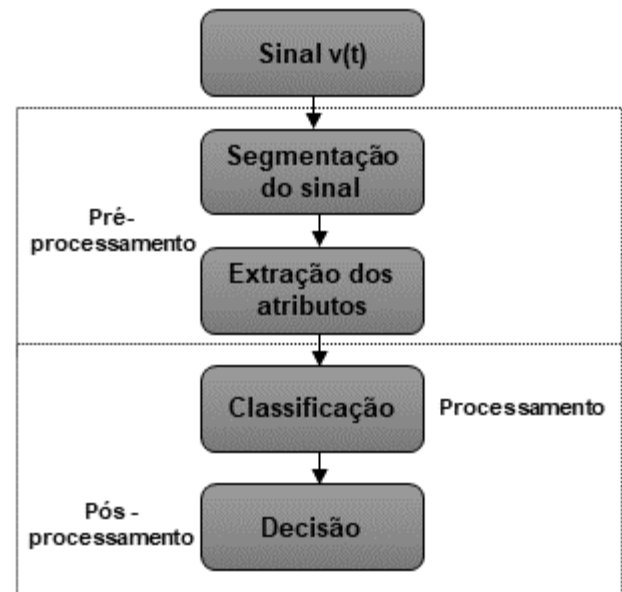


Figura 1. Diagrama de fluxo de projeto

sistemas fuzzy Mahela et al. (2020) e sistemas neurofuzzy Reddy et al. (2021). No entanto, técnicas como a máquina de vetor suporte (MVS) de Paula Faria et al. (2019) também se fazem presentes.

Diante disso, a proposição de um sistema classificador reside não só na escolha entre combinações de técnicas de pré e pós-processamento, mas sim na escolha de uma melhor arquitetura de pré-processamento que seja capaz de aliar a robustez à simplicidade, mantendo, ou até mesmo melhorando, os resultados obtidos da saída do sistema de pós-processamento.

3. METODOLOGIA

O desenvolvimento deste projeto constou de três etapas distintas: Etapa 1: Desenvolvimento da base de dados de sinais de tensão para treinamento e validação da rede neural utilizando o software MATLAB®; Etapa 2: Definição e extração dos atributos dos sinais de tensão; Etapa 3: Desenvolvimento das duas arquiteturas de solução baseadas em PMC. Na etapa 1, à priori, foram criados sinais de referência, cada qual com a frequência de 60Hz e tensão que poderia variar entre (0.9 p.u. e 1.1 p.u.) ANEEL (2021). A amostragem dos sinais foi feita em 3kHz devido à determinações da ANEEL (2021), que estipula como mínimo a estimação de distúrbios de frequência de 25ª harmônica. Logo, pelo Teorema de Nyquist:

$$f_{amostragem} \geq 2(60Hz)(25) = 3kHz \quad (1)$$

Todos os sinais gerados tiveram 4 segundos de duração, sendo capazes de captar todos os VTCDs momentâneos, cuja faixa temporal está entre um ciclo de tensão e 3 segundos de ocorrência de distorção. No total, foram gerados 1600 sinais, sendo 50% para treinamento e 50% para validação sendo que os distúrbios criados foram distribuídos uniformemente em 25% cada, sendo estas criadas a partir de interferências no sinal de referência.

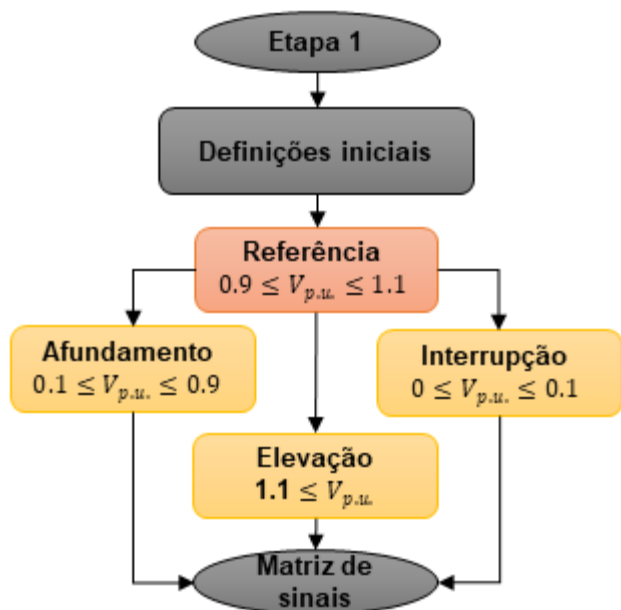


Figura 2. Geração e amostragem dos sinais

Para a etapa 2, foram escolhidos cinco atributos comuns na literatura para análise de sinais temporais de diversas áreas. Considerando $v[n]$ o sinal amostrado de tensão, f_s a frequência de amostragem

