

# DETECTION OF VOLTAGE UNBALANCE IN MICROGRIDS USING ARTIFICIAL NEURAL NETWORKS

Roberta Carvalho Marques

Faculdade de Engenharia de Ilha Solteira – FEIS  
Universidade Estadual Paulista “Júlio de Mesquita Filho” –  
UNESP  
Ilha solteira, Brasil  
[rc.marques@unesp.br](mailto:rc.marques@unesp.br)

Dionizio Paschoareli Junior

Faculdade de Engenharia de Ilha Solteira – FEIS  
Universidade Estadual Paulista “Júlio de Mesquita Filho” –  
UNESP  
Ilha solteira, Brasil  
[dionizio.paschoareli@unesp.br](mailto:dionizio.paschoareli@unesp.br)

**Abstract**— This work proposes a methodology for detecting voltage unbalance using the OpenDSS software and COM interface. Perceptron Multilayer Artificial Neural Network is used to detect voltage unbalances. Communication between OpenDSS and MATLAB is established to simulate a microgrid composed of distributed generators, energy storages, single- and three-phase loads. Studies are carried out in the IEEE 13 bus test system.

**Keywords**— voltage unbalance, Artificial neural networks, OpenDSS.

## I. INTRODUÇÃO

A sociedade é cada vez mais dependente de um fornecimento de energia elétrica seguro, confiável e nos altos padrões de qualidade estabelecidos nas normas reguladoras. Neste contexto, tais requisitos devem ser, guardadas as devidas distinções técnicas, estendidos para as microrredes de energia elétrica. As microrredes têm sido indicadas como alternativas para o fornecimento de energia em localidades isoladas ou mesmo como condição operacional transitória em situação de contingência. O ilhamento de parte do sistema interligado e consequente operação na condição de microrrede reduz a duração dos desligamentos para uma parcela dos consumidores. As microrredes são normalmente definidas partir do uso de recursos energéticos distribuídos (DERs – distributed energy resources), que incluem geradores e armazenadores de energia, e cargas diversas monofásicas ou trifásicas. Tipicamente, estes sistemas possuem controles inteligentes para o adequado compartilhamento da energia armazenada ou gerada a partir de diversas fontes (de pequena potência e baixa tensão) e para compatibilidade entre a geração disponível e a carga demandada ([1], [2]). Esta condição de operação dá uma dinâmica muito particular à operação das microrredes.

Devido às particularidades técnicas e operacionais das microrredes, a garantia da qualidade da tensão em todos os pontos de conexão do sistema torna-se um grande desafio. Isto porque os recursos energéticos distribuídos, assim como as cargas, podem ser monofásicos, desequilibrando a microrrede. Aliás, o desequilíbrio de tensão é um tipo de distúrbio na qualidade da energia elétrica muito recorrente nas microrredes [3].

Como consequência dos desequilíbrios ocorre o aumento das perdas ôhmicas na rede, a má operação de cargas trifásicas com perda na vida útil dos equipamentos, a operação indevida da proteção (particularmente de sequência zero), entre outras. Devido as consequências dos desequilíbrios, é muito importante a detecção desses distúrbios para que ações saneadoras sejam tomadas. Várias técnicas para detecção de desequilíbrios têm sido propostas na literatura, como a norma NEMA (*National Electrical Manufacturers Association of USA*), o método IEEE, método das componentes simétricas e o método do Cigré [4], entre outras.

Para a detecção dos desequilíbrios, as redes neurais artificiais (RNAs) mostram-se como ferramentas bastante adequadas, uma vez que permitem o reconhecimento e a classificação de padrões, a aproximação de funções, a otimização e agrupamento de dados [5]. Sendo assim, este trabalho propõe a utilização das RNAs calculada com o uso do simulador MATLAB® a partir da interface COM (Component Object Model) do programa de simulação OpenDSS para identificação dos desequilíbrios das fases de tensão. Os dados considerados nas simulações foram forçados a ter o desequilíbrio de tensão para testar a eficácia da RNA.

## II. DETECÇÃO DE DESEQUILÍBRIOS

A metodologia proposta nesse trabalho para detecção de desequilíbrio de tensão em microrredes é baseada em RNAs *perceptron* de multicamadas. Uma microrrede é modelada e simulada utilizando-se o simulador OpenDSS, onde é calculado o fluxo de potência de uma microrrede com desequilíbrios de geração e carga. Os resultados do cálculo do fluxo de potência obtidos no OpenDSS são tratados para que sejam inseridos como dados de entrada no simulador Matlab®. No simulador Matlab®, os desequilíbrios de tensão são detectados e tratados por uma RNA *perceptron* de multicamadas. A Fig. 1 ilustra este fluxo de informações entre o OpenDSS e o Matlab®.

