

## Metodologia de Treinamento de Redes Neurais Artificiais para Detecção de Ilhamento de Geradores Distribuídos Fotovoltaicos

Luiza Buscariolli, Ricardo Caneloi dos Santos,  
Ahda P. Grilo Pavani

Universidade Federal do ABC - UFABC, Santo André, SP 09210-580  
(e-mail: luiza.buscariolli@ufabc.edu.br, ricardo.santos@ufabc.edu.br, ahda.pavani@ufabc.edu.br).

---

**Abstract:** The anti-islanding protection of distributed generators is typically performed by conventional protection schemes that monitor the magnitude and frequency of voltage signals. However, one of the main issues to setting these protection schemes is to identify and differentiate the magnitude and frequency variations of an islanding event from other disturbances that may occur along the system, such as voltage sag or swell. By using an Artificial Neural Network (ANN) based algorithm, it is possible to recognize existent patterns on the distributed generator voltage waveform, which makes possible to obtain an accurate response about islanding events. However, the ANN training process involves important issues such as the definition of the ANN architecture, the data window length, the sampling rate, and the selection of a representative training set for the analyzed power grid. In this context, this paper discusses the fundamental aspects for training an ANN used for islanding detection of photovoltaic distributed generators.

**Resumo:** A proteção anti-ilhamento de geradores distribuídos é tipicamente realizada por esquemas de proteção convencionais que monitoram a magnitude e a frequência dos sinais de tensão. Uma das principais questões para definir esses esquemas de proteção é identificar e diferenciar as variações de magnitude e frequência de um evento de ilhamento de outros distúrbios que podem ocorrer no sistema, como aumento e diminuição de tensão. Utilizando um algoritmo baseado em Rede Neural Artificial (RNA), é possível reconhecer padrões existentes na forma de onda de tensão analisada, obtendo uma resposta precisa sobre eventos de ilhamento. No entanto, o processo de treinamento da RNA envolve questões importantes como definição da arquitetura da RNA, tamanho da janela de dados, taxa de amostragem e seleção de um conjunto de treinamento representativo do sistema analisado. Nesse contexto, este artigo discute os aspectos fundamentais para o treinamento de uma RNA utilizada para detecção de ilhamento de geradores distribuídos fotovoltaicos.

**Keywords:** Distributed Generation; Islanding Detection; Artificial Neural Networks.

**Palavras-chaves:** Geração Distribuída, Detecção de Ilhamento, Redes Neurais Artificiais.

---

### 1. INTRODUÇÃO

Com o objetivo de reduzir a dependência da produção de energia elétrica a partir de combustíveis fósseis, as tecnologias de energia renovável estão se tornando cada vez mais importantes nos sistemas de fornecimento de energia. Os geradores distribuídos (GDs) que operam a partir de fontes renováveis melhoram a segurança energética, reduzem o impacto das flutuações dos preços da eletricidade, reduzem o congestionamento nas linhas de transmissão e proporcionam estabilidade à rede elétrica local (Banshal 2017, Obara e Morel 2017).

O aumento de pequenos GDs operando em paralelo com a rede principal oferece vantagens distintas como maior eficiência energética, menor impacto ambiental e maior confiabilidade. Por outro lado, também altera a dinâmica dos sistemas elétricos de potência, trazendo desafios aos sistemas, por exemplo, o aumento da complexidade da operação da rede

devido ao fluxo bidirecional de potência, o aumento do nível de tensão no barramento onde o GD está conectado e mudanças no o nível de curto-circuito do sistema, afetando diretamente a coordenação dos elementos de proteção (Vargas et al. 2018, Ponnam et al. 2018). A operação da geração distribuída deve garantir que, ao se conectar à rede, os parâmetros de qualidade de energia, como distorções harmônicas, desequilíbrio de tensão, flutuação de tensão e variações de tensão de curta duração, não tenham seus valores de referência violados (ANEEL, 2017).

Avanços nos sistemas de conversão de energia e a crescente preocupação com o meio ambiente levaram a uma maior penetração de geradores fotovoltaicos (FV) nas redes de distribuição. Os sistemas fotovoltaicos são um dos recursos mais utilizados na geração distribuída, pois a fonte solar é abundante e não poluente (Do et al 2016). No Brasil, os GDs FV correspondem a 90,4% do total de energia produzida pela geração distribuída em 2020, produzindo 4764 GWh (EPE, 2021).

Os geradores fotovoltaicos são compostos por módulos solares e inversor. Os módulos solares são fabricados com material semicondutor e, por meio do efeito fotovoltaico, transformam a energia presente nos raios solares em energia, gerada em corrente contínua. O inversor é responsável por converter a corrente contínua gerada pelos painéis em corrente alternada, para que o gerador fotovoltaico possa operar em paralelo com a rede (Rathore et al. 2021).

