

CLASSIFICAÇÃO E LOCALIZAÇÃO DA ORIGEM DE VTCDS EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA ATRAVÉS DE PARÂMETROS DA FUNDAMENTAL E REDES NEURAIS ARTIFICIAIS

RICHARD H. R. ANTUNES* LISANDRO LOVISOLO* PEDRO H. G. COELHO* JOÃO A. MOOR NETO†

**PROSAICO (Lab. de Processamento de Sinais Aplicações Inteligentes e Comunicações)*
PEL/DETEL - FEN - UERJ, Rio de Janeiro, RJ, Brasil

†*CEFET-RJ*
Rio de Janeiro, RJ, Brasil

Email:

richard_henrique@yahoo.com.br; lisandro@uerj.br; phcoelho@uerj.br; jamoor.neto@gmail.com

Abstract— This work aims to understand the impacts of Short Duration Voltage Variations (SDVV) in the supply of electricity, that is in the delivery network. A database for the diagnosis of SDVV faults was obtained through simulations of a radial feeder through software PSCAD/EMTDC. The databases is used for benchmark for different approaches for guessing the origin of the fault. It is assumed that the operation is monitoring the voltage and current waveforms at the feeding substation as well as in some other point of the feeder. For detecting the fault these waveforms are applied into a Phase-Locked Loop (PLL), which estimates the frequency, phase angle and amplitude of the voltage and current waveforms. These data feed two artificial neural networks: one to identify the fault and another to locate the origin of it in the SDVV. The technique investigated here applies to three phase feeders with unbalanced loads. The performance of the proposed technique was satisfactory and demonstrates its feasibility to obtain the relevant knowledge for the classification and location of short circuits.

Keywords— Artificial Neural Networks, Short Duration Voltage Variations, Phase-Locked Loop, Power Delivery Network.

Resumo— O objetivo deste trabalho é conhecer e compreender melhor os imprevistos no fornecimento de energia elétrica, quando ocorrem as variações de tensão de curta duração (VTCD). O banco de dados necessário para os diagnósticos das faltas foi obtido através de simulações de um modelo de alimentador radial através do software PSCAD/EMTDC. Este trabalho utiliza um *Phase-Locked Loop* (PLL) com o intuito de detectar VTCDS e realizar a estimativa da frequência, do ângulo de fase e da amplitude das fundamentais de tensões e correntes da rede elétrica. Desenvolveu-se duas redes neurais artificiais: uma para classificar o tipo e outra para localizar a origem dos VTCDS no sistema de distribuição de energia. A técnica aqui proposta aplica-se a alimentadores trifásicos com cargas desequilibradas, que podem possuir ramais laterais trifásicos, bifásicos e monofásicos. No desenvolvimento da mesma, considera-se que há disponibilidade de medições de tensões e correntes no nó inicial do alimentador e também em alguns pontos esparsos ao longo do alimentador de distribuição. Os desempenhos das arquiteturas das redes neurais foram satisfatórios e demonstram a viabilidade da proposta.

Keywords— Redes Neurais Artificiais, Variação de Tensão de Curta Duração, Phase-Locked Loop, Sistema de Distribuição de Energia Elétrica

1 Introdução

Confiabilidade e disponibilidade no fornecimento de energia elétrica são necessárias para a vida contemporânea. Distúrbios no fornecimento de energia elétrica devem ser evitados e, quando ocorrerem, deve-se prever a rápida recuperação do fornecimento (Dugan et al., 1996) (Turam Gonen, 2007) (Santoso et al., 2012). A identificação e a localização de distúrbios em um sistema de distribuição de energia elétrica são importantes para a manutenção da confiabilidade e da disponibilidade do sistema. Pois, essas ações permitem providenciar o reparo do fornecimento de energia quando os primeiros sinais de distúrbios sejam detectados.

Dentre os distúrbios que ocorrem na rede elétrica, a variação de tensão de curta duração (aumento ou decréscimo na tensão fornecida durante um curto intervalo de tempo) possui grande relevância na avaliação da qualidade da energia elétrica fornecida. Tais distúrbios, apesar de geralmente não ocasionarem a interrupção do fornecimento, podem ser rapidamente percebidos por consumidores industriais, comerciais e residenciais. Por exemplo, a ocorrência desse distúr-

bio pode acarretar a interrupção de processos industriais gerando produtos inadequados e, conseqüentemente, perdas econômicas.