<https://doi.org/10.53316/sepoc2021.041>




Fig. 1. Interação entre o OpenDSS e o Matlab® (próprio autor)

## II.1 OpenDSS

O OpenDSS é um programa de simulação para sistemas de distribuição de energia elétrica baseado em linhas de comando, que definem os circuitos. As linhas podem ser criadas pelo próprio usuário, a partir de um arquivo de texto fixo, ou obtidas de outros programas através da interface COM da Microsoft [6]. A interface COM permite aos usuários projetar e executar modos de soluções próprios através de outros programas.

O OpenDSS pode ser utilizado para análises de geração distribuída, eficiência energética e análise de distorções. As principais análises obtidas com a utilização do programa [7] são:

- fluxo de potência (snapshot, diário e anual);
- distorções harmônicas;
- operação dinâmica do sistema;
- estudos de curto circuito.

Os resultados deste trabalho são obtidos através dos programas OpenDSS e Matlab® associados através da interface COM.

## II.2 Rede Neural Artificial (RNA)

As RNAs são estruturas baseadas no funcionamento do cérebro humano. A RNA apresenta uma grande versatilidade na solução de problemas como reconhecimento de padrões, compreensão de voz, identificação de imagens, pilotos automáticos, sistemas de previsões, desenvolvimento de produtos, controle de processos, análises de formas de ondas, entre outros [8].

As RNAs são compostas por unidades de processamento de informações, que são denominados neurônios artificiais e emulam o funcionamento do cérebro humano. As unidades de processamento, ou neurônios, têm a capacidade de armazenar informações através de um processo de aprendizagem [9]. Diferentemente de outros algoritmos e de máquinas que são programadas para fazer determinada tarefa, a RNA é treinada por dados de exemplos para realizar alguma função. Assim, o algoritmo de aprendizagem universaliza os dados e memoriza as informações dentro dos parâmetros adaptáveis (pesos sinápticos). Cada neurônio artificial pode ter  $n$  entradas que são usadas para calcular um sinal de saída que é enviado para outros neurônios. A rede precisa em seus neurônios de uma função de ativação que utiliza o somatório das entradas multiplicado por pesos para produzir um novo valor de saída no neurônio. A forma com que os neurônios ligam-se entre si está diretamente relacionada ao algoritmo de aprendizagem escolhido para treinar a rede. Existem diversas arquiteturas de rede, as quais são classificadas entre redes *feedforward*, onde o fluxo de dados

é sempre para frente, e *recurrent*, onde contém laços de realimentação, ou seja, contém conexões das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores. [10]. Devido à sua robustez e aplicabilidade em problemas complexos, com resultados satisfatórios, a rede escolhida para este trabalho é a *perceptron* de multicamadas, classificada como *feedforward*.

As redes *perceptron* de multicamadas consistem no conjunto de  $n$  neurônios que formam a camada de entrada, uma ou mais camadas escondidas, e uma camada de saída. Elas são redes *feedforward*, em que o sinal de entrada se propaga para frente. Como ilustrado na Fig. 2, o fluxo de dados percorre cada camada até chegar na camada de saída. Neste caso, as saídas dos neurônios da primeira camada são as entradas dos neurônios na segunda camada e assim sucessivamente. Os dados iniciais são identificados em sua camada de entrada. As camadas escondidas utilizam dos dados iniciais e as codificam por meio dos pesos sinápticos e da função de ativação presente em cada neurônio, criando sua própria representação do ambiente em que o sistema a ser tratado está inserido. Por fim, os neurônios da camada final recebem as informações dos neurônios da última camada escondidas, elaborando o padrão de resposta. O ajuste dos pesos sinápticos de cada um dos neurônios da rede é feito através de algoritmos de aprendizagem. No caso das redes *perceptron* de multicamadas, o algoritmo de aprendizagem é o de retropropagação do erro (*backpropagation*) [11].