O ilhamento não intencional ocorre quando uma parte da rede, contendo cargas e GD, permanece energizada, porém isolada eletricamente da rede de distribuição, representando um dos problemas mais graves na geração distribuída, pois a concessionária não tem controle sobre tensão e frequência de a área ilhada (Gupta et al. 2021). Segundo Wang et al. (2015) e Kolli et al. (2020), as principais implicações do ilhamento não intencional são:

- equipes de manutenção estão em risco devido a áreas que permanecem energizadas sem o conhecimento da concessionária;
- a qualidade da energia no trecho ilhado está fora do controle da concessionária, embora ainda esteja sob sua responsabilidade;
- danos ao equipamento, tanto do lado do consumidor quanto da concessionária;
- a coordenação do sistema de proteção da rede ilhada pode não funcionar satisfatoriamente devido às mudanças no nível de curto-circuito do sistema;
- o sistema ilhado pode ter um aterramento inadequado devido à perda de conexão com a concessionária;
- sérios danos ao GD e às cargas em caso de restauração não sincronizada da energia da concessionária.

A detecção de ilhamento não intencional é uma função de proteção obrigatória para todo GD conectado à rede elétrica. As proteções anti-ilhamento devem garantir a desconexão física entre a concessionária e a porção ilhada. Segundo a norma internacional IEEE STD 1547, que é a referência mais utilizada, o tempo de desconexão para eventos de ilhamento, é de no máximo dois segundos, variando conforme o desvio de tensão e/ou frequência (ANEEL 2017, Llonch-Masachs et al. 2019).

Existe grande número de métodos de detecção de ilhamento propostos nos últimos anos. Geralmente são classificados como métodos remotos ou locais. Os métodos remotos são baseados na comunicação entre os GDs e a rede principal, monitorando os disjuntores em tempo real. Técnicas locais são amplamente utilizadas para detectar eventos de ilhamento com base na medição dos parâmetros do sistema como tensão, frequência, corrente e distorção harmônica no ponto de conexão comum (PCC): onde GD, carga e a rede se conectam. As técnicas locais podem ser divididas em técnicas passivas, ativas e híbridas (Khamis et al. 2013).

Os esquemas de detecção de ilhamento remoto são baseados em princípios de comunicação entre DGs e concessionárias. Todos os parâmetros são verificados em tempo real e estes esquemas independem da carga do sistema e das características do inversor. Essas técnicas têm melhor confiabilidade do que as técnicas locais. No entanto, os equipamentos utilizados geralmente são caros e podem exigir a instalação de circuitos adicionais, inviabilizando seu uso, principalmente quando há poucos GDs (Li et al. 2014).

Técnicas locais ativas injetam sinais no PCC e medem a resposta do sistema a tais distúrbios. O principal problema neste caso é a diminuição da qualidade de energia e estabilidade do sistema. Essas técnicas podem não atuar quando há outras técnicas operando em paralelo, bem como quando mais de um GD é considerado (Abo-Khalil et al. 2013).

Raza et al. (2015) definem técnicas locais passivas, também chamadas de técnicas convencionais, como aquelas que utilizam a medição local (como magnitude e frequência dos sinais de tensão) para detectar condições de ilhamento. O GD será desconectado quando os valores medidos excederem os valores limite. Todo inversor operando em paralelo com a rede principal deve ter proteção contra sobre/subtensão e proteção contra sobre/subfrequência. O principal problema ocorre quando a potência absorvida pela carga coincide quase perfeitamente com a potência gerada pelo GD, implicando em um pequeno desbalanço de potência. Quando isso acontece, a magnitude e a frequência da tensão na saída do inversor podem não variar significativamente, e as proteções citadas acima podem não conseguir detectar o evento de ilhamento. Outra situação possível é o falso trip, que ocorre quando o GD é desconectado para eventos diferentes de ilhamento.

Para superar as limitações dos métodos convencionais, métodos inteligentes têm sido utilizados nos últimos anos. Esses novos métodos são mais confiáveis e eficientes, detectando um evento de ilhamento mesmo quando há um pequeno desbalanço de potência.

As Redes Neurais Artificiais (RNAs) podem ser aplicadas para problemas de reconhecimento e classificação de padrões. Dada a sua capacidade de generalização, as RNAs são capazes de obter grande precisão mesmo quando apresentadas a dados nunca antes vistos (Bishop 1995).

Alguns autores utilizam classificadores inteligentes (como RNAs) combinados com algoritmos de processamento de sinal, como Menezes et al. (2019) e Guan e Liao (2019). O algoritmo proposto neste trabalho difere de outros trabalhos, utilizando um classificador inteligente que se baseia exclusivamente no padrão de forma de onda do sinal de tensão medido no PCC para a detecção de ilhamento.

