

Classificador de distúrbios no sinal de energia elétrica, baseado em redes neurais artificiais

Analiza Dalla Costa

UCS - Universidade de Caxias do Sul
Campus Universitário da Região dos Vinhedos
Curso de Engenharia Elétrica
Flores da Cunha – RS – Brasil
analizadallac@gmail.com

Ricardo Becker

UCS - Universidade de Caxias do Sul
Faculdade SENAI de Tecnologia
UniRitter – Centro Universitário Ritter dos Reis
Porto Alegre – RS – Brasil
ricardobecker.eng@gmail.com

Resumo — Este trabalho propõe a avaliação de uma metodologia para realizar a classificação de distúrbios que afetam a qualidade de energia elétrica distribuída. Considera-se como referência uma biblioteca de sinais sintéticos contendo variações de tensão de curta duração. Para detecção dos distúrbios avalia-se aspectos extraídos com a aplicação da Transformada S (Stockwell). Neste domínio, são calculados parâmetros que são usados como entrada para o sistema classificador, baseado em redes neurais artificiais. O sistema foi implementado em *software* Matlab. O método mostrou-se eficaz, apresentando uma taxa de acerto acima de 95%. Foi também realizada uma comparação com estudos anteriores em termos de precisão de classificação, tanto com sinais reais como sintéticos, o que demonstrou que os resultados obtidos estão coerentes e superaram algumas destas referências.

Palavras-chaves — Qualidade de Energia, Distúrbios Elétricos, Transformada S, Redes Neurais Artificiais.

I. INTRODUÇÃO

Diante do cenário marcado por características de cargas não lineares dos consumidores de energia, além da crescente inserção de microgerações ao sistema, tem-se destacado cada vez mais a necessidade de avaliação, por parte das concessionárias, do atendimento de requisitos referentes à qualidade de energia elétrica. Os padrões e respectivas normas que ditam esses requisitos estão descritos no PRODIST (Procedimentos de Distribuição), elaborado pela ANEEL, especificamente o módulo 8, que trata exclusivamente da qualidade de energia.

Os parâmetros levados em conta pelo PRODIST para a determinação do desempenho do sistema são a continuidade, o atendimento ao consumidor e a conformidade. Ou seja, avalia-se a qualidade do serviço e a qualidade do produto oferecidos pela empresa distribuidora [1].

Os fenômenos que envolvem distorções da forma de onda da tensão do sistema de distribuição, estão diretamente relacionados com o padrão da forma de onda da corrente consumida pelas cargas de natureza não-linear [2]. Esses fenômenos podem causar interferências em sistemas de comunicação, mau funcionamento de sistemas eletrônicos e de proteção entre outras falhas aos equipamentos ligados à rede elétrica. Devido a esses problemas, verifica-se a importância de se realizar uma eficiente investigação da qualidade de energia, tanto do ponto de vista de controle, para detecção e caracterização de diversos distúrbios, como do ponto de vista de correção e eliminação dos mesmos [3]; [4].

Outro ponto é o fato de que, havendo uma localização instantânea, eficiente e precisa de determinada falha, a mesma poderia auxiliar no processo de reparo do sistema e reestabelecimento de energia aos consumidores. Assim, o tempo necessário para o operador do sistema localizar o problema seria minimizado. Isso reduziria, por exemplo, custos de manutenção, aumentaria a confiabilidade operacional do sistema de distribuição, além de contribuir para a melhoria de indicadores de continuidade da concessionária [3].

Frente ao exposto, percebe-se que o estudo e implementação de algoritmos para análise de distúrbios relacionados à qualidade de energia em redes elétricas compreende: a detecção e localização da falha; sua caracterização, ou seja, identificação do tipo de distúrbio e a forma como se pode atuar para resolver o evento indesejável detectado. Diferentes métodos têm sido propostos para detectar e classificar esses eventos. De modo geral, pode-se identificar três diferentes: a. Técnicas baseadas em processamento de sinais, b. Inteligência artificial e c. Técnicas baseadas em processamento de sinais em conjunto com inteligência artificial [5].