Fig. 2. Estrutura de uma RNA *perceptron* de multicamadas

### II.2.1 Backpropagation

O algoritmo de aprendizagem *backpropagation* é um método de ajuste dos pesos baseado no erro quadrático dos neurônios de saída. Esse procedimento envolve apresentação de padrões tanto de entrada como saída. Em seguida calcula-se o erro de cada saída (diferença entre o valor desejado e a saída). O próximo passo consiste na determinação do erro propagado no sentido inverso, através da rede associada à derivada parcial do erro quadrático de cada elemento com relação aos pesos e, finalmente, ajustando os pesos de cada elemento, o processo é repetido, para todos os padrões, até a convergência [12]. A rede é inicializada com seus pesos gerados com valores pequenos e de forma randômica. O algoritmo usa inicialmente o vetor de entrada para produzir seu próprio vetor de saída e assim comparar com a saída desejada. Se existir diferença, os pesos são alterados até que se reduza essa diferença a precisão

requerida ( $\epsilon$ ). Caso contrário, não existe aprendizado. A regra para se alterar os pesos é dada pela equação (1)

$$e_j(n) = d_j(n) - y_i(n) \quad (1)$$

onde:

e:

$j, i$ : são os neurônios, sendo que  $j$  está na camada à direita de  $i$

$n$ : é o  $n$ -ésimo padrão de treinamento que é apresentado a rede, e refere-se ao sinal do erro da saída do neurônio

$d$ : é o vetor da saída desejada

$y$ : é o vetor da saída real da rede

A equação do erro quadrático  $E(n)$  é calculada pela equação (2).

$$E(n) = \frac{1}{2} \sum_{j=1}^n e_j^2(n) \quad (2)$$

Considerando  $N$  o número total de amostras de treinamento, a estimação do desempenho global do algoritmo é efetuada através do erro médio quadrático ( $E_m$ ) como visto na equação (3).

$$E_m(n) = \frac{1}{N} \sum_{n=1}^N E(n) \quad (3)$$

Para cada conjunto de dados de treinamento,  $E_m$  é uma medida do desempenho de aprendizagem da rede e a cada interação o objetivo é diminuir o  $E_m$  até que fique igual ou menor a uma precisão estipulada ( $\epsilon$ ). O algoritmo pode ser dividido em duas partes: uma *forward* (propagação) e outra *backward* (retropropagação). Na fase *forward* tem-se o cálculo dos campos induzidos, que é a soma de todas as entradas do neurônio  $j$  na camada  $l$ , da rede pela equação (4).

$$v_j^{(l)}(n) = \sum_{i=0}^{m0} w_{ij}^{(l)} y_i^{(l-1)}(n) \quad (4)$$

onde:

$v_j^{(l)}$ : é campo local induzido na camada  $l$

$y_i^{(l-1)}(n)$ : é a função de saída do neurônio  $i$  na camada anterior

$w_{ij}^{(l)}$ : é o peso sináptico do neurônio  $j$  da camada  $l$  que é alimentado pela neurônio  $i$  da camada  $l-1$

$m0$ : tamanho da camada de entrada

A função de ativação é a sigmoide descrita pela equação (5).

$$\varphi = \frac{\{1 - e^{(-\lambda s)}\}}{\{1 + e^{(-\lambda s)}\}} \quad (5)$$

para  $-1 \leq \varphi \leq 1$

onde:

$s$ : é a saída intermediária do neurônio

$\lambda$ : é a inclinação da função sigmoide a qual teve valor definido 0,5 através de tentativa e erro.

O sinal de saída do neurônio  $j$  na camada  $l$  é dado pela equação 6.

$$y_j^{(l)} = \varphi_j(v_j(n)) \quad (6)$$

Se o neurônio estiver na primeira camada, a equação se torna a equação 7, com  $l=1$ .

$$y_j^{(1)}(n) = x_j(n) \quad (7)$$

Onde  $x$  é o  $j$ -ésimo elemento do vetor de entrada.

Depois desta etapa é calculado o sinal do erro através da equação (1).

Passando para a fase de *backward*, onde são calculados os gradientes locais, que são as modificações necessárias nos pesos a cada iteração da rede, definidos pelas equações (8), para o neurônio  $j$  da camada de saída  $L$  e (9), para o neurônio  $j$  da camada oculta  $l$ .

$$\delta_j^{(L)} = e_j^{(L)}(n) \varphi_j'(v_j^{(L)}(n)) \quad (8)$$

$$\delta_j^{(l)} = \varphi_j'(v_j^{(l)}(n)) \sum_k^j \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \quad (9)$$

Com os gradientes locais calculados o ajuste dos pesos sinápticos ( $w_{ji}^l$ ) é feito através da equação (10).