A Seção 2 apresenta o modelo elétrico utilizado para o processo de treinamento da RNA. O algoritmo proposto para detecção de ilhamento é descrito na Seção 3. A Seção 4 apresenta os resultados, considerando a seleção da melhor RNA. A seção 5 traz as conclusões do presente trabalho.

## 2. MODELAGEM DO SISTEMA TESTE

Como forma de estudar a detecção de ilhamento de geradores fotovoltaicos, o cenário analisado foi delimitado nas instalações da Universidade Federal do ABC (UFABC) em Santo André. O sistema elétrico adotado é apresentado na Fig. 1. Os transformadores destacados mostram os circuitos que operam em 380 V. Os demais ramos funcionam em 220 V. Todas as medidas elétricas foram feitas no PCC, destacado em laranja. Os dados dos geradores fotovoltaicos são apresentados na Tabela 1.

**Tabela 1. Dados técnicos da modelagem elétrica**

Característica	(1)	(2)	(3)	(4)
No. de módulos	180	140	120	200
Potência CC (kWp)	64,8	50,5	43,2	72,0
Inversor (kW)	55	55	33	55

O sistema foi modelado computacionalmente usando MATLAB e Power System Blockset (PSB) do Simulink. Para investigar o fenômeno de ilhamento, a microrrede é desconectada repentinamente da rede principal em 0,2 s pela abertura do disjuntor (CB) e o tempo total de simulação foi 0,44 s.

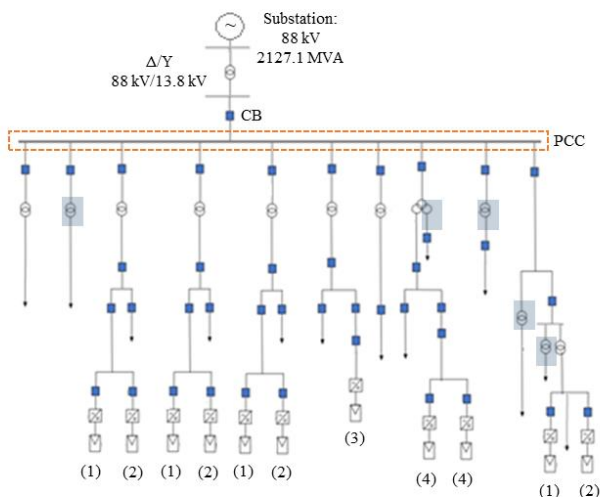


Fig. 1 Diagrama das instalações da UFABC.

As treze cargas consideradas foram modeladas como impedância constante, sendo o pior caso para detecção de ilhamento, pois a potência varia em função do quadrado da variação da tensão. Essas características são conservadoras e, portanto, as mais críticas do ponto de vista da proteção. Assim, um bom desempenho do algoritmo nessas condições garante melhor desempenho para todos os outros cenários possíveis (Merlin et al. 2013).

## 3. ALGORITMO PROPOSTO PARA DETECÇÃO DE ILHAMENTO

Neste trabalho, são utilizadas RNAs do tipo Multilayer Perceptron (MLP), pois sua principal habilidade é resolver

problemas complexos e não linearmente separáveis. Este tipo de RNA é o mais indicado para aplicações em sistemas de potência, pois algumas de suas principais características são: o processo de treinamento é possível por meio de dados experimentais ou de modelos, grande capacidade de identificar padrões e aproximar funções, capacidade de lidar com grande número de dados, robustez e tolerância a falhas (Merlin et al. 2013).

Durante a etapa de desenvolvimento do algoritmo, para fins de avaliação de desempenho, o sinal de tensão da fase A (medido no PCC) foi amostrado utilizando duas taxas de amostragem: dezesseis e trinta e duas amostras por ciclo de 60 Hz. Quanto maior a taxa de amostragem, maior o número de cálculos realizados, exigindo maior processamento computacional. Vale ressaltar que durante a etapa de aquisição de dados, o sinal de tensão foi normalizado, variando no intervalo [-1, 1].

A Fig. 2. mostra como funciona o algoritmo proposto. Cada janela de dados corresponde a um vetor de entrada da RNA, cujo tamanho é função da taxa de amostragem utilizada. Os vetores são apresentados sequencialmente à RNA, produzindo uma resposta de saída. No caso de condição de ilhamento, a saída da RNA é "1", caso contrário, "0".