Enquanto os problemas de classificação e localização de faltas na transmissão de energia elétrica tem resultados excelentes, o mesmo não se pode de dizer em relação às ocorrências na rede de distribuição. Por isso, esses problemas em redes de distribuição de energia têm sido crescentemente considerados (Awalin et al., 2012) (Zhu et al., 1997) (Mora-Florez et al., 2008) (Li et al., 2005) (Mokhlis and Li, 2011) (Kezunovic, 2011).

Este trabalho investiga a possibilidade de detecção e localização de quem / o que gera esses distúrbios em uma rede de distribuição de energia a partir dos parâmetros da fundamental estimada durante a ocorrência da falta. Para isso, nos baseamos em um alimentador real e que há monitoração das formas de onda de tensão e corrente em diferentes pontos desse alimentador. Essas formas de onda são empregadas para caracterizar os fenômenos observados no sistema, isto é o distúrbio na energia durante a falta. Assim, dessas formas de onda, extraem-se parâmetros (frequência, amplitude e fase) da fundamental usando um PLL (algoritmo disponível em diver-

dos registradores digitais de perturbação e qualímetros). Esses parâmetros são empregados para detetar a falta e, além disso, alimentam dois classificadores baseados em redes neurais artificiais: um para identificar o tipo de falta e o outro para localizar o ponto de origem do distúrbio.

2 Rede de Distribuição Simulada

Para este trabalho simulamos um sistema de distribuição de energia elétrica utilizando o software PSCAD/EMTDC. A simulação permite obter dados em quantidade satisfatória para estudar e desenvolver técnicas para detectar e classificar as faltas do tipo VTCDs (Lovisolto et al., 2012). Isso é obviamente inviável com uma rede real, devido à dificuldade intrínseca para gerar distúrbios e realizar testes e análises em quantidade em uma rede real (por exemplo, curtos entre fases) e registrar a alteração ocorrida na rede.

As ramificações presentes no sistema real foram agregadas e substituídas por cargas equivalentes. Desta forma, o sistema simulado e analisado foi modelado concentrando as cargas em 13 pontos distintos, conforme apresentado na Figura 1. Essa rede de distribuição de energia elétrica é composta de uma subestação e uma malha contendo várias cargas, representando pequenas indústrias. Na Tabela 1 são apresentados os parâmetros definidores das cargas da rede de distribuição simulada e na Tabela 2 as distâncias entre as cargas e o alimentador da rede de distribuição de energia elétrica.

Pode-se ver na rede simulada (Figura 1) a existência de 3 RDPs (Registradores Digitais de Perturbação), também conhecidos como oscilógrafos digitais. A principal função de um RDP é registrar o estado do sistema e de sua proteção durante eventos importantes, como faltas e oscilações de frequência, entre outros.

Faltas são simuladas em diferentes pontos desse sistema e com diferentes características. Capturam-se as formas das ondas de tensão e corrente em cada fase da rede trifásica, quando da ocorrência das faltas usando os RDPs, em diferentes posições da rede.

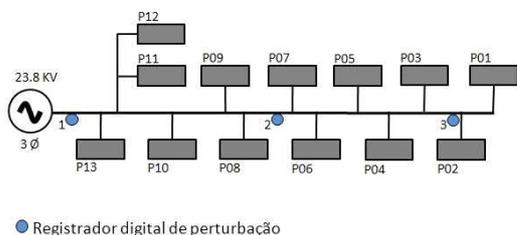


Figura 1: Diagrama unifilar da rede de distribuição simulada.

Os tipos das faltas simulados envolvem as três fases do sistema. Assim, têm-se 10 tipos de faltas: AB, AC, BC, ABC, AG, BG, CG, ABG, ACG, BCG (Dugan et al., 1996) (Santoso et al., 2012) (Lovisolto et al., 2012). Essas po-

Tabela 1: Cargas agregadas nos ramais do sistema simulado.

Carga	Res. (Ω)	Ind. (H)	Pot. (KVA)
P01	335,8730	1,8395	1750,0
P02	391,8519	2,1461	1500,0
P03	2612,3	14,3080	225,0
P04	1175,55	6,4383	500,0
P05	2612,3	14,3080	225,0
P06	1175,55	6,4383	500,0
P07	1959,3	10,7304	300,0
P08	1959,3	10,7304	300,0
P09	2612,3	14,3080	225,0
P10	1959,3	10,7304	300,0
P11	1959,3	10,7304	300,0
P12	1175,55	6,4383	500,0
P13	824,951	4,5181	712,5

Tabela 2: Distância entre as cargas e o alimentador.