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha [w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (10)$$

onde

$\eta$ : é o parâmetro da taxa de aprendizagem

$\alpha$ : é a constante de momento.

A constante de momento visa ponderar o quão as matrizes dos pesos sinápticos foram alteradas entre duas alterações anteriores ou sucessivas. Deste modo, é repetido todo esse processo até que seja satisfeito o critério de parada que é quando o erro médio entre duas épocas sucessivas seja menor ou igual à precisão requerida  $\epsilon$  e ou atingido o número máximo de épocas [13]

### III. TESTE DE DESEQUILÍBRIO DE TENSÃO EM UMA MICRORREDE

A rede teste IEEE 13 original, apesar de ter um número pequeno de barras, apresenta linhas trifásicas aéreas e subterrâneas desbalanceadas, ramais bifásicos e trifásicos de distribuição, cargas distribuídas, dois bancos de capacitores shunt e um regulador de tensão conectado em estrela [14]. Para torná-la uma microrrede algumas alterações na rede foram feitas dentre elas, uma chave de manobra foi inserida entre a subestação (barra 650) e a barra 632, permitindo a desconexão da rede principal. Também foi necessário adicionar geradores distribuídos que atendessem a demanda de energia elétrica da

microrrede operando em modo ilhado. Desta maneira, foi adicionado um gerador trifásico na barra 646, um gerador bifásico na barra 611 e sistemas fotovoltaicos com armazenamento de energia nas barras 680 e 675. O diagrama unifilar da microrrede é apresentado na Fig. 3.

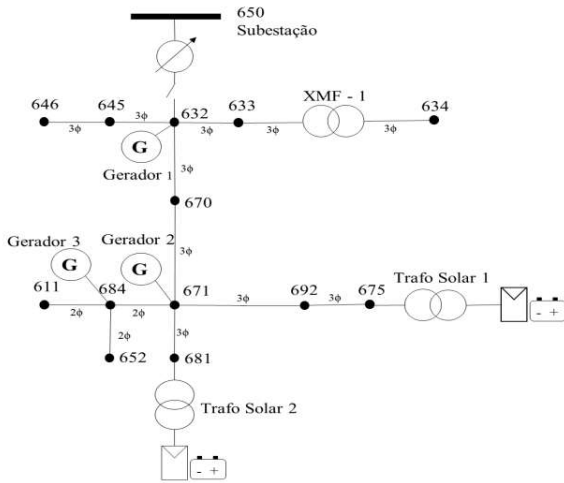


Fig. 3. Diagrama unifilar da microrrede teste

Para as simulações realizadas nesse trabalho foi utilizada uma curva de carga comercial típica para todas as cargas da microrrede. O padrão da curva é representado pela Fig. 4, com o valor da carga expresso em pu período de 24 horas. O maior consumo de energia elétrica é observado entre 10 horas e 18 horas.



Fig. 4. Curva de carga comercial

As cargas concentradas da microrrede estão apresentadas na Tabela 1.

TABELA 1 CARGAS CONCENTRADAS NA MICRORREDE

Barra	Carga	Fase A		Fase B		Fase C	
		Conexão-Modelo	KW	Kvar	KW	Kvar	KW
634	Y-PQ	160	110	120	90	120	90
645	Y-PQ	0	0	170	125	0	0
646	D-Z	0	0	230	132	0	0
652	Y-Z	128	86	0	0	0	0
971	D-PQ	385	220	385	220	385	220
675	Y-PQ	485	190	68	60	290	212
692	D-I	0	0	0	0	170	151
611	Y-I	0	0	0	0	170	80

Vale a pena ressaltar que a rede possui em maioria cargas monofásicas e como analisado nas tabelas elas estão bem desequilibradas. Na rede teste tem uma carga distribuída entre os nós 632 e 671, para fins de simulação o equivalente dessa carga está na barra virtual 670, essa carga está representada na Tabela 2.

TABELA 2 CARGA DISTRIBUÍDA DA MICRORREDE

Trecho	Carga	Fase A		Fase B		Fase C	
		Conexão-Modelo	KW	Kvar	KW	KVar	KW
632-671	Y-PQ	17	10	66	38	117	68

Geradores síncronos são alocados nas barras 632, 671 e 684 e suas características nominais de funcionamento estão apresentadas na Tabela 3.