- Valor de pico V_{pico} : a obtenção do valor de pico do sinal, muito utilizada nos estudos de máquinas elétricas, circuitos elétricos e sistemas de potência, foi escolhida como atributo por ser adequada para identificar distorções que são maiores que a tensão de referência.

$$V_{pico} = \max(v[n]) \text{ p.u.} \quad (2)$$

- Excursão de tensão ΔV : o valor de excursão do sinal, frequentemente adotada em análise de circuitos elétricos Boylestad (2012) e eletrônicos Boylestad (2013), serve para identificar se os valores de tensão estão em um intervalo maior ou menor que o sinal de referência adotado.

$$\Delta V = \max(v[n]) - \min(v[n]) \text{ p.u.} \quad (3)$$

- Energia do sinal E : o cálculo de energia do sinal, muito utilizado nos estudos de transmissão de sinais e telecomunicações, foi escolhido como atributo pelo fato de indicar desvios no padrão de energia do sinal de referência, tal como em Pinho and Garcia (2020).

$$E = \sum_{n=1}^{\infty} \frac{|v[n]|^2}{f_s} \text{ J} \quad (4)$$

- Valor eficaz V_{ef} : análise de valor eficaz (ou RMS – root mean square) é de uso comum em processamento de sinais dos sistemas elétricos de potência e circuitos elétricos Boylestad (2012), indicando o valor de corrente ou tensão que produz a mesma quantidade de potência que uma fonte CC. Seu aumento ou diminuição podem indicar a presença de anomalias na onda.

$$V_{ef} = \sqrt{\frac{1}{N} \sum_{n=1}^{\infty} |v[n]|^2} V_{rms} \quad (5)$$

- Amplitude do evento de VTCD V_e : a análise da amplitude do evento de VTCD é embasada em critérios provenientes da ANEEL (2021), sendo este um indicador da porcentagem da tensão residual do distúrbio.

$$V_e = \frac{V_{residual}}{V_{ref}} 100 \quad (6)$$

Após o sistema realizar a extração dessas métricas, é necessário indicar a classe à qual o sinal pertence para assim ser possível realizar um treinamento supervisionado. Para isso, foram adicionadas 4 colunas na matriz de características, estas possuindo apenas valores binários (1 ou 0) que indicam o pertencimento (1) ou não (0) a uma das 4 classes. O esquema que mostra o processo da etapa 2 está na figura 3

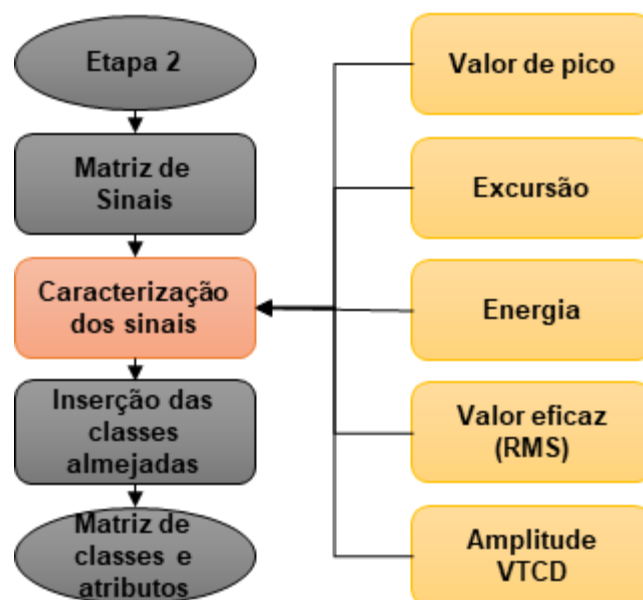


Figura 3. Esquema indicativo da etapa 2

A rede neural escolhida para a fase de processamento é o Perceptron Multicamadas. Este é pertencente à arquitetura feedforward de camadas múltiplas, com treinamento supervisionado de algoritmo backpropagation. Apresenta grande versatilidade visto que produz resultados de excelência operando como aproximador de funções, reconhecimento de padrões, controle e otimização de processos e previsão de séries temporais. da Silva et al. (2010)