Carga	Distância (km)
P01	6,755
P02	7,615
P03	6,210
P04	5,715
P05	5,715
P06	5,505
P07	5,085
P08	3,945
P09	3,915
P10	3,225
P11	3,500
P12	5,050
P13	1,120

dem ocorrer em cada um dos 13 pontos da malha. Porém, faltas de um mesmo tipo num mesmo local, podem possuir motivos causadores e características bem diferentes. Assim, para cada uma das 130 combinações de tipos e locais de falta (10×13), foram geradas faltas com durações e resistências diferentes num total de 9 diferentes características. Foram utilizados três valores para a resistência das faltas a fim de simular situações bem distintas: (“alta impedância”) 40Ω , (“média impedância”) 25Ω e (“baixa impedância”) 10Ω . As faltas simuladas assumiram três diferentes durações de forma a diversificar a base de dados, estas foram: 8,33 ms, 16,67 ms e 25,00 ms. Desta forma obteve-se registros correspondentes a 1170 faltas distintas, registradas em três locais diferentes do barramento do sistema de distribuição de energia.

A potência de curto-circuito do barramento representativo da subestação é de $S_{cc}=115$ MVA e as cargas incluídas nos barramentos foram do tipo impedância constante com ligação em Y, sendo o terminal de neutro aterrado, com uma $P_t=3,24$ MVA e com um fator de potência 0,92 indutivo. Os segmentos de linha do alimentador foram modelados como circuitos RL em série, sem consideração de acoplamento entre as fases do sistema trifásico. No alimentador em questão, para os trechos entre os barramentos foram considerados dados geométricos dos cabos e postes e foi adotado o *model frequency dependent (phase)* (Manitoba HVDC, 2005b) (Manitoba HVDC, 2005a). As faltas foram modeladas como simples resistências e a frequência de amostragem para captura utilizada foi de 24.390 amostras por segundo.

3 Detecção das Faltas

Cada simulação fornece os sinais de tensões e correntes correspondentes às faltas. Para detectar o instante de incidência da falta é necessário extrair, dos sinais de tensões e corrente, o instante em que a falta ocorreu. Para isso foi utilizado um PLL (Lovisol et al., 2008). A Figura 2 apresenta o diagrama de blocos com os módulos que compõem o algoritmo de detecção da faltas.



Figura 2: Diagrama de blocos dos módulos do algoritmo de detecção de incidência de falta.

3.1 Transformada de Clarke

A equação (1) apresenta a forma matricial da transformada direta de Clarke (Bollen and Gu, 2006) que transforma um sistema a, b e c no sistema bifásico α, β e 0.

$$\begin{bmatrix} p_\alpha(t) \\ p_\beta(t) \\ p_0(t) \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} p_a(t) \\ p_b(t) \\ p_c(t) \end{bmatrix} \quad (1)$$

3.2 Análise Fundamental

PLLs são empregados para extrair, individualmente, a partir das componentes α, β e 0, valores estimados de frequências, amplitudes e fases dos sinais de tensão e corrente dos registros das faltas. O algoritmo utilizado é baseado no PLL proposto em (Lovisol et al., 2008). A ideia central é a determinação da informação da fase usando a projeção do sinal de entrada sobre o subespaço complexo $e^{-j2\pi ft}$ gerado a partir da estimativa da frequência fundamental f presente no próprio sinal de entrada. Ou seja, altera-se a frequência de um oscilador controlado até que o sinal produzido por este esteja sincronizado a fase e portanto com a frequência do sinal de referência.

3.3 Detecção da Falta

Seja $y = f(x)$, se x variar de um valor x_0 até um valor x_1 então podemos definir $\Delta x = x_1 - x_0$, para essa variação de Δx em x_0 podemos definir a variação $\Delta y = f(x_1) - f(x_0)$. O quociente entre essas diferenças é dado pela equação (2), que é a taxa de variação média de y em relação a x , no intervalo $[x_0, x_1]$.

$$\frac{\Delta y}{\Delta x} = \frac{f(x_1) - f(x_0)}{x_1 - x_0} \quad (2)$$

Empregamos $\frac{\Delta y}{\Delta x}$ para analisar o desvio do PLL. Usamos o desvio em qualquer sentido (aumento ou redução) da frequência fundamental for maior que um fator pré-estipulado para detectar a falta.

Neste trabalho definiu-se um fator de 0.1% para definir o desvio máximo a partir do qual indica-se a ocorrência da falta. A falta é detectada quando a amplitude ou frequência estimadas para alguns dos sinais de tensão ou corrente variar mais que o permitido pelo limiar. Essa detecção dispara a captura dos atributos do processo de classificação, conforme explicado a seguir. Cabe salientar que esta estratégia de detecção permitiu detectar corretamente 100% das faltas simuladas quando de suas ocorrências.