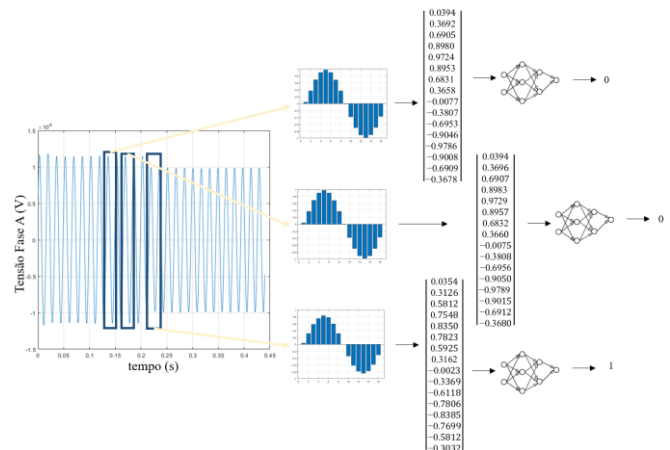


Fig. 2 Exemplo de um vetor originado de um evento de ilhamento com dezesseis amostras por ciclo.

É importante notar que em uma condição de ilhamento, a magnitude da tensão diminui se a carga for maior que a geração FV, como visto na Fig. 3 (a). Por outro lado, a magnitude da tensão aumenta se a carga for menor que a geração FV, como mostra a Fig. 3 (b). No entanto, pode haver uma condição em que a magnitude da tensão pode não variar significativamente, sob baixo desbalanço de potência, ou seja, quando a potência absorvida pela carga está próxima da potência gerada no GD fotovoltaico.

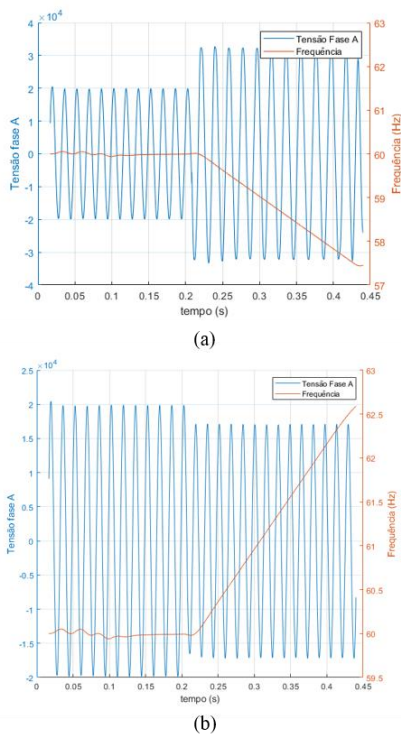


Fig. 3 Comportamento de tensão e frequência em função do desbalanço de carga para um evento de ilhamento.

### 3.1 Conjunto de Treinamento

O processo de treinamento de uma RNA consiste em encontrar os valores de peso ( $w$ ) e bias ( $b$ ), que são modificados iterativamente para tornar a RNA capaz de realizar uma tarefa de interesse.

Neste trabalho, o processo de treinamento foi desenvolvido no MATLAB utilizando o método de treinamento supervisionado, que acontece conforme visto na Fig. 4. A RNA recebeu um conjunto de treinamento que representa o cenário analisado. Este conjunto contém os vetores de entrada e suas saídas desejadas. Ao final do processo de treinamento, a diferença entre a saída estimada da RNA e a saída desejada deve ser menor que um erro aceitável.

O erro quadrático médio (EQM) é calculado a partir do quadrado da diferença entre a saída calculada pela RNA e a saída desejada. Um critério para parar o processo de treinamento é quando o EQM observado atinge um determinado valor mínimo. Outro critério de parada usa o número de vezes que o processo de treinamento é executado (epoch).

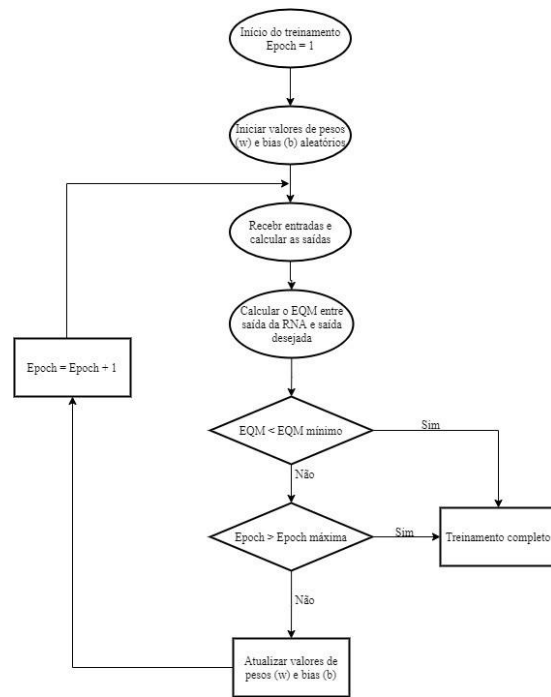


Fig. 4 Diagrama com o algoritmo de treinamento supervisionado de uma RNA.