O foco principal deste trabalho está no estudo de algoritmos com capacidade para detectar e caracterizar anormalidades contidas na energia elétrica distribuída. Desta forma, propõe-se utilizar uma técnica de processamento de sinais em sistemas de potência combinada à inteligência artificial.

II. METODOLOGIA

O objetivo do trabalho está na classificação de distúrbios, assim, a metodologia consiste em aplicar uma Rede Neural Artificial, combinada com a Transformada S (Stockwell) para realizar essa classificação, conforme apresentado na Fig. 1.

A análise de sinais compreende, geralmente, a decomposição em função do tempo ou no domínio da frequência. As duas representações contemplam as mesmas informações, entretanto, respondem a abordagens diferentes e complementares [6]. Muitas vezes se faz necessário o uso combinado dos dois domínios. Neste trabalho, se utiliza a representação tempo – frequência, pela Transformada S (ST). Essa representação é fundamental na análise dos distúrbios que comprometem a qualidade de energia elétrica (QEE), pois estes são sinais não-estacionários e necessita-se obter características que expressem o distúrbio em questão. A análise pela ST combina elementos da Transformada Wavelet

e Transformada de Fourier de Tempo Curto (STFT), utilizando uma janela cuja largura decresce com a frequência. Fornece uma análise multirresolução, enquanto retém a fase absoluta para cada frequência. Ademais, o contorno da frequência proporcionado pela ST localiza sinais com distúrbio, mesmo com alto nível de ruído, fornecendo características únicas para determinada perturbação da qualidade de energia, podendo ser utilizadas em conjunto com Redes Neurais Artificiais, lógica Fuzzy ou Máquinas de Vetores de Suporte para reconhecimento automático e classificação de padrões [2]; [7].




Fig. 1. Esquema em blocos do sistema

A. Projeto de Implementação

1) *Sinais Sintéticos*: Foram utilizadas, inicialmente, amostras geradas em *software* Matlab, a partir das equações paramétricas da Tabela I e parâmetros da Tabela II, descritas por [7]. Isto devido à dificuldade em obter sinais reais com distúrbios pelo fato de que as concessionárias devem garantir o fornecimento dentro de padrões de qualidade. Então, para localizar eventos específicos seria demandado um elevado tempo de monitoramento do sinal de energia, sem garantias de sucesso.

TABELA I – EQUAÇÕES PARA IMPLEMENTAÇÃO DOS SINAIS.

Distúrbio	Equação
Senóide ideal	$Y = A \sin(\omega t)$
Elevação de tensão	$Y = A (1 + \alpha(u(t - t_1) - u(t - t_2))) \sin(\omega t)$
Afundamento de tensão	$Y = A (1 - \alpha(u(t - t_1) - u(t - t_2))) \sin(\omega t)$
Interrupção	$Y = A (1 - \alpha(u(t - t_1) - u(t - t_2))) \sin(\omega t)$

Fonte: adaptado de [7].

TABELA II – DEFINIÇÃO DOS PARÂMETROS PARA AS EQUAÇÕES.

Distúrbio	Parâmetros
Senóide ideal	$A = 1 \text{ pu}; f = 60 \text{ Hz}$
Elevação de tensão	$0,1 \leq \alpha \leq 0,8; T \leq t_2 - t_1 \leq 9T;$ $t_1 < t_2; u(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases}$
Afundamento de tensão	$0,1 \leq \alpha \leq 0,9; T \leq t_2 - t_1 \leq 9T;$ $t_1 < t_2; u(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases}$
Interrupção	$0,9 \leq \alpha \leq 1; T \leq t_2 - t_1 \leq 9T$

Fonte: adaptado de [7].

Foi proposto classificar quatro classes, as variações de tensão de curta duração: elevação, afundamento e interrupção de tensão, além da senóide ideal. Os sinais sintéticos gerados foram divididos em dois grupos. O primeiro para realizar a etapa de treinamento do algoritmo da rede neural e o segundo para testar e validar o mesmo.

