DETECÇÃO DE ILHAMENTO DE GERADORES DISTRIBUÍDOS UTILIZANDO TÉCNICAS DE APRENDIZAGEM DE MÁQUINA

THIAGO S. MENEZES*, WILHIAM C. DE CARVALHO*, DENIS V. COURY*

* Departamento de Engenharia Elétrica e de Computação Escola de Engenharia de São Carlos (EESC), Universidade de São Paulo (USP) São Carlos, SP, Brasil

Emails: thiagosm@usp.br, wcarvalho@usp.br, coury@sc.usp.br

Abstract— Recently with the increase of distributed generators (DGs), the power flow in the distribuition system has gone from radial to bidirectional. While this may bring benefits, there is a problem that has become more evident: the islanding. Currently there are consolidated techniques for islanding detection, with passive techniques being the most used one due to the low cost and ease of implementation. However, since these techniques are dependent on the active and reactive power unbalance during the islanding to operate correctly, they have large non-detection zones for the cases in which the unbalance is small. In order to fulfill this need, intelligent passive techniques have been studied. In this study, a machine learning based detection technique was modeled to mitigate the non-detection zones' problem. Initially, the analysis of the voltage frequency spectrum in the point of common coupling (PCC) is performed using the S-Transform to differentiate the islanding from other events. To classify the data, two classifiers were tested. The first one based on Fuzzy Logic and the second on artificial neural networks (ANN). The proposed protections presented higher accuracy than the conventional protection, where the ANN presented the most prominent performance.

Keywords— Artificial Neural Networks, Distributed Generators, Fuzzy Logic, Islanding Detection, Machine Learning and S-Transform.

Resumo— Nos últimos anos, com o aumento de Geradores Ditribuídos (GDs), o fluxo de potência em sistemas de distribuição passou de radial para bidirecional. Embora isso possa trazer melhorias, há um problema que se tornou mais evidente: o ilhamento. Atualmente existem técnicas consolidadas para a detecção do ilhamento, sendo as técnicas passivas as mais utilizadas devido ao baixo custo e facilidade na implementação. Porém, como essas técnicas são dependentes do desbalanço de potência ativa e reativa durante o ilhamento para atuarem corretamente, elas apresentam grandes zonas de não detecção caso esse desbalanço seja pequeno. Para suprir tal necessidade, técnicas passivas inteligentes vêm sendo estudadas. Neste trabalho foi modelada uma proteção anti-ilhamento com o uso de aprendizagem de máquina para mitigar o problema das zonas de não detecção. Inicialmente, é utilizada a análise do espectro de frequências da tensão no Ponto de Acoplamento Comum (PAC) com o uso da Transformada de Stockwell (TS) para diferenciar o ilhamento de outros fenômenos. Para a classificação dos dados, são testados dois classificadores. O primeiro baseado em lógica fuzzy e um segundo em Redes Neurais Artificiais (RNAs). As proteções propostas apresentaram taxas de acerto superiores à proteção convencional, onde a RNA destacou-se com o melhor desempenho.

Palavras-chave Aprendizagem de Máquina, Detecção de Ilhamento, Geradores Distribuídos, Transformada S, Lógica Fuzzy e Redes Neurais Artificiais.

1 Introdução

Recentemente, a geração distribuída vem crescendo substancialmente no Brasil (ANEEL, 2018). O aumento no número de unidades geradoras de pequeno e médio porte conectadas aos Sistemas de Distribuição (SDs) pode reduzir as perdas elétricas e melhorar o perfil de tensão. Entretanto, a geração distribuída pode trazer algumas desvantagens, como a elevação de tensão na condição de carga leve e problemas de proteção devido a bidirecionalidade no fluxo de potência. Outro problema relacionado a geração distribuída é o ilhamento, que é uma situação em que uma porção do SD se encontra eletricamente isolada do restante do Sistema Elétrico de Potência (SEP), porém essa porção ainda permanece energizada por um Gerador Distribuído (GD) (Mahat et al., 2008). O ilhamento pode ocorrer devido a atuação da proteção em uma condição de falta ou mesmo devido a uma manobra para manutenção de algum equipamento pela distribuidora.