A definição dos parâmetros das RNAs (pesos, bias e funções de ativação) e sua arquitetura (número de neurônios por camada e número de camadas) dependem da aplicação e do nível de precisão desejado. Assim, durante o processo de treinamento, muitos testes foram realizados considerando diferentes topologias de RNAs. Além disso, foram avaliadas alterações considerando diferentes taxa de amostragem, possibilitando analisar a melhor configuração de RNA para um nível de precisão desejado.

Para o processo de treinamento da RNA, foram considerados 1248 cenários, com diferentes combinações de carga. Esses cenários foram simulados considerando quatro eventos possíveis: ilhamento, aumento de tensão, afundamento de tensão e distorção harmônica.

As janelas de dados pré-evento foram consideradas para condições de não ilhamento, juntamente dos casos de aumento de tensão, queda de tensão e distorção harmônica. Foram consideradas janelas pós-evento para a condição de ilhamento, caracterizada pela abertura do disjuntor no PCC.

Para cada simulação, vinte e quatro ciclos do sinal de tensão foram obtidos do modelo: onze ciclos caracterizando a operação antes de um evento e treze ciclos caracterizando a operação após um evento. Esses vetores (pré e pós evento) foram usados para formar os conjuntos de treinamento da RNA. A Tabela 2 mostra o número de vetores no conjunto de treinamento.

**Tabela 2. Quantidade de vetores no conjunto de treinamento**

Total	Ilhamento	% Ilhamento
30376	4480	14,75%

Para todas as RNAs testadas a camada de saída foi sempre implementada com uma função de ativação linear, enquanto que para as camadas ocultas, foram avaliadas as funções logística (sigmoide) e tangente hiperbólica.

### 3.2 Conjunto de Teste

A acurácia das RNAs treinadas foi verificada medindo seu desempenho em relação a um segundo conjunto de dados independente (conjunto de teste). Para tanto, foram gerados outros nove cenários, com diferentes configurações de carga. É importante notar que as janelas de dados (vetores de entrada) desses nove cenários não foram utilizadas durante o processo de treinamento, sendo totalmente novas para as RNAs. A Tabela 3 mostra o número de casos utilizados para testar as RNAs.

**Tabela 3. Quantidade de vetores no conjunto de testes**

Total	Ilhamento	% Ilhamento
8864	2585	29,16%

Para escolher a melhor RNA, foram calculadas métricas de avaliação do modelo. Essas métricas levam em consideração a classificação feita pela RNA e a resposta alvo (target). Os resultados são apresentados em uma matriz de confusão, mostrada na Fig. 5. O eixo vertical mostra a classe prevista pela RNA e o eixo horizontal mostra a classe esperada.

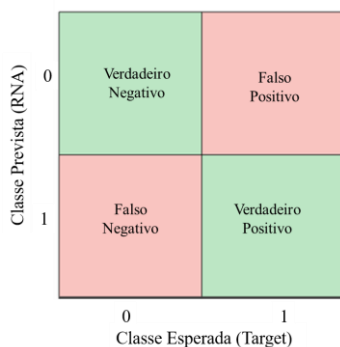


Fig. 5 Matriz de Confusão

Um caso negativo verdadeiro mostra os casos não insulares que foram classificados como não insulares; casos falso-positivos mostram casos de ilhamento que foram classificados como operação normal; casos falsos negativos mostram casos operacionais normais classificados como ilhamento e casos verdadeiros positivos mostram casos ilhados classificados corretamente.

A partir desses casos, foram calculados precisão e recall. A métrica F0.5 também foi calculado, pois penaliza os casos falsos positivos.

Precisão é a proporção de previsões positivas corretas dividida pelo número total de previsões positivas. Ela mede a probabilidade de detecção correta de valores positivos. Para calcular a precisão, deve-se usar (1) (Goutte e Gaussier, 2005).

$$Precisão = \frac{Verdadeiro\ Positivo}{Verdadeiro\ Positivo + Falso\ Positivo} \quad (1)$$

Recall é uma medida de quão bem o modelo está prevendo o caso positivo e é calculado segundo (2) (Goutte e Gaussier, 2005).

$$Recall = \frac{Verdadeiro\ Positivo}{Verdadeiro\ Positivo + Falso\ Negativo} \quad (2)$$

A métrica F0.5 é a média harmônica ponderada de precisão e recall e dá mais peso à precisão. Portanto, considera os casos em que os falsos positivos têm um impacto maior do que os falsos negativos, como visto em (3) (Goutte e Gaussier, 2005).

$$F0.5 = (1 + 0.5)^2 \times \frac{Precisão \times Recall}{(0.5^2 \times Precisão) + Recall} \quad (3)$$

Para avaliação das RNAs foram considerados “precisão” e “F0.5”, que são as métricas que levam em consideração os casos falsos positivos, que são os casos em que o ilhamento não foi corretamente identificado e, portanto, deve ser minimizado.