3.4 Parâmetros Extraídos para Classificação e Localização

Para o processamento dos RDPs conjuntamente o conjunto de atributos extraído para entrada do classificador é composto dos 3 parâmetros (frequência, amplitude e fase) extraídos dos registros de tensões e correntes das 3 fases (A, B e C) para os 3 RDPs, gerando um total de 54 atributos, vetor de entrada do classificador. Esses valores são computados no instante de tempo correspondente a um ciclo após o instante de detecção da falta.

De forma a validar o ganho de capturar registros em diferentes pontos, comparamos os classificadores que empregam registros capturados em um único ponto da rede. Neste caso, o conjunto de atributos é composto dos 3 parâmetros (frequência, amplitude e fase) extraídos dos registros de tensões das 3 fases (A, B e C) para um dos RDPs, gerando um total de 18 atributos. Esses valores são extraídos no mesmo instante acima descrito.

4 Classificação e Localização das Faltas Usando RNAs

Os dados extraídos após a detecção das faltas são aplicados a redes neurais de forma a classificar as faltas. Empregou-se duas redes neurais artificiais: uma para identificação do tipo da falta (**RNA-TF**) e outra para localização da falta (**RNA-LF**) a partir dos parâmetros (frequência, amplitude e fase) estimados para a fundamental, tanto dos registros de tensão como dos de corrente, conforme explicado na subseção 3.4. Antes de apresentar a topologia das redes empregadas e os resultados obtidos, cabe ressaltar alguns cuidados tomados no projetos das RNAs.

4.1 Características Gerais

As redes neurais empregadas são do tipo *Multi-layer Perceptron (MLP)*. algoritmo de treinamento empregado foi o *backpropagation* e a taxa de aprendizado inicial foi configurada para 0.03 (Haykin, 2001).

4.2 Separação do Banco de Dados

Para uma utilização eficiente e correta do banco de dados construído, dividiu-se o mesmo em 3 conjuntos. 60% dos dados são separados para treinamento, 20% para validação e 20% para teste. Essas porcentagens equivalem a 702, 234 e 234 registros respectivamente de um total de 1170. O

número de épocas foi fixado em 1500 com parada anterior caso o erro de validação aumente 20 vezes consecutivas e essas redes foram iniciadas 10 vezes e dentre as assim treinadas apresentam-se os resultados obtidos para as de menores erros nos testes.

4.3 Topologias das RNAs

A **RNA-TF** possui dez saídas. Cada saída é ativada para um possível tipo de falta, conforme a Tabela 3. A **RNA-LF** possui treze saídas. Cada saída é ativada para cada possível região de origem da falta, conforme a Tabela 4. As Tabelas 5 e 6 resumem as características das redes empregadas.

Tabela 3: Ativação da saídas da **RNA-TF**.

Tipo falta	Saída Correspondente									
	ABC	BC	AC	AB	BCG	ACG	ABG	CG	BG	AG
ABC	1	0	0	0	0	0	0	0	0	0
BC	0	1	0	0	0	0	0	0	0	0
AC	0	0	1	0	0	0	0	0	0	0
AB	0	0	0	1	0	0	0	0	0	0
BCG	0	0	0	0	1	0	0	0	0	0
ACG	0	0	0	0	0	1	0	0	0	0
ABG	0	0	0	0	0	0	1	0	0	0
CG	0	0	0	0	0	0	0	1	0	0
BG	0	0	0	0	0	0	0	0	1	0
AG	0	0	0	0	0	0	0	0	0	1

Tabela 4: Ativação das saídas da **RNF-LF**.

Loc. falta	Saída Correspondente															
	P13	P12	P11	P10	P09	P08	P07	P06	P05	P04	P03	P02	P01			
P13	1	0	0	0	0	0	0	0	0	0	0	0	0			
P12	0	1	0	0	0	0	0	0	0	0	0	0	0			
P11	0	0	1	0	0	0	0	0	0	0	0	0	0			
P10	0	0	0	1	0	0	0	0	0	0	0	0	0			
P09	0	0	0	0	1	0	0	0	0	0	0	0	0			
P08	0	0	0	0	0	1	0	0	0	0	0	0	0			
P07	0	0	0	0	0	0	1	0	0	0	0	0	0			
P06	0	0	0	0	0	0	0	1	0	0	0	0	0			
P05	0	0	0	0	0	0	0	0	1	0	0	0	0			
P04	0	0	0	0	0	0	0	0	0	1	0	0	0			
P03	0	0	0	0	0	0	0	0	0	0	1	0	0			
P02	0	0	0	0	0	0	0	0	0	0	0	1	0			
P01	0	0	0	0	0	0	0	0	0	0	0	0	1			

Tabela 5: Características das RNAs (MLPs) utilizadas para os RDPs conjuntamente, obs.: para as funções de ativação ver (Haykin, 2001).