2) *Transformada S*: Para realizar a classificação dos distúrbios, a rede neural artificial recebe como entrada os sinais pré-processados, no domínio do tempo para o domínio tempo-frequência, através da Transformada S, onde as classes de distúrbios podem ser separadas por parâmetros estatísticos que as diferenciam. A fase de extração de características é o ponto chave para o reconhecimento de padrões, uma vez que mesmo o melhor classificador irá responder de forma errônea caso os recursos não sejam bem escolhidos [7]. Um extrator de recurso deve reduzir o vetor da forma de onda original para uma dimensão menor, que contenha a maior parte da informação útil [7]. Diversas características, tais como amplitude máxima, média e desvio padrão, são amplamente utilizadas para a classificação de perturbações no sinal de energia [8]. Serão consideradas 6 características. Para um vetor $A_{m\acute{a}x}$, contendo N amostras, disposto no domínio tempo-frequência. Este é o vetor de máxima amplitude *versus* tempo, obtido após a aplicação da ST em um determinado sinal, com N amostras. A partir de $A_{m\acute{a}x}$, as 6 características são calculadas, conforme mostrado em (1)-(6):

- PE1: Máximo valor do vetor de máxima amplitude da ST:
$$m\acute{a}x = m\acute{a}ximo(A_{m\acute{a}x}) \quad (1)$$

- PE2: Mínimo valor do vetor de máxima amplitude da ST:
$$m\acute{in} = m\acute{in}imo(A_{m\acute{a}x}) \quad (2)$$

- PE3: Média do vetor de máxima amplitude da ST:
$$med = \frac{1}{N} \sum_{i=1}^N A_{m\acute{a}x_i} \quad (3)$$

- PE4: Desvio padrão do vetor de máxima amplitude da ST:
$$dvp = \sqrt{\frac{1}{N} \sum_{i=1}^N (A_{m\acute{a}x_i} - med)^2} \quad (4)$$

- PE5: Assimetria do vetor de máxima amplitude da ST:
$$ass = \frac{1}{(N-1)dvp^3} \sum_{i=1}^N (A_{m\acute{a}x_i} - med)^3 \quad (5)$$

- PE6: Curtose do vetor de máxima amplitude da ST:
$$cur = \frac{1}{(N-1)dvp^4} \sum_{i=1}^N (A_{m\acute{a}x_i} - med)^4 \quad (6)$$

3) *Rede Neural Artificial*: O modelo de rede neural utilizado foi do tipo MLP (*multilayer perceptron*). O número de neurônios da camada de entrada variou de quatro a seis, pois foram criados três grupos de vetores para compor o vetor entrada, conforme critérios que serão apresentados na etapa sobre resultados dos testes funcionais. Na camada oculta, segundo a topologia apresentada em [7], são utilizados doze neurônios. Para a segunda rede, este número foi definido de acordo com os testes que apresentaram melhor resultado e convergência mais rápida ao erro quadrático máximo permitido. Na camada de saída, para as duas redes propostas neste trabalho, existem quatro neurônios, com isso sendo

possível classificar os quatro diferentes tipos de distúrbios considerados.

Conforme [7], o algoritmo de aprendizagem RPROP (*resilient backpropagation*) elimina os efeitos prejudiciais da inclinação nos extremos da função de transferência sigmoide e geralmente é mais rápido que o algoritmo de retropropagação padrão. Este algoritmo utiliza apenas o sinal da derivada da função para determinar a direção das atualizações de peso, enquanto a magnitude da derivada não tem efeito sobre essas atualizações. Além disso, também tem a propriedade de não exigir um aumento significativo em requisitos de memória.

Foram definidas condições para parada do treinamento, com a finalidade de encontrar o ponto em que o erro de classificação fosse mínimo. Foi considerado um número máximo de quinze mil épocas. Outro critério de convergência considerado foi o mínimo erro quadrático médio por época. Considera-se que tenha ocorrido a convergência quando a taxa de variação do erro médio quadrado por época for pequena, na ordem de 0,1 a 1% [9].