## 4. RESULTADOS

Para cada topologia considerada, foram treinadas quatro RNAs. Os resultados exibidos nesta seção mostram o melhor desempenho obtido. Nas Tabelas 4 a 6, a função de ativação logística é representada por “L” e a função tangente hiperbólica, como “TH”.

### 4.1 RNAs com uma camada oculta

A Tabela 4 apresenta os melhores resultados para RNAs de uma camada e vetor de entrada com 16 amostras.

**Tabela 4. Resultados para RNA com uma camada oculta e vetor de 16 amostras**

Amostras no vetor de entrada	16	16	16	16
Número de Neurônios	8	8	16	16
Função de Ativação	L	TH	L	TH
Precisão	100%	99,1%	99,6%	99,5%
F0.5	97,5%	98,6%	96,1%	96,3%

A Tabela 5 apresenta os melhores resultados para RNAs de uma camada e vetor de entrada com 32 amostras.

**Tabela 5. Resultados para RNA com uma camada oculta e vetor de 32 amostras**

Amostras no vetor de entrada	32	32	32	32
Número de Neurônios	16	16	32	32
Função de Ativação	L	TH	L	TH
Precisão	100%	99,2%	99,5%	100%
F0.5	97,5%	99,7%	87,9%	95,2%

Examinando os resultados, é possível notar que para RNA de uma camada não há diferença prática entre as funções de

ativação utilizadas. As RNAs cujo número de neurônios é metade da taxa de amostragem (tamanho do vetor de entrada) apresentam desempenho ligeiramente melhor, quando se consideram as duas métricas estudadas. Nota-se que os resultados com RNAs de uma camada já são satisfatórios.

#### 4.2 RNAs com duas camadas ocultas

Para fins de comparação, a Tabela 6 apresenta os resultados para RNAs com duas camadas ocultas, destacando que as duas camadas possuem a mesma função de ativação. Neste ponto, optou-se pela utilização da mesma topologia, variando-se o tamanho do vetor de entrada.

**Tabela 6. Resultados para RNA com duas camadas ocultas**

Amostras no vetor de entrada	16	16	32	32
Número de Neurônios	16-8	16-8	16-8	16-8
Função de Ativação	L	TH	L	TH
Precisão	99,5%	99,5%	96,1%	92,3%
F0.5	99,2%	96,1%	99,2%	97,6%

Para as RNAs com duas camadas ocultas, percebe-se que o aumento no tamanho do vetor de entrada não trouxe melhoria para a topologia considerada, sendo que houve diminuição nas métricas estudadas. Quando se considera o vetor de entrada com 16 amostras, a função de ativação logística tem desempenho superior: por ter valor de F0.5 maior, há menos casos de ilhamento classificados erroneamente pela RNA.

Para ilustrar como o algoritmo funciona, as Figs. 6 a 9 mostram a resposta da RNA de duas camadas, com topologia 16-8 e função de ativação logística, para os diferentes eventos considerados: ilhamento, aumento de tensão, diminuição de tensão e presença de harmônicos. A resposta da RNA é vista em laranja enquanto que a tensão normalizada está em azul. A linha vertical mostra o início de um evento.

É possível observar que a detecção do ilhamento foi realizada com precisão, enquanto para os demais eventos, que não representam situações de ilhamento, a saída da RNA permaneceu desabilitada “0”.

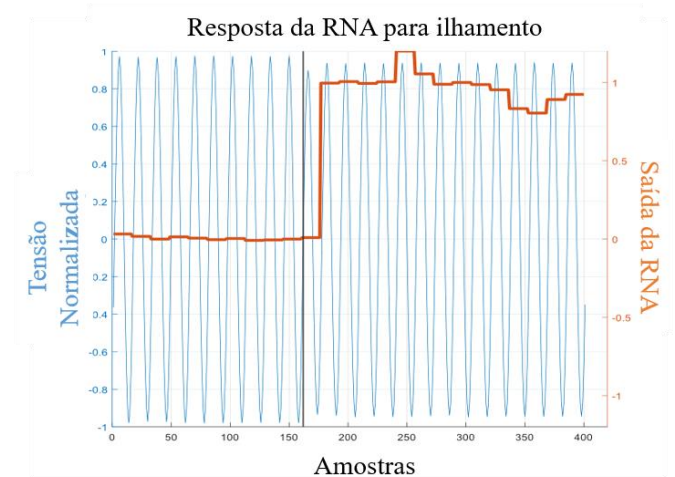


Fig. 6 Resposta da RNA para ilhamento.