TABELA 3 CARATERÍSTICAS DOS GERADORES DAS BARRAS 646 E 611

Gerador	Número de fases	Barra	Tensão Nominal (kV)	Potência ativa (kW)
Gerador 1	3	632	4,16	300
Gerador 2	2	671	4,16	1000
Gerador 3	2	684	4,16	100

Há ainda dois sistemas de geração fotovoltaica conectados nas barras 675 e 681, com as mesmas características nominais, conforme descrito na Tabela 4. Estes sistemas fotovoltaicos carregam os armazenadores de energia elétrica que estão conectados junto à rede.

TABELA 4 CARACTERÍSTICAS DOS SISTEMAS FOTOVOLTAICOS DA MICRORREDE

Tensão (V)	480
Potência nominal (kWp)	600
Pmpp (kW)	500

Os valores apresentados na Tabela 4 são baseados nas condições padrões de teste (STC) para irradiância de 1 kW/m<sup>2</sup> e temperatura de 25 °C [15]. Cada sistema tem um inversor de 600 kVA e potência aparente. Os sistemas fotovoltaicos possuem armazenadores de energia com as características descritas na Tabela 5.

TABELA 5 CARACTERÍSTICAS DOS ARMZENADORES DE ENERGIA

Tensão (kV)	480
Potência (kW)	350
Capacidade de armazenamento (kWh)	2000
Modo de despacho	follow

Destaca-se o modo de despacho de energia do armazenador, que é o modo *follow*. Esse modo segue uma curva a qual carrega durante o dia com o sistema fotovoltaico e despacha a energia para a rede durante a noite.

São realizadas simulações com a microrrede desconectada da rede geral de distribuição. As tensões calculadas pelo programa de simulação OpenDSS são registradas em intervalos horários. Os resultados do cálculo das tensões são, então, enviados ao Matlab® através da interface COM. O programa Matlab® identifica distúrbios da tensão utilizando RNA *perceptron* de multicamadas. O processo de cálculo da RNA é apresentado um fluxograma na Fig. 5.

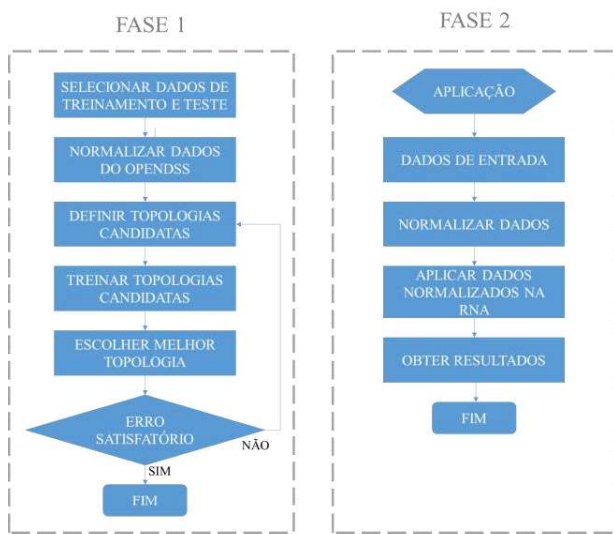


Fig. 5 Fluxograma do funcionamento da RNA

### III.1 Fase 1

Na fase 1 é feita a etapa de treinamento da microrrede. Para treinamento da rede neural, são considerados 100% das tensões nas barras decorrentes da simulação do OpenDSS no intervalo de 48 horas e os dados utilizados para detectar desequilíbrio de tensão foram as fases das barras trifásicas, totalizando 384 amostras de dados.

Como os dados de entrada da RNA são valores grandes, há a necessidade de normalizá-los, objetivando melhorar o desempenho da rede neural. Desta forma, os dados atendem a faixa de variação dinâmica da função de ativação sigmoide descrita da equação (5), entre -1 e 1. Esta transformação é feita utilizando o Teorema de Tales [11].

Após a normalização de dados é feita a escolha de topologias candidatas para a RNA, utilizando o método de Fletcher-Gloss [11]. A Equação (10) é utilizada para se determinar o número de neurônios na camada escondida ( $r_1$ ), que irá definir as possíveis topologias da rede neural.

$$2\sqrt{r} + r_2 \leq r_1 \leq 2r + 1 \quad (10)$$

Onde:

$r$  : é o número de entradas da rede

$r_1$ : é a quantidade de neurônios na camada escondida

$r_2$ : é a quantidade de neurônios na camada de saída.