Serão feitas duas propostas da solução para processamento e classificação:

- rede com 5 entradas (atributos) e 4 saídas (4 classes), tal como mostrado na figura 4
- 4 redes PMC contendo, cada uma, 5 entradas (atributos) e uma saída binária, indicando o pertencimento ou não à cada classe, tal como mostrado na figura 5

Ambas as soluções utilizaram o algoritmo de treinamento Levenberg-Marquardt e funções de ativação tangente hi-

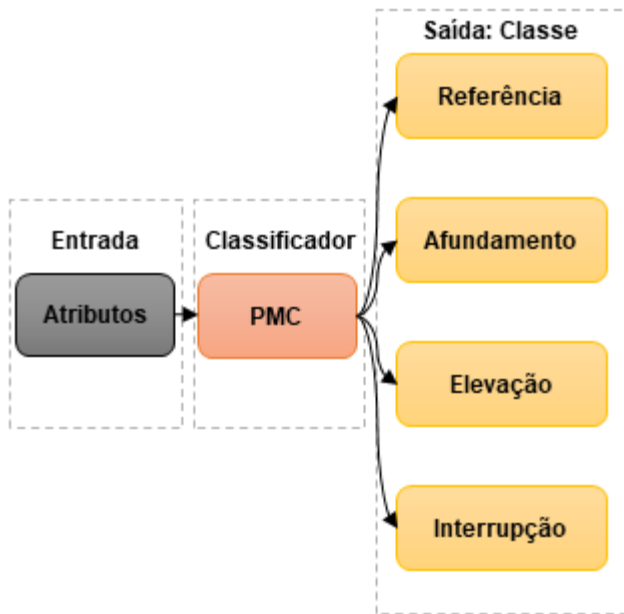


Figura 4. Classificador composto de uma rede com 4 saídas

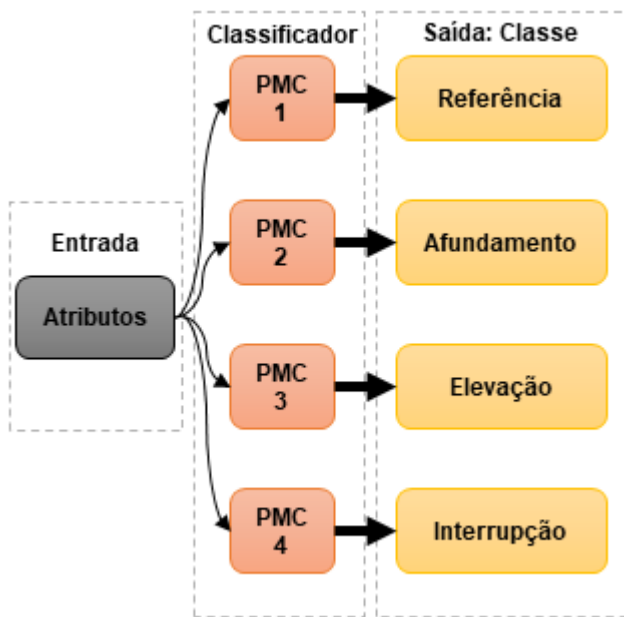


Figura 5. Classificador composto de 4 redes com uma saída perbólica. No entanto, buscou-se encontrar a melhor estrutura de camadas neurais para cada situação.

A seguinte tabela 1 identifica a forma como os distúrbios foram organizados nas redes neurais desenvolvidas, de forma que a rede identificada como PMC refere-se à com 4 saídas e as redes identificadas com PMC1, PMC2, PMC3 e PMC4 são as redes de uma saída apenas.

4. RESULTADOS

Após o desenvolvimento e configuração das redes especialistas conforme apresentado anteriormente, foram sucedidas as fases de treinamento e validação da rede. Já na fase de treinamento foi possível observar resultados

Rede	Referência	Afundamento	Elevação	Interrupção
PMC	1	0	0	0
	0	1	0	0
	0	0	1	0
	0	0	0	1
PMC1	1	0	0	0
PMC2	0	1	0	0
PMC3	0	0	1	0
PMC4	0	0	0	1

Tabela 1. Relação entre saídas e distúrbios dos perceptrons desenvolvidos

significativos, visto que todas as redes neurais propostas convergiram para o erro esperado de 10^{-4} . No entanto, cada uma das estruturas apresentou convergência em um tempo e número de épocas diferentes, sendo possível visualizar uma relação entre estas grandezas através da tabela 2.