Característica	RNA-TF	RNA-LF
Quantidade de entradas	54	54
Quantidade de saídas	10	13
Camadas ocultas	2	2
Neurônios na camada 1	39	65
Neurônios na camada 2	21	52
Func. ativa. camadas ocultas	logsig	logsig
Func. ativa. camada saída	tansig	tansig

5 Resultados

Conforme discutido acima, as formas de onda de tensão e corrente provenientes de um RDP podem ser consideradas isoladamente com dados para os problemas de classificação e localização de faltas ou conjuntamente aos diversos RDPs para os mesmos fins. Assim, consideramos as estratégias de 1) emprego conjunto dos dados dos três RDPs e 2) dados dos três registradores de perturbações são empregados separadamente. Isso permita avaliar

Tabela 6: Características das RNAs (MLPs) utilizadas para os RDPs isoladamente, obs.: para as funções de ativação ver (Haykin, 2001).

Característica	RNA-TF	RNA-LF
Quantidade de entradas	18	18
Quantidade de saídas	10	13
Camadas ocultas	2	2
Neurônios na camada 1	39	65
Neurônios na camada 2	21	52
Func. ativa. camadas ocultas	logsig	logsig
Func. ativa. camada saída	tansig	tansig

se dispor de mais de um RDP para a classificação e localização de faltas em sistemas de distribuição de energia confere ganhos de desempenho.

5.1 Processamento com os RDPs Conjuntamente

5.1.1 Identificação dos Tipos das Faltas

O melhor desempenho deste classificador requereu um treinamento com 204 épocas e seu desempenho para o total de 702 registros do conjunto de treinamento foi de 692 acertos com desempenho de 94.0%. Para o conjunto de validação, que possui 234 registros, obteve-se 170 acertos com desempenho de 72.6% e 64 erros com taxa de 27.4%. Para o conjunto de testes, também com 234 registros, obteve-se 174 acertos com desempenho de 74.4% e 60 erros com taxa de 25.6%. Na matriz de confusão, Tabela 7, podemos ver que as classes 1 (ABC), 4 (AB) e 8 (CG) foram as mais confundidas pelo classificador.

Tabela 7: Matriz de Confusão para a identificação do tipo de falta empregando as informações dos três RDPs. As classes alvos estão nas colunas e as saídas das RNA estão nas linhas.

	ABC	BC	AC	AB	BCG	ACG	ABG	CG	BG	AG
ABC	16	0	0	2	1	0	1	2	4	0
BC	0	20	1	0	0	1	0	0	1	0
AC	0	0	17	0	0	5	2	0	0	0
AB	4	0	0	11	1	0	1	0	0	1
BCG	2	1	0	1	11	0	0	0	0	0
ACG	0	1	2	0	0	13	0	0	3	1
ABG	0	0	1	3	0	0	22	0	0	2
CG	0	2	0	5	3	0	1	23	1	1
BG	0	0	0	0	0	0	0	0	14	0
AG	0	0	0	0	0	0	0	0	3	27

5.1.2 Localização dos Tipos das Faltas

O melhor desempenho deste classificador requereu um treinamento com 224 épocas e seu desempenho para o conjunto de treinamento de 626 acertos, 89.2% de taxa de acerto, e 76 erros, 10.8% de taxa de erro. Para o conjunto de validação com 234 registros obteve-se 159 acertos, 67.9%, 75 erros, com taxa de erro de 32.1%. Para o conjunto de teste com 234 registros e obteve-se 140 acertos com desempenho de 59.8% e 94 erros com taxa de erro de 40.2%. A matriz de confusão, Tabela 8, permite verificar que individualmente para as classes temos taxas de erro variando desde aproximadamente 30% (P10) até 57% (P09).

Tabela 8: Matriz de Confusão para a localização da origem falta empregando as informações dos três RDPs. As classes alvos estão nas colunas e as saídas das RNA estão nas linhas.