Para detecção de desequilíbrio de tensão tem-se 3 entradas, que são as fases da barra naquele instante de tempo, e uma saída, que é a situação em a barra se encontra naquele instante tempo (equilibrada ou desequilibrada).

A definição das topologias candidatas se deu em:

$$4,46 \leq r_1 \leq 7$$

Desta maneira, uma vez que a quantidade de neurônios deve ser um número inteiro na camada escondida, definiu-se três possíveis topologias: a primeira com cinco neurônios na camada escondida, a segunda com seis e a terceira com sete. Ao iniciar as simulações computacionais, os valores de pesos são inicializados de forma randômica, com valores pequenos utilizando uma distribuição uniforme entre  $-2,4/r$  e  $2,4/r$ , conforme a literatura, sendo  $r$  o número de entradas [14]. Na Tabela 6 são apresentados os resultados da porcentagem de acertos da RNA para cada simulação das topologias candidatas.

TABELA 6 RESULTADOS DAS POSSÍVEIS RNAS

Número de neurônios na camada escondida	Acertos (%)	Número de épocas	Tempo de processamento (s)
4	96,9	2793	39,89
5	98,4	3986	56,43
6	98,4	2943	59,44
7	98,4	4478	56,03
8	97,9	5788	59,55

Para certificar-se que o método de Fletcher-Gloss é um método adequado para este trabalho, foram adicionadas simulações com topologia de 4 e de 8 neurônios escondidos (primeira e última linhas da Tabela 4). É possível observar um resultado inferior no percentual de acertos.

Como destacado na segunda linha da Tabela 4, a topologia escolhida foi a de 5 neurônios na camada escondida. Esta topologia apresenta o mesmo resultado em porcentagem de acertos (98,4%) que as topologias com 6 e 7 neurônios, mas com um menor número de neurônios. O menor número de neurônios com uma alta porcentagem de acertos significa maior capacidade de aprendizado da RNA.

### III.2 Fase 2

Após treinar a rede neural e obter o erro satisfatório com a topologia escolhida, a metodologia entra na fase de aplicação, onde se obtém os resultados para o desequilíbrio de tensão da microrrede. O procedimento é parecido com a fase de treinamento. Porém, não se tem a atualização dos pesos que ocorre a cada época (interação) na fase 1 (de treinamento) e o algoritmo é rodado apenas uma vez. O gráfico com os dados de entrada na RNA é apresentado na Fig. 6. Esses dados são os resultados de simulação do OpenDSS entre as horas 48 e 72 (terceiro dia) na barra 692.



Fig. 6. Gráfico das fases das tensões na Barra 692 no dia 3 em modo ilhado.

Com a análise dos dados de entrada e com base do que se sabe de desequilíbrio de tensão utilizando os valores de fase das tensões se espera que a RNA retorne estado desequilibrado em todos os horários. O relatório com os resultados está exposto na Fig. 7.

RELATÓRIO		
ESTADO	HORA	BARRA
desequilibrado	1	692
desequilibrado	2	
desequilibrado	3	
desequilibrado	4	
desequilibrado	5	
desequilibrado	6	
desequilibrado	7	
desequilibrado	8	
desequilibrado	9	
desequilibrado	10	
desequilibrado	11	
desequilibrado	12	
desequilibrado	13	
desequilibrado	14	
desequilibrado	15	
desequilibrado	16	
desequilibrado	17	
desequilibrado	18	
desequilibrado	19	
equilibrado	20	
equilibrado	21	
desequilibrado	22	
desequilibrado	23	
desequilibrado	24	

Fig. 7. Relatório da metodologia para a barra 692.

Como a rede neural não teve 100% de acertos alguns horários, como por exemplo, a hora 20 e 21 da barra 692 retornaram a resposta equilibrado. Para fins de comparação e validação da metodologia foi feita a mesma análise para a microrrede conectada à rede geral de distribuição. Os valores de fase das tensões da mesma barra 692 e para o mesmo período de dia estão no gráfico da Fig 8.




Fig. 7. Gráfico das fases das tensões na Barra 692 no dia 3 em modo normal.

A microrrede quando conectada à rede geral de distribuição mostra um comportamento mais equilibrado, como visto na Barra 692 no mesmo terceiro dia de funcionamento. Assim destaca-se a importância de se estudar maneiras de se detectar os distúrbios de QEE, em específico o desequilíbrio de tensão.