III. RESULTADOS

A. Testes Funcionais

1. *Sinais Sintéticos*: As variações de tensão de curta duração sintéticas, apresentadas na Fig. 2, foram geradas a partir das equações e parâmetros da Tabela I e Tabela II, com variações de duração e amplitude aleatórias, respeitando os limites especificados. Foram geradas cem amostras de sinais de cada tipo de distúrbio, para formar a base de dados para treinamento da rede neural.




Fig. 2. Sinais sintéticos gerados. a) Sinal senoidal ideal. b) Sinal com distúrbio – elevação. c) Sinal com distúrbio – afundamento. d) Sinal com distúrbio – interrupção.

Com o intuito de avaliar o desempenho de classificação da rede frente a sinais expostos a diferentes condições, foram gerados novos conjuntos de dados. Essa base de dados para testes e validação ficou assim composta:

- Conjunto 1: Cem amostras de cada distúrbio, sem qualquer tipo de ruído;
- Conjunto 2: Cem amostras de cada distúrbio, com adição de ruído gaussiano de 20 dB;
- Conjunto 3: Cem amostras de cada distúrbio, com adição de ruído gaussiano de 30 dB;
- Conjunto 4: Cem amostras de cada distúrbio, com adição de ruído gaussiano de 40 dB;

- Conjunto 5: Cem amostras de cada distúrbio, misturados: com adição de ruído gaussiano de 20 dB e sem qualquer tipo de ruído.

Partindo de um sinal senoidal com 60 Hz, adotou-se, inicialmente uma frequência de amostragem de 3,2 kHz, o que equivale a 53,33 amostras por ciclo, assim definida levando-se em conta os trabalhos relacionados [2] e [7]. Os distúrbios são simulados em uma janela de dados correspondente a 12 ciclos.

Posteriormente, foram geradas, novas amostras de sinais com frequência de amostragem de 7,68 kHz, afim de avaliar e comparar a resposta final do sistema frente a esta diferença no número de amostras por ciclo.

2. *Transformada S*: A ST realiza a caracterização dos distúrbios pela sua magnitude e frequência. A forma complexa da matriz ST é calculada para cada distúrbio, em seguida, são obtidos os valores absolutos da matriz ST para extrair as informações em tempo-frequência. O valor máximo de cada coluna contém a informação relativa à principal frequência presente no sinal em um determinado momento. O valor máximo de cada linha fornece a informação relativa a amplitude máxima da referida frequência em todo tempo de amostragem [2]. Portanto, informações de amplitude, frequência e tempo podem ser obtidas para detectar, localizar e classificar as perturbações de QEE [7]. Na Fig. 3, apresenta-se o resultado, onde se pode realizar uma análise por inspeção dos sinais mostrados na Fig. 2. A aplicação da ST fornece uma matriz S composta por 640×640 elementos, com frequência fundamental de 60 Hz, quando a frequência de amostragem é 3,2 kHz.

Após a aplicação da ST, realizou-se a especificação do vetor de entrada para a rede neural, a partir das características calculadas sobre a matriz S.




Fig. 3. Transformada S dos sinais da Fig. 2. a) Sinal ideal. b) Sinal com elevação. c) Sinal com afundamento. d) Sinal com interrupção.

Uma forma de avaliar se a combinação dos parâmetros escolhidos auxilia a diferenciar os distúrbios envolvidos, consiste na análise por gráficos de dispersão. Estes gráficos separam e diferenciam com precisão as diferentes classes de distúrbios [7]. Cada análise é realizada com um par de características, calculadas sobre as cem amostras de cada classe de distúrbio, pode-se verificar na Fig. 4 e Fig. 5.

Verifica-se que os parâmetros escolhidos atendem aos requisitos de projeto, pois distinguem os distúrbios,

separando-os em regiões distintas do gráfico. Outrossim, verifica-se que, se a rede não for parametrizada de maneira adequada, há a possibilidade de não fazer distinção entre os afundamentos e interrupções de tensão, já que os parâmetros calculados sobre essas duas classes de distúrbios são próximos, chegando a haver sobreposição de valores.

Tendo sido realizada esta análise prévia, definiu-se três grupos distintos de vetores, para a realização de treinamentos. Os mesmos foram separados conforme Tabela III.