	P13	P12	P11	P10	P09	P08	P07	P06	P05	P04	P03	P02	P01
P13	11	0	0	0	0	1	0	0	0	3	0	0	0
P12	4	13	1	0	0	2	0	0	0	0	0	0	0
P11	0	0	8	3	1	1	2	1	0	0	1	0	0
P10	0	0	1	14	0	1	0	4	0	0	0	0	0
P09	2	0	0	0	9	1	0	0	3	2	2	1	2
P08	0	2	0	0	0	11	1	0	0	1	1	0	0
P07	0	5	5	0	1	0	7	0	1	0	0	0	0
P06	0	0	1	3	0	0	4	7	0	0	0	0	2
P05	0	0	0	0	3	0	0	0	13	1	0	0	1
P04	0	1	0	0	6	0	0	0	1	7	0	0	0
P03	0	0	0	0	0	1	0	0	2	1	16	1	1
P02	1	0	0	0	1	0	0	2	0	0	1	10	0
P01	0	0	0	0	0	0	0	0	1	0	1	2	14

5.2 Processamentos Isolados dos RDPs

5.2.1 Identificação dos Tipos das Faltas

Separando os dados dos RDPs, o treinamento da rede convergiu em 244 épocas (no pior caso) com desempenho de 594 acertos com desempenho de 84.6% e de 108 erros com taxa de 15.4%. Para os 234 registros do conjunto de validação, obteve-se 167 acertos com desempenho de 71.4% e 67 erros com taxa de 28.6%. Para o conjunto de testes com 234 registros, obteve-se 160 acertos com desempenho de 68.4% e 74 erros com taxa de 31.6%. As matrizes de confusão obtidas para a rede treinada para os dados provenientes de cada RDP podem ser vistas nas Tabelas 9, 10 e 11, para os RDPs 1, 2 e 3, respectivamente. Na matriz de confusão para o RDP 1, as classes 1 (ABC), 4 (AB), 5 (BCG), 7 (ABG) e 8 (CG) foram as mais confundidas pelo classificador. Já para os dados provenientes do RDP 2, as mas confundidas são as classes 4 (AB), 5 (BCG), 6 (ACG) e 7 (ABG). Para a rede treinada a partir do RDP 3, as confusões ocorrem em maior número para as classes 3 (AC), 4 (AB), 5 (BCG), 6 (ACG) e 8 (CG).

Tabela 9: Matriz de Confusão para a identificação do tipo de falta empregando as informações do RDP 1.

	ABC	BC	AC	AB	BCG	ACG	ABG	CG	BG	AG
ABC	14	0	0	4	2	2	0	6	0	0
BC	0	12	0	0	3	0	0	0	0	0
AC	0	0	18	0	1	4	2	0	0	1
AB	1	0	0	11	0	0	3	2	1	1
BCG	3	2	0	0	12	0	0	2	2	0
ACG	0	4	1	1	0	20	1	0	0	0
ABG	2	1	0	7	0	0	13	0	0	1
CG	3	0	0	2	1	0	3	12	0	0
BG	0	1	0	0	0	2	1	0	24	0
AG	0	0	0	0	0	0	0	0	1	24

5.2.2 Localização dos Tipos das Faltas

Separando os dados dos RDPs, o treinamento da rede convergiu em 263 épocas (no pior caso) com desempenho de 540 acertos com desempenho de 76.9% e de 162 erros com taxa de 23.1%. Para os 234 registros do conjunto de validação, obteve-se 142 acertos com desempenho de 60.7% e 92 erros com taxa de 39.3%. Para o conjunto de testes com

Tabela 10: Matriz de Confusão para a identificação do tipo de falta empregando as informações do RDP 2.

	ABC	BC	AC	AB	BCG	ACG	ABG	CG	BG	AG
ABC	18	0	0	1	2	1	0	4	0	0
BC	0	11	3	1	1	2	0	0	0	0
AC	0	0	21	0	0	5	0	0	1	0
AB	2	1	2	11	2	1	2	2	0	1
BCG	2	4	0	0	13	0	1	1	1	0
ACG	1	3	3	1	1	12	0	0	0	0
ABG	0	0	3	2	1	1	12	0	1	3
CG	0	0	1	1	5	0	0	18	1	0
BG	1	0	0	0	2	2	0	0	16	1
AG	0	0	0	0	0	1	1	0	0	23

Tabela 11: Matriz de Confusão para a identificação do tipo de falta empregando as informações do RDP 3.