Estrutura	Distúrbio	Neurônios	Épocas	Tempo[seg]
4 saídas	Todos	10	90	14,85
1 saída	Referência	4	58	4,25
1 saída	Afundamento	4	31	2,93
1 saída	Elevação	6	41	2,72
1 saída	Interrupção	2	18	2,29

Tabela 2. Relação entre neurônios das camadas escondidas, épocas necessárias para treinamento e tempo total de treinamento dos PMCs desenvolvidos

Para o PMC de 4 saídas, que continha duas camadas neurais escondidas com 5 neurônios cada, demandou maior tempo e maior número de épocas para conseguir fazer a generalização, implicando em maior uso de recursos computacionais.

Em contrapartida, nas redes com apenas uma saída, os tempos foram consideravelmente menores, sendo, no pior dos casos, 29% do tempo do PMC de 4 saídas e, como tempo de treinamento total, tem-se 12,19 segundos, sendo ainda assim menor que os 14,85 segundos do primeiro PMC.

Em relação aos resultados obtidos com os treinamentos de cada rede neural, é possível observar na matriz de confusão 6 que para todos os diferentes padrões, a rede apresentou 100% de acertos. O mesmo ocorre com as redes de uma saída, com exceção da rede PMC3 (elevação), que apresentou 99,9%. Entretanto, vale ressaltar que as configurações com uma saída conseguem obter os mesmos 100% de acerto com menor quantidade de neurônios em camadas escondidas.

A figura 7, relativa ao classificador de sinais de referência, ilustra as matrizes de confusão dos PMC1, PMC2 e PMC4. Já a figura 8 demonstra a confusão do PMC3, cuja porcentagem de acertos é ligeiramente menor que 100%.

Uma das formas de atestar o grau de separabilidade e, conseqüentemente, a qualidade de um sistema inteligente classificador é a curva ROC (Receiver Operating Characteristic). Sendo uma curva probabilística que apresenta uma maneira de avaliar a performance em problemas de classificação de padrões, quanto maior o valor (entre 0 e 1) apresentado na curva, maior a separabilidade. Assim, para o PMC de 4 saídas é possível atestar uma excelente




Figura 6. Matriz de confusão relativa ao PMC classificador de 4 distúrbios




Figura 8. Matriz de confusão relativa ao PMC3




Figura 7. Matriz de confusão relativa ao PMC1

capacidade de classificação, visto que a curva para todas as saídas estão em nível 1, como mostra em 9.

A curva ROC para os PMCs de saída única são, também, de excelência, como mostra a figura 10 apresentando valores iguais a 1, ou próximos à 1, no caso do PMC3, como ilustra a figura 11.

É importante considerar que o sucesso do classificador é composto não somente pela utilização das redes neurais, mas também pela escolha dos atributos do sinal que são entradas do sistema. Através de uma análise de correlação entre as variáveis de entrada e as saídas, é possível inferir que, todas as variáveis influem na saída de maneira similar,




Figura 9. Curva ROC relativa ao PMC classificador de 4 distúrbios

visto que, na maior parte dos casos, existe baixa correlação entre as entradas e as saídas, ou seja, correlação menor que 0,8 ou maior que -0,8. O único caso que se difere é a correlação entre o valor RMS e o fenômeno de elevação, que indica uma alta multicolinearidade (maior que 0,8 ou menor que -0,8), justificando assim, pela alta interferência desse atributo, o fato de ser o único PMC com assertividade menor que 100%.

5. CONCLUSÃO

É possível concluir que a obtenção de resultados satisfatórios para a proposição de um classificador inteligente de

REFERÊNCIAS




Figura 10. Curva ROC relativa ao PMC1

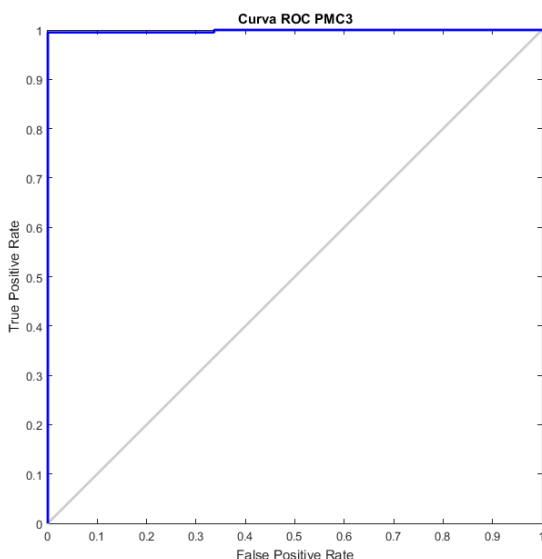


Figura 11. Curva ROC relativa ao PMC3

variações de tensão de curta duração (VTCD) momentâneas se devem a dois fatores principais:

- Escolha de cinco atributos de sinais no domínio do tempo, não necessitando de mudança de domínio e cálculos mais complexos. Esta escolha implica em uma sumarização dos dados amostrados, reduzindo a utilização de recursos computacionais da etapa de processamento e pós-processamento.
- Opção pela utilização de um sistema especialista Perceptron Multicamadas, versátil e bem quisto para o objetivo. É válido considerar que a opção pela elaboração de 4 PMCs de uma saída se mostrou mais viável que a elaboração de um único PMC de 4 saídas.

- Alcântara, I.F.P., Barbosa, B.H.G., and Ferreira, D.D. (2019). Detecção de distúrbios em qualidade de energia usando modelo narx neurais. *Simpósio Brasileiro de Automação Inteligente (SBAI)*.
- ANEEL (2021). *Procedimentos de distribuição de energia elétrica no sistema elétrico nacional – PRODIST Módulo 8 – Qualidade da energia elétrica*.
- Bollen, M.H. and Gu, I. (2006). *Signal Processing of Power Quality Disturbances*.
- Boylestad, R.L. (2012). *Introdução à análise de circuitos*. Pearson.
- Boylestad, R.L. (2013). *Dispositivos eletrônicos e teoria de circuitos*. Pearson.
- da Silva, I.N., Spatti, D.H., and Flauzino, R.A. (2010). *Redes neurais artificiais para engenharia e ciências aplicadas (2010)*. Artliber Editora, São Paulo.
- de Araújo, M.A., Flauzino, R.A., Batista, O.E., de Moraes, L.A., and Martins, C.H.R. (2016). Classificação de distúrbios de qualidade de energia elétrica empregando redes neurais artificiais.
- de Paula Faria, B., Mendes, T.M., and Ferreira, D.D. (2019). Sistema para classificação de distúrbios de qualidade de energia elétrica baseado em svm one class. *Simpósio Brasileiro de Automação Inteligente (SBAI)*.
- Decanini, J.G.M.S., Tonelli-Neto, M.S., and Minussi, C.R. (2015). Diagnóstico de faltas de curto-circuito em sistemas de distribuição de energia elétrica usando sistemas inteligentes. *Simpósio Brasileiro de Automação Inteligente (SBAI)*.
- Fortunato, D.A., Santana, M.W., and Gomes, J.B. (2019). Filtro hodrick-prescott aplicado à análise de sinais elétricos com distúrbios de qualidade de energia elétrica. *Simpósio Brasileiro de Automação Inteligente (SBAI)*.
- IEEE, S.B. (1995). *IEEE Recommended Practice for Monitoring Electric Power Quality*. Ieee std. 1159-1995 edition.
- Mahela, O.P., Khan, B., Alhelou, H.H., and Siano, P. (2020). Power quality assessment and event detection in distribution network with wind energy penetration using stockwell transform and fuzzy clustering. *IEEE Transactions on Industrial Informatics*.
- Mahela, O.P., Shaik, A.G., and Gupta, N. (2014). A critical review of detection and classification of power quality events.
- Monteiro, A.T.S., Moreira, Y.B., de M. Araújo, M., Lemos, F.V.E., Lopes, P.R., and Almeida, A.R. (2019). Contribuições à identificação de distúrbios de qualidade de energia com uso de transformada wavelet. *Simpósio Brasileiro de Automação Inteligente (SBAI)*.
- Pinho, A.C. and Garcia, E.G.A. (2020). Novas métricas para a classificação de distúrbios da qualidade da energia elétrica. *Simpósio Brasileiro de Sistemas Elétricos (SBSE)*.
- Reddy, K.R.M., Reddyb, P.K.K., and Sujata, P. (2021). Power quality classification of disturbances using discrete wavelet packet transform (dwpt) with adaptive neuro-fuzzy system. *Turkish Journal of Computer and Mathematics Education*.
- Souza, M.G.M., Oleskovicz, M., and Monaro, R.M. (2014). Um método alternativo para a estimação de componentes harmônicos por redes neurais artificiais. *Congresso Brasileiro de automática (CBA)*.