#### IV. CONCLUSÃO

O uso de microrredes de energia elétrica para atendimento de áreas remotas e reforço no sistema de distribuição, potencializado pelo incentivo ao uso da geração distribuída e controles inteligentes de geração e carga, requer estudos adicionais para que a energia disponibilizada tenha níveis de qualidades aceitáveis tais como aquelas exigidas nos sistemas interligados. Um problema típico das microrredes, no que se refere à QEE, é o desequilíbrio nas tensões, que precisa ser detectado para as necessárias correções. Este trabalho utiliza o programa de simulação OpenDSS para calcular as tensões nas barras de uma microrrede cujo desequilíbrio é avaliado a partir de uma rede neural artificial *perceptron* resolvida no simulador Matlab®. A metodologia foi avaliada utilizando a rede teste IEEE 13 barras e mostrou-se eficiente em detectar o desequilíbrio de fase das tensões com rapidez. Porém, observou-se algumas detecções falsas, pois o percentual de acertos foi torno de 98%, o que representa uma ótima qualidade de detecção. O estudo mostra-se muito importante para que se possa, a partir das detecções de desequilíbrios, encontrar opções para correções desse distúrbio de QEE. A metodologia será testada posteriormente em outras redes e ampliada para detecção de outros distúrbios de QEE em microrredes.

#### REFERENCIAS

- [1] J. J. Burke, D. C. Griffith, D. J. Ward, "Power quality – two different perspective" IEEE Transactions On Power Delivery, p.1501-15133, jul. 1990.
- [2] E. Dyalnas, N. D. Hatzargyriou, "Impact of Microgrids on Service Quality", Power Engineering Society General Meeting, [s.l.], jun. 2007. IEEE. <http://dx.doi.org/10.1109/pes.2007.385972>.
- [3] M. Hojeo, I. Yuta, T. Funabashi, Y. Ueda, "A Method of Three-Phase Balancing in Microgrid by Photovoltaic Generation Systems", 13th International Power Electronics and Motion Control Conference (EPE-PEMC 2008), p. 2487-2491, Poznan, Poland, 1-3 Sept. 2008.
- [4] G. J. P. Vieira "Desequilíbrios de tensão em micro-redes durante o funcionamento em modo isolado", Dissertação de mestrado, Faculdade de Engenharia da Universidade do Porto, Cidade do Porto, jun 2012.
- [5] T. A. P. Beneteli, "Método para limitação de índices de desequilíbrio de máquinas elétricas trifásicas em sistemas de distribuição", Dissertação de mestrado, Universidade Federal de Juiz de Fora, Juiz de Fora, 2015.
- [6] A. Von Joanne, B. B. Banerjee, "Voltage unbalance: Power quality issues, related standards and mitigation techniques" Electric Power Research Institute, Palo Alto, CA, EPRI Final rep. maio 2000.
- [7] R. C. Dugan, T. E. Mcdermott, "An open source platform for collaborating on smart grid research", IEEE. Power and Energy Society General Meeting, p. 1-7, 2011 IEEE. [S.l.], 2011.
- [8] J. Sexauer, "OpenDSS primer, programa revision: 7.6", EPRI – Electric Power Research Institute, set. 2012.
- [9] S. Haykin, "Neural Networks and Learning Machine". 3. ed. Ontario, Canada: Pearson Prentice Hall, 2009.
- [10] B. Krose, P. D. Smagt, "An Introduction to Neural Networks". 8. ed. Amsterdam: The University of Amsterdam, 1996.
- [11] I. N. da Silva, D. H. Spatti, R. A. Andrade, "Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: fundamentos teóricos e aspectos práticos." 2. ed. São Paulo: Artliber, 2016.
- [12] D. E. Rumelhart et al. "Learning Internal Representations by Error Propagation." In: Parallel Distributed Processing. Cambridge: M.A. M.I.T Press, 1987. Cap. 8. p. 318-362.
- [13] W. H. Kersting, "Radial distribution test feeders." IEEE Transactions On Power Systems, [S.l.], v. 6, n. 3, p. 975-985, 1991. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/59.119237>.
- [14] Y. LeCun, "Generalization and network design strategies." Technical Report CRG-TR-89-4., Toronto, Canada, p. 9. 1989.
- [15] P. Radatz et. al. OpenDSSPVSystem and InvControl Element Models. [S.l.]: Epri - Electric Power Research Institute, 2020.