	ABC	BC	AC	AB	BCG	ACG	ABG	CG	BG	AG
ABC	20	0	4	5	2	0	0	3	0	0
BC	1	15	0	0	2	1	1	1	1	0
AC	0	0	14	0	2	8	1	0	0	0
AB	2	0	0	11	0	2	2	2	0	1
BCG	1	2	0	1	10	1	0	5	0	0
ACG	0	3	3	2	1	15	0	0	3	4
ABG	0	0	1	0	0	0	14	0	0	2
CG	2	1	0	4	3	0	0	9	1	0
BG	0	0	0	0	2	1	2	1	16	1
AG	0	0	0	0	0	2	1	0	1	18

234 registros, obteve-se 130 acertos com desempenho de 55.6% e 104 erros com taxa de 44.4%. As matrizes de confusão obtidas para a rede treinada para os dados provenientes de cada RDP podem ser vistas nas Tabelas 12, 13 e 14, para os RDPs 1, 2 e 3, respectivamente. As matrizes de confusão, permitem verificar que individualmente para as classes temos taxas de erro superiores às obtidas para o classificador que considera os dados conjuntamente.

Tabela 12: Matriz de Confusão para a localização da origem falta empregando as informações do RDP 1

	P13	P12	P11	P10	P09	P08	P07	P06	P05	P04	P03	P02	P01
P13	12	2	0	0	0	2	0	0	1	0	0	0	3
P12	0	5	0	0	0	0	0	0	0	0	0	0	0
P11	3	1	12	1	1	1	5	1	0	0	0	0	0
P10	0	1	2	6	0	0	2	4	1	0	0	0	0
P09	0	4	0	1	7	1	0	0	5	0	0	0	0
P08	3	1	0	0	1	9	0	0	1	1	1	0	0
P07	0	5	1	1	0	0	8	1	0	0	1	1	0
P06	0	0	0	1	0	0	4	9	0	0	0	0	0
P05	0	0	0	1	1	0	0	3	11	2	0	0	1
P04	7	1	0	1	4	2	0	0	1	14	1	0	0
P03	0	0	0	0	0	2	0	0	1	0	13	1	1
P02	0	1	0	0	0	0	1	2	0	0	0	15	0
P01	1	0	0	0	0	0	0	0	0	0	2	2	9

6 Conclusão

Este trabalho abordou o problema de identificação e localização do tipo das faltas de VTCDs em um sistema de distribuição de energia elétrica. A abordagem adotada baseia-se na construção de um banco de dados de registros de faltas. Esse contém só os sinais correspondentes às formas de onda de tensão e corrente no sistema. Para a extração do instante em que a falta ocorreu aplica-se um PLL e avalia-se a variação dos parâmetros extraídos pelo mesmo. Além disso, aplica-se esse

Tabela 13: Matriz de Confusão para a localização da origem falta empregando as informações do RDP 2.

	P13	P12	P11	P10	P09	P08	P07	P06	P05	P04	P03	P02	P01
P13	6	1	2	2	5	0	2	0	0	3	0	0	0
P12	4	6	1	0	1	2	0	0	0	1	1	0	0
P11	0	2	8	2	1	1	3	0	0	0	0	1	0
P10	0	1	1	8	0	0	0	1	0	0	0	0	1
P09	2	0	1	1	11	0	0	0	1	0	0	0	0
P08	5	5	1	0	1	12	1	2	0	5	0	0	0
P07	0	0	0	0	0	0	6	0	0	0	2	0	0
P06	0	0	5	1	1	1	0	14	0	0	0	4	0
P05	0	0	0	0	4	0	0	0	12	3	0	1	3
P04	0	0	0	0	0	0	1	0	0	7	0	0	0
P03	0	1	0	0	0	1	2	0	1	1	13	1	0
P02	0	0	0	0	0	0	0	2	0	0	1	12	0
P01	0	0	0	0	0	0	0	0	1	0	0	2	16

Tabela 14: Matriz de Confusão para a localização da origem falta empregando as informações do RDP 3.

	P13	P12	P11	P10	P09	P08	P07	P06	P05	P04	P03	P02	P01
P13	9	0	0	1	4	1	0	0	1	4	0	0	0
P12	2	9	0	0	1	6	2	0	0	0	0	0	0
P11	0	1	5	0	0	0	6	3	0	0	0	1	0
P10	0	2	0	3	2	0	0	5	1	0	0	1	0
P09	1	0	0	0	12	0	0	0	0	2	0	0	1
P08	1	6	2	1	1	9	0	1	0	8	2	0	0
P07	0	1	1	0	0	0	8	0	0	3	0	0	0
P06	0	0	3	3	0	0	1	7	1	0	2	0	2
P05	0	0	0	1	1	0	0	1	16	0	0	0	0
P04	0	1	0	0	1	2	0	0	1	10	0	1	0
P03	0	0	0	0	0	3	1	0	0	0	12	2	0
P02	0	0	0	0	0	0	3	0	0	0	1	10	0
P01	0	0	0	0	0	0	0	1	2	0	1	1	13

banco de dados para o treinamento de redes neurais artificiais para a identificação e a localização dos distúrbios.