Fig. 4. Gráfico de Dispersão de PE1 vs PE2.




Fig. 5. Gráfico de Dispersão de PE3 vs PE4.

TABELA III – GRUPOS DE PARÂMETROS.

Parâmetros	Grupo 1	Grupo 2	Grupo 3
PE1			*
PE2	*	*	*
PE3	*	*	*
PE4	*	*	*
PE5	*	*	*
PE6		*	*

3. Rede Neural Artificial: Para distinção das duas configurações de redes neurais utilizadas, chamamos de Rede A e Rede B.

3.1 Rede Neural A: Os parâmetros de configuração desta rede neural foram baseados na topologia descrita em [7]. Na Tabela IV, estão seus parâmetros de configuração.

3.2 Rede Neural B: Na Tabela V, estão os parâmetros definidos para configuração da rede neural B.

TABELA IV – ARQUITETURA E PARÂMETROS DE TREINAMENTO DA REDE NEURAL A.

Arquitetura	Número de camadas	3
	Número de neurônios	Entrada: Variou-se de 4 a 6
		Oculto: 12
		Saída: 4
	Função de ativação	Tansig Tansig Logsig
Parâmetros de Treinamento	Regra de aprendizagem	Resilient backpropagation (rprop)
	Valor inicial do peso	0,01
	Taxa de aprendizagem	0,5
	Erro quadrático médio	1e-05
	Número máximo de iterações	15000

TABELA V – ARQUITETURA E PARÂMETROS DE TREINAMENTO DA REDE NEURAL B.

Arquitetura	Número de camadas	5
	Número de neurônios	Entrada: Variou-se de 4 a 6
		Oculto: [12 6 4]
		Saída: 4
	Função de ativação	Tansig Tansig Logsig Tansig Logsig
Parâmetros de Treinamento	Regra de aprendizagem	Resilient backpropagation (rprop)
	Valor inicial do peso	Aleatório
	Taxa de aprendizagem	0,5
	Erro quadrático médio	1e-05
	Número máximo de iterações	15000

B. Testes de Validação

1. Validação Rede Neural A

1.1 Validação para sinais com frequência de amostragem de 3,2 kHz

TABELA VI – VALIDAÇÃO REDE A (FS = 3,2 kHz).

Grupo de Caract.	Taxa de acerto				
	Conj. 1 Sem ruído	Conj. 2 20 dB	Conj. 3 30 dB	Conj. 4 40 dB	Conj. 5 Misturados
Grupo 1	96,0%	68,3%	72,3%	77,0%	83,5%
Grupo 2	96,5%	69,3%	73,0%	79,5%	83,3%
Grupo 3	97,0%	71,0%	73,0%	78,0%	83,5%

1.2 Validação para sinais com frequência de amostragem de 7,68 kHz

TABELA VII – VALIDAÇÃO REDE A (FS = 7,68 kHz).

Grupo de Caract.	Taxa de acerto				
	Conj. 1 Sem ruído	Conj. 2 20 dB	Conj. 3 30 dB	Conj. 4 40 dB	Conj. 5 Misturados
Grupo 1	98,8%	72,5%	74,3%	74,0%	85,0%
Grupo 2	98,5%	72,3%	73,3%	72,8%	85,0%
Grupo 3	98,8%	71,8%	73,5%	74,8%	85,0%

2. Validação Rede Neural B

2.1 Validação para sinais com frequência de amostragem de 3,2 kHz

TABELA VIII – VALIDAÇÃO REDE B (FS = 3,2 kHz).

Grupo de Caract.	Taxa de acerto				
	Conj. 1 Sem ruído	Conj. 2 20 dB	Conj. 3 30 dB	Conj. 4 40 dB	Conj. 5 Misturados
Grupo 1	95,3%	68,0%	70,5%	73,5%	82,5%
Grupo 2	94,0%	67,3%	71,5%	76,0%	82,0%
Grupo 3	93,8%	66,3%	69,3%	72,3%	81,3%

2.2 Validação para sinais com frequência de amostragem de 7,68 kHz

TABELA IX – VALIDAÇÃO REDE B (FS = 7,68 kHz).