O ilhamento pode ser classificado em dois tipos: intencional e não intencional. No primeiro caso, o GD permanece alimentando o sistema ilhado intencionalmente, assegurando que este continuará energizado. Por outro lado, no ilhamento não intencional, após a detecção da ocorrência do ilhamento, o GD é removido para evitar possíveis problemas, tais como risco à equipe de manutenção da distribuidora, aterramento inadequado, perda da coordenação da proteção de sobrecorrente e religamento fora de sincronismo (Walling and Miller, 2002).

Para a detecção do ilhamento, convencionalmente são utilizados métodos remotos ou locais baseados em técnicas ativas e passivas. Segundo Mahat et al. (2008), os métodos remotos apresentam uma confiabilidade elevada, porém, por necessitarem de comunicação entre os GDs e a distribuidora, tais métodos acabam em desuso pelo seu elevado custo. Além disso, em caso de falha na comunicação, o gerador necessita de uma proteção local para permanecer protegido. Os métodos locais que utilizam técnicas ativas baseiam-se na inserção de um distúrbio e sua análise para verificar possíveis alterações no sistema elétrico. Entretanto, a inserção de oscilações e distúrbios no sistema podem gerar problemas de qualidade da energia. Por outro lado, os baseados em técnicas passivas são os mais utilizados por serem os mais viáveis economicamente. Eles se baseiam na leitura de sinais do sistema, como tensão e frequência, para tomar a decisão. Entretanto, caso durante o ilhamento essas grandezas não sofram alterações significativas, como no caso em que a potência consumida pelas cargas é semelhante a gerada pelo GD, o ilhamento pode não ser identificado.

Para garantir a detecção do ilhamento mesmo nessas situações, o uso de técnicas inteligentes vem sendo estudado. Lidula and Rajapakse (2009) propuseram a análise de sinais transitórios de alta frequência, amostrados com taxa de 20 kHz, para conseguir identificar o ilhamento utilizando Redes Neurais Artificiais (RNAs) e a Transformada Wavelet (TW). Fayyad and Osman (2010) realizaram um estudo semelhante para a detecção do ilhamento com o uso das mesmas ferramentas, porém com a taxa amostral de 10 kHz. Samantaray et al. (2010) propuseram o uso de lógica Fuzzy para detectar o ilhamento, sendo que os parâmetros de entrada, regras e funções de pertinência do sistema Fuzzy foram definidos com base em uma árvore de decisão. Ray et al. (2012) efetuaram um estudo comparativo entre a TW e a Transformada de Stockwell (TS) com o intuito de identificar qual delas apresenta o melhor desempenho na extração de características. Visando a detecção de ilhamento, Ray et al. (2012) verificaram que a TS apresentou uma melhor resposta em relação a TW. Mishra et al. (2016) utilizaram a TS do sinal de tensão de sequencia negativa para detecção de ilhamento em conjunto com a técnica de Máquina de Aprendizado Extremo (ou Extreme Learning Machine (ELM)).

Nesse contexto, são apresentadas neste trabalho duas técnicas de detecção de ilhamento voltada para geradores síncronos com o intuito de detectar o ilhamento no maior número de condições possíveis. O método baseia-se na extração de características e reconhecimento de padrões nos sinais de tensão amostrados no Ponto de Acoplamento Comum (PAC) do gerador síncrono. Para isso, o sinal de tensão é pré-processado com o uso da TS para a extração de características do espectro de frequência. O reconhecimento dos padrões presentes no sinal pré-processado, por sua vez, é realizado por técnicas de aprendizagem de máquina, em específico um classificador fuzzy e uma RNA.

Este trabalho está organizado de modo que a Seção 2 apresenta a metodologia proposta e a modelagem do sistema elétrico. Os resultados das simulações e as análises do desempenho das técnicas de aprendizagem de máquina são apresentados na Seção 3. Por fim, a Seção 4 apresenta as conclusões.