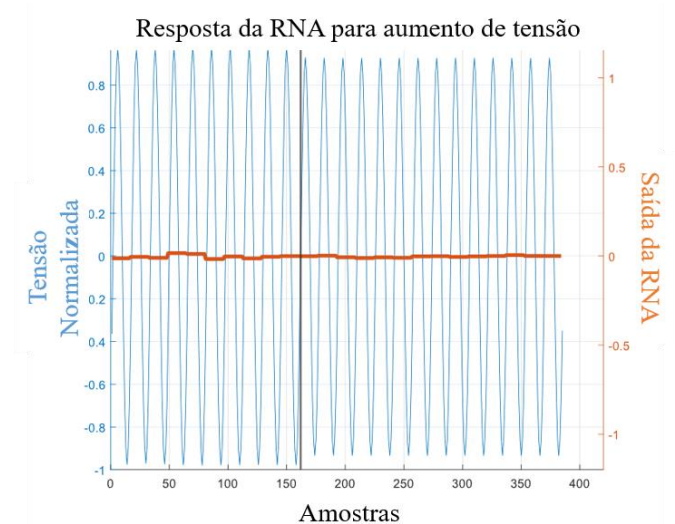


Fig. 7 Resposta da RNA para aumento de tensão.




Fig. 8 Resposta da RNA para diminuição de tensão.

## REFERÊNCIAS

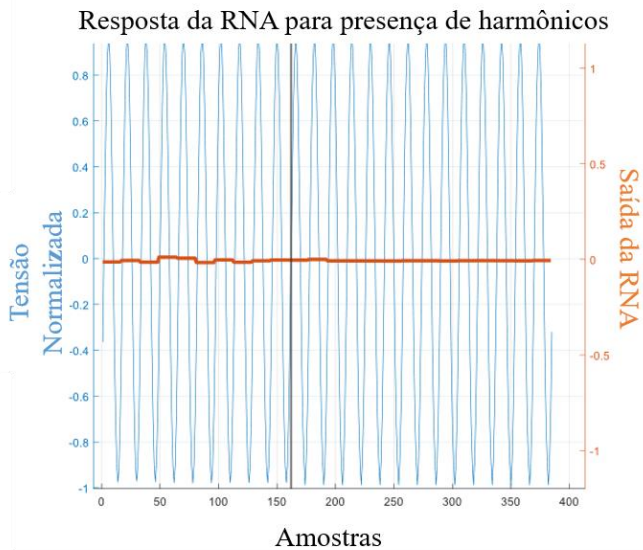


Fig. 9 Resposta da RNA para presença de harmônicos.

## 5. CONCLUSÕES

Neste trabalho, foi discutida a aplicação de RNAs para detecção de ilhamento. A vantagem deste método é utilizar exclusivamente amostras do sinal de tensão no ponto de conexão comum, sem nenhum processamento adicional, tornando-o mais rápido e eficiente. Além disso, este algoritmo pode ser implementado em um dispositivo eletrônico inteligente, já disponível para fins de proteção.

Para avaliar o desempenho do algoritmo proposto, uma rede elétrica real foi modelada. Para a construção do conjunto de treinamento, foram considerados quatro eventos elétricos e diferentes configurações de carga. É importante ressaltar que ao empregar RNAs, o conjunto de treinamento deve ser bem construído, representando com precisão os limites do cenário analisado. Desta forma, a RNA pode aprender a classificar todos os eventos possíveis.

Para comparar o desempenho das RNAs desenvolvidas, as métricas de avaliação do modelo foram calculadas na Seção 4, onde as RNAs foram testadas. Para o cenário analisado, a adição de camadas não aumentou a precisão das RNAs nem a mudança nas funções de ativação.

Como forma de demonstrar a robustez do método proposto, foi demonstrado que a RNA pode detectar a condição de ilhamento, distinguindo-a de outras condições. Ressalta-se que foi uma forma de investigar melhor as relações entre a topologia da RNA e a acurácia. O próximo passo é gerar novo conjunto de testes, com desbalanços de potência cada vez menores, representando situações onde a detecção de ilhamento é mais crítica.

## AGRADECIMENTOS

Os autores gostariam de agradecer à Enel Distribuidora SP pelo financiamento do projeto de pesquisa.