Grupo de Caract.	Taxa de acerto				
	Conj. 1 Sem ruído	Conj. 2 20 dB	Conj. 3 30 dB	Conj. 4 40 dB	Conj. 5 Misturados
Grupo 1	98,5%	71,5%	73,0%	73,5%	84,3%
Grupo 2	98,0%	73,0%	74,8%	76,3%	85,0%
Grupo 3	97,3%	72,5%	72,0%	71,3%	84,3%

O PRODIST (módulo 8), não especifica os limites toleráveis em relação ao nível de ruído no sinal de energia a ser monitorado. No entanto, a norma IEEE 1159 [10], recomenda que o valor de ruído presente no sinal monitorado seja inferior à 1% de sua amplitude. Assim, verifica-se que a máxima relação sinal-ruído em um sinal, de tal modo que permaneça dentro dos valores pré-estabelecidos por norma é de 40 dB, conforme pode ser verificado em (7), consultada em [11].

$$SNR_{dB} = 20 \log_{10} SNR = 20 \log_{10} \left(\frac{V_{SINAL}}{V_{RUÍDO}} \right)$$

$$SNR_{dB} = 20 \log_{10} \left(\frac{1 pu}{0,01 pu} \right) = 40 dB \quad (7)$$

Do mesmo modo, a relação sinal-ruído de 20 dB, corresponde a 10% da amplitude do sinal de energia e a relação sinal ruído de 30 dB, corresponde a 3,16% da amplitude do sinal. Para valores fora dos padrões estabelecidos, a IEEE 1159, recomenda que os problemas sejam atenuados com a utilização de filtros, condicionadores de linha ou transformadores de isolamento.

Supondo que em um caso real, fosse aplicada uma solução (filtros) a estes sinais com ruído acima da faixa determinada pela norma e que o sistema classificador proposto recebesse apenas sinais com ruído abaixo de 40 dB, teríamos uma taxa de acerto entre 71,3% a 98,8%, conforme validações apresentadas.

3. Validação com sinais reais: Esse conjunto de dados é composto por sinais reais com afundamentos de tensão em conjunto com sinais sintéticos ideais, elevações de curta duração e interrupções de tensão.

As oscilografias reais foram registradas por um analisador de energia MARH-21. Essas oscilografias foram medidas em um consumidor que apresentava problemas de QEE e foram fornecidas pela área responsável, da concessionária de Energia Elétrica local.

Utilizou-se o *software* ANAWIN, para análise prática e direta dos dados, fornecido juntamente com o registrador e com o

qual foi possível exportar os dados para um arquivo em formato Excel. Os dados foram registrados no modo 10 (grandezas mais perturbações). Conforme manual do fabricante, este modo registra os dados em uma taxa de amostragem de 64 amostras por ciclo, ou seja, a frequência de amostragem é de 3,84 kHz.

Sobre esse novo conjunto formado, foi aplicada a ST, calculado suas características e formados os grupos 1, 2 e 3, seguindo o mesmo procedimento descrito para sinais sintéticos. Recebendo como entrada este conjunto, as redes neurais A e B apresentaram as taxas de acertos gerais descritas na Tabela X.

TABELA X – TAXA DE ACERTO REDE A E REDE B, FRENTE À UM CONJUNTO COM SINAIS REAIS.

Grupo de Caract.	Taxa de acerto	
	Rede Neural A	Rede Neural B
Grupo 1	98,5%	97,5%
Grupo 2	98,5%	96,8%
Grupo 3	99,0%	97,3%

4. Comparação de resultados: Apresenta-se, na Tabela XI, um resumo comparativo com os resultados dos principais trabalhos pesquisados envolvendo classificação de distúrbios que afetam a qualidade de energia.