Para o problema de identificação do tipo de falta obtém-se resultados melhores que para o problema de localização dos distúrbios. Ainda assim, os resultados são satisfatórios e promissores. Obteve-se 74.4% e 68.4% de acerto na identificação das faltas quando considera-se o uso de medidores em três pontos da rede e em um único ponto da rede, respectivamente. Considerando a dificuldade envolvida na localização das faltas, os resultados de 59.8% e 55.6% de desempenho nos mesmos casos pode ser considerado satisfatório, ainda mais considerando-se que a rede deve generalizar entre 13 casos distintos (possíveis origens das faltas). Ainda assim, os resultados indicam a possibilidade de realizar essas tarefas se consideram-se RDPs em diversos pontos da rede de distribuição, o que parece ser um cenário condizente com o advento dos *Smart-Grids* (Kezunovic, 2011).

Para melhora dos resultados obtidos considera-se que: 1) a captura de registros em mais pontos do sistema de distribuição (que como visto acima confere melhorias ao desempenho), 2) a extração de parâmetros para a classificação / localização em outros instantes, entre outros, podem vir a ajudar. Além disso, outras estratégias de extração de parâmetros com maiores complexidades computacional poderiam ser tentadas. Talvez, esses incrementos possam ajudar a melhorar o desempenho da proposta de classificação e localização de VTCDs em sistemas de distribuição de energia apresentada neste

trabalho. Outra possibilidade é o desenvolvimento de estruturas / classificadores com outras estruturas usando ou não RNAs. Entretanto, fica disponível para esses desdobramentos, o banco de dados construído.

Agradecimentos

Os autores gostariam de agradecer à FAPERJ.

Referências

- Awalin, L., Mokhlis, H. and Halim, A. (2012). Improved fault location on distribution network based on multiple measurements of voltage sags pattern, *Power and Energy (PECon), 2012 IEEE International Conference on*, IEEE, pp. 767–772.
- Bollen, M. H. and Gu, I. (2006). *Signal processing of power quality disturbances*, Vol. 30, Wiley-IEEE Press.
- Dugan, R. C., McGranaghan, M. F. and Beaty, H. W. (1996). *Electrical power systems quality*, Vol. 2, McGraw-Hill New York.
- Haykin, S. (2001). *Redes Neurais: Princípios e Prática*, Bookman.
- Kezunovic, M. (2011). Smart fault location for smart grids, *Smart Grid, IEEE Transactions on* **2**(1): 11–22.
- Li, H., Mokhar, A. S. and Jenkins, N. (2005). Automatic fault location on distribution network using voltage sags measurements, *Electricity Distribution, 2005. CIRED 2005. 18th International Conference and Exhibition on*, IET, pp. 1–4.
- Lovisol, L., Moor Neto, J., Figueiredo, K., de Menezes Laporte, L. and Dos Santos Roch, J. (2012). Location of faults generating short-duration voltage variations in distribution systems regions from records captured at one point and decomposed into damped sinusoids, *Generation, Transmission & Distribution, IET* **6**(12): 1225–1234.
- Lovisol, L., Neto, J. A. M., Ortiz, A. and Aredes, M. (2008). Análise Comparativa do Desempenho de Algoritmos de Sistemas de Sincronismos (PLL - Phase Lock Loop), *Revista EletroEvolução - Sistema de Potência, Cigré-Brasil* **10**(51): 37–43.
- Manitoba HVDC (2005a). *EMTDC - Transient Analysis for PSCAD Power System Simulations: User's Guide*, Manitoba HVDC Research Centre.
- Manitoba HVDC (2005b). *PSCAD - Power Systems Computer Aided Design: User's Guide*, Manitoba HVDC Research Centre.
- Mokhlis, H. and Li, H. (2011). Non-linear representation of voltage sag profiles for fault location in distribution networks, *International Journal of Electrical Power & Energy Systems* **33**(1): 124–130.
- Mora-Florez, J., Melendez, J. and Carrillo-Cacedo, G. (2008). Comparison of impedance based fault location methods for power distribution systems, *Electric Power Systems Research* **78**(4): 657–666.
- Santoso, S., McGranaghan, M. F. and Beaty, H. (2012). *Electrical power systems quality*, McGraw-Hill.
- Turam Gonen (2007). *Electric Power Distribution System Engineering*, CRC Press.
- Zhu, J., Lubkeman, D. L. and Girgis, A. A. (1997). Automated fault location and diagnosis on electric power distribution feeders, *Power Delivery, IEEE Transactions on* **12**(2): 801–809.