- Abo-Khalil, A. G.; Al-Qawasmi, A.; Aly, O. A. M (2013). A novel islanding detection method for three-phase photovoltaic generation systems. In *2013 IEEE Jordan Conference on Applied Electrical Engineering and Computing Technologies (AEECT)*, pp. 1–5. IEEE, Jordan.
- Balanco Energético Nacional (BEN) 2021: Ano base 2020, 2021. Disponível em: <https://ben.epe.gov.br>, acesso em 18/06/2020.
- Banshal, R (2017). *Handbook of Distributed Generation*. Springer, Pretoria.
- Bishop, C. M. (1995). *Neural Networks for pattern recognition*. Oxford University Press, Oxford.
- Do, H. T., Zhang, X., Nguyen, N. V., Li, S. S., Chu, T. T (2016). Passive-Islanding Detection Method Using the Wavelet Packet Transform in Grid-Connected Photovoltaic Systems. In *IEEE Transactions on Power Electronics*, vol. 31, no. 10, pp. 6955–6967.
- Goutte C., Gaussier E. (2005). *A Probabilistic Interpretation of Precision, Recall and F-Score, with Implication for Evaluation*. In Losada D.E., Fernández-Luna J.M. (eds) *Advances in Information Retrieval*. ECIR, Berlin.
- Guan, Z., Liao, Y. (2019). A New Islanding Detection Method Based on Wavelet-transform and ANN for Micro-grid Including Inverter Assisted Distributed Generator. *International Journal of Emerging Electric Power Systems*, 20(5), 1–10.
- Gupta, N., Dogra, R., Garg, R., Kumar, P. (2021). Review of islanding detection schemes for utility interactive solar photovoltaic systems. In *International Journal of Green Energy*.
- Khamis, A., Shareef, H., Bizkevelci, E., Khatib, T. (2013). A review of islanding detection techniques for renewable distributed generation systems. *Renewable and Sustainable Energy Reviews* 28 (1) 483–493.
- Kolli, A. T., Ghaffarzadeh, N. (2020). A novel phaselet-based approach for islanding detection in inverter-based distributed generation systems, In: *Electric Power Systems Research*, vol. 182, pp. 1–9.
- Li, C., Cao, C., Cao, Y., Kuang, Y., Zeng, L., Fang, B.: A review of islanding detection methods for microgrid. *Renewable and Sustainable Energy Reviews* 35(1), 211–220 (2014).
- Llonch-Masachs, M., Heredero-Peris, D., Chillón-Antón, C., Montesinos-Miracle, D., Villafafila-Robles, R. (2019). Impedance measurement and detection frequency bandwidth, a valid island detection proposal for voltage-controlled inverters. *Applied Sciences* 9(6), 1146–1168.
- Menezes, T. S., Coury D. V., Fernandes, R. A. S. (2019). Islanding Detection Based on Artificial Neural Network and S-transform for Distributed Generators. In: *2019 IEEE Milan PowerTech*, pp. 1–6, IEEE, Milan.
- Merlin, V. L., Santos, R. C., Pavani, A. P. G., Coury, D. V., Oleskovicz, M., Vieira, J. C. M. (2013). A methodology for training artificial neural networks for islanding detection of distributed generators. In: *2013 IEEE PES Conference on Innovative Smart Grid Technologies (ISGT Latin America)*, pp. 1–6, IEEE Sao Paulo.

- Obara, S., Morel, J. (2017). *Clean Energy Microgrids*. The Institution of Engineering & Technology, London.
- Ponnam, Y., Kumar, P. S., Kiran, M. S. (2018). Islanded and grid interconnected operation modes of PV system. In *Indian Journal of Scientific Research* 17(2), 174–184.
- Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST: Módulo 3 – Acesso ao Sistema de Distribuição (revisão 7). Disponível em: <https://www.aneel.gov.br/modulo-3>. Último acesso em 04/01/2021.
- Rathore N., Panwar, N. L., Yettou, F., Gama, A. (2021). A comprehensive review of different types of solar photovoltaic cells and their applications. In: *International Journal of Ambient Energy*, 42 (10), 1200–1217.
- Raza, S., Mokhlis, H., Arof, H., Laghari, J.A., Wang, L. (2015). Application of signal processing techniques for islanding detection of distributed generation in distribution network: A review. *Energy Conversion and Management* 96(1) 613–624.
- Vargas, M. C., Mendes, M. A., Batista, O. E., Simonetti, D. S. L. (2018). A review on the protection elements required for distributed generation in Brazil. In *Simpósio Brasileiro de Sistemas Elétricos 2018*, pp. 1–6. IEEE, Niteroi.
- Wang, M.H., Huang, M.-L. and Liou, K.-J. (2015). Islanding detection method for grid connected photovoltaic systems. *IET Renewable Power Generation* 9(6), 700–709.