TABELA XI – COMPARATIVO COM OUTROS TRABALHOS

Referência	Tipo de Classificador	Tipo de Dados	Nº de Classes de Distúrbios	Taxa de acerto
[2]	Rede Neural + Árvore de Decisão	Sintéticos	13	99,9%
[7]	ST + Rede Neural	Sintéticos	9	99,67%
[6]	ST + Árvore de Decisão	Sintéticos	15	94,42%
[12]	ASN + RNA ARTMAP-Fuzzy	Sintéticos	7	100%
[13]	TWD + RNA	Sintéticos	4	100%
[14]	ST+ SVM	Reais	7	95,15%
Este trabalho	ST + RNA	Reais	4	99,8%

O percentual de acerto apresentado, deste trabalho, refere-se ao resultado obtido pela Rede A, quando o grupo 1 de características dos afundamentos de tensão reais foi apresentado. Este resultado superou o desempenho apresentado em [6]; [7] e [14].

Verifica-se que a grande maioria dos trabalhos considera testes com sinais sintéticos e não reais, gerados seguindo os mesmos critérios aqui apresentados, e mesmo com estes, não alcançam uma taxa de acerto de 100%, exceto os trabalhos [13] e [12], os quais obtiveram acertos nesta ordem.

Por fim, apresenta-se um comparativo mais detalhado com o trabalho [7], já que esta foi a principal referência utilizada e tomada como base para implementação da Rede Neural A. Tanto para a Rede A quanto para a Rede B, os resultados da Tabela XII novamente referem-se à validação realizada quando o grupo 1 de características foi calculado para os diferentes conjuntos de sinais teste.

Verifica-se que, sob ruído o resultado fica bastante prejudicado, para ambas as redes. Ademais, para os sinais sem ruído e sinais reais, obtidos com auxílio de um qualímetro, os resultados alcançam um patamar acima de 95%, o que demonstra a eficácia do sistema classificador.

TABELA XII – COMPARATIVO ENTRE REDES.

Referência	Taxa de acerto [%]					
	Sem ruído	20 dB	30 dB	40 dB	Misturados	Reais
[7]	99,67	94,0	99,11	99,56	-	-
Rede A	98,8	72,5	74,3	74,0	85,0	99,8
Rede B	95,3	68,00	70,5	73,5	82,5	99,5

IV. CONSIDERAÇÕES FINAIS

O presente trabalho consistiu no desenvolvimento de um classificador de variações de tensão de curta duração no sinal de energia elétrica. Foram utilizadas: uma técnica de pré-processamento de sinais baseada na Transformada de Stockwell, a partir da qual foram extraídos recursos para alimentar Redes Neurais Artificiais, o que possibilitou a classificação dos eventos considerados.

A partir dos resultados obtidos, há de se destacar que a preparação dos dados, pela técnica de pré-processamento proposta, facilitou e promoveu a convergência dos treinamentos das Redes Neurais Artificiais, fornecendo, por consequência, resultados satisfatórios na classificação das perturbações de qualidade de energia.

Com relação a taxa de amostragem utilizada para geração dos sinais sintéticos, foi notado que frente a um aumento de 3,2 kHz para 7,68 kHz, houve também um percentual de aumento em torno de 2%, na taxa de acertos, durante a etapa de validação. Possivelmente, isso se dá pelo fato de um maior número de amostras em cada ciclo possibilitar uma melhor precisão no cálculo das características consideradas, para formar o vetor base de entrada das Redes. A taxa de 53,33 amostras por ciclo foi utilizada devido às referências apresentadas, o que possibilitou realizar um comparativo inicial entre resultados. Já a escolha da taxa de amostragem de 128 amostras por ciclo se deu por ser comumente utilizada para registros de dados reais em oscilógrafos, apesar de neste trabalho terem sido utilizadas oscilografias reais registradas com uma frequência de amostragem de 3,84 kHz.

Durante toda etapa de validação, as Redes Neurais receberam como entrada conjuntos de dados diferentes daqueles utilizados no processo de treinamento. Isto é essencial para se verificar a integridade dos treinamentos realizados e a capacidade de generalização das redes. Além disso, foi testada a sensibilidade do classificador quando os sinais estavam sob influência de ruídos. Também fez parte da etapa de validação, testes com oscilografias reais contendo afundamentos de tensão, obtidas por um analisador de qualidade de energia. Tanto a Rede Neural A, quanto a Rede Neural B, se mostraram eficazes na classificação destes distúrbios, apresentando uma taxa de acerto acima de 95% na classificação. Foi também realizada uma comparação com estudos anteriores em termos de precisão de classificação, o que demonstrou que os resultados obtidos estão coerentes.

O que se destaca no sistema proposto é a redução no tamanho dos dados, quando aplicada a ST e calculados os parâmetros dos grupos 1, 2 e 3, sem que as características distintivas das classes de distúrbios fossem perdidas. Considera-se isto como uma vantagem que pode aumentar a velocidade de convergência das redes neurais e reduzir o espaço de memória requerido.

Outro aspecto diferenciado do trabalho foi o uso de sinais reais para a validação da implementação. Poucas referências

apresentam resultados usando distúrbios medidos na rede de energia em operação. Neste sentido, o controle sobre a amostra é bem menor, visto que o sinal está sujeito a qualquer tipo de distúrbio e não somente aos que foram gerados de forma sintética. Mesmo para esses sinais, os resultados foram bastante significativos com alta taxa de acerto, como apresentado.

Com tudo isso, sugere-se como trabalhos posteriores a aplicação da mesma metodologia, sendo analisados diferentes parâmetros para formar o vetor de entrada para a rede neural e também novas configurações para a mesma. Além disso, para tornar o protótipo classificador mais amplo, considera-se a oportunidade de acréscimo de classes de distúrbios. Outro ponto relevante seria a implementação da metodologia para uso em tempo real, avaliando sua confiabilidade e eficiência.

V. REFERÊNCIAS

- [1] Agência Nacional de Energia Elétrica - ANEEL, "Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST: Módulo 8 - Qualidade de Energia Elétrica. Revisão 6. Resolução Normativa 641/2014," [Online]. Available: <http://www.aneel.gov.br>. [Acesso em agosto 2015].
- [2] R. Kumar et al., "Recognition of power quality disturbances using S transform based ANN classifier and rule based decision tree," *IEEE Transactions on Industry Applications*, vol. 51, 2015.
- [3] A. A. P. Biscaro, "Proposta de algoritmos inteligentes para localizar faltas e monitorar a qualidade da energia em redes de distribuição," 2013.
- [4] R. C. Dugan, M. F. Mcgranaghan, S. Santoso and W. Beaty, *Electrical Power Systems Quality*, 3^a ed., McGraw-Hill, 2012.
- [5] G. Jain, R. Grosh and S. Dalai, "Identification of power system transients using recurrence plot analysis," *ICPDEN*, 2015.
- [6] G. G. Peña, "Análise de eventos em redes de distribuição por meio das transformadas wavelet e S," São Carlos, 2012.
- [7] M. Uyar, S. Yildirim and M. T. Gencoglu, "An expert system based on S transform and neural network for automatic classification of power quality disturbances," *Expert System with Applications*, vol. 36, 2009.
- [8] S. Kaewarsa, "Classification of power disturbances using S-transform based artificial neural networks," 2009.
- [9] S. Haykin, *Redes Neurais*, 2^a ed., Porto Alegre: Bookman, 2001.
- [10] IEEE Standards Board, *IEEE STD 1159 - 2009: Recommended practice for monitoring electric power quality*, 2009.
- [11] A. B. Forouzan, *Comunicação de dados e redes de computadores*, 4^a ed., Bookman, 2008.
- [12] J. C. Silva, F. P. A. Lima and C. R. Minussi, "Diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica," *Ilha Solteira*, 2014.
- [13] S. Kamble and I. Dupare, "Detection of power quality disturbances using wavelet transform and artificial neural network," *International Conference on Magnetism, Machines e Drives - AICERA, iCMMD*, 2014.
- [14] P. K. Ray et al., "Optimal feature and decision tree - based classification of power quality disturbances in distributed generation systems," *IEEE Transactions on Sustainable Energy*, vol. 5, no. 1, 2014.
- [15] R. G. Stockwell, L. Mansinha and R. P. Lowe, "Localization of the complex spectrum: S Transform," *IEEE Transactions on signal processing*, vol. 44, 1996.