2 Modelagem e Metodologia da Detecção de Ilhamento Proposta

Para este estudo, as tensões foram amostradas no PAC a uma taxa de 64 amostras por ciclo, ou seja, a 3840 Hz. O método de detecção do ilhamento proposto é apresentado no diagrama da Figura 1.



Figura 1. Fluxograma da metodologia proposta.

Após a amostragem da tensão no PAC, é realizada a detecção de evento no sistema. Caso haja a ocorrência de algum evento, realiza-se a decomposição do espectro de frequência da tensão com o uso da TS. Os níveis de frequências do espectro são discretizados e utilizados como entradas para o classificador, que é responsável pela decisão de abertura do disjuntor de conexão do GD.

Cada uma das etapa da metodologia apresentadas na Figura 1 serão apresentadas de forma mais detalhada posteriormente.

2.1 Sistema Elétrico em Análise

O sistema elétrico em estudo é um SD para testes do Conselho Internacional de Grandes Sistemas Elétricos, em francês *Conseil International des Grands Réseaux Électriques* (CIGRÉ), baseado em um sistema real de distribuição europeu com tensão nominal de 20 kV e frequência nominal de 50 Hz. Todos os parâmetros desse sistema foram retirados da brochura oficial (CIGRÉ Task Force C6.04, 2014). Porém, para este trabalho, a frequência do sistema foi alterada para 60 Hz e todas as impedâncias do sistema foram recalculadas. O diagrama unifilar do sistema é apresentado na Figura 2.

Antes de efetuar a alteração da frequência, o sistema foi modelado com os seus valores nominais, para validar a modelagem, feita no software Alternative Transient Program (ATP) pela interface do software ATPDraw (ATPDraw, 2017). Após a validação dos valores, efetuou-se os ajustes das impedâncias do sistema para alterar a frequência para 60 Hz.

Verifica-se na Figura 2 que o GD, conectado à barra 5, possui uma potência nominal de 5 MVA e opera com controle P-Q. Tal GD consiste em uma



Figura 2. Sistema de distribuição em estudo.

máquina síncrona com potência mecânica fornecida por uma turbina a vapor.

2.2 Detecção de evento

Após a leitura dos sinais de tensão, é realizada a detecção de evento para evitar a constante execução do algoritmo, conforme apresentada na Figura 1.

Para essa detecção foi adotada a análise das componentes de sequência negativa (V_2) e zero (V_0) da tensão no PAC. Como o sistema em estudo é equilibrado, as variações de V_0 e V_2 indicam a ocorrência de eventos transitórios. Caso a taxa de variação destes sinais exceda um limiar definido, o sistema reconhece a ocorrência de um transitório e a execução do algoritmo se inicia.

2.3 Transformada S

Para extrair características da tensão amostrada no PAC, optou-se por utilizar o espectro de frequência do sinal. Um dos métodos mais consolidados para esta analise é o uso da Transformada de Fourier de Tempo Curto (TFTC), apresentada na Equação 1. Porém, por utilizar uma janela de largura fixa, a TFTC considera o sinal sendo estacionário dentro desta janela, apresentando o mesmo espectro durante todo este período (Moukadem et al., 2014).

$$S_x(\tau, f) = \int_{-\infty}^{\infty} x(t)w(t-\tau, f)e^{-j2\pi ft}dt \qquad (1)$$

Outra técnica de análise no domínio da frequência é a TW, que apresenta um tamanho variável de sua janela de acordo com a frequência do sinal, sendo assim capaz de melhor representar o espectro do sinal (Daubechies, 1992).

A TS, proposta por Stockwell em 1996, pode ser considerada um método híbrido entre a TFTC e a TW (Moukadem et al., 2014). De modo similar a TFTC, a TS efetua o janelamento do sinal a ser analisado, utilizando uma janela w(t, f) com formato de uma gaussiana, conforme apresentado na Equação 2.

$$w(t,f) = \frac{1}{\sigma(f)\sqrt{2\pi}}e^{\frac{-t}{2\sigma f^2}}$$
(2)

Na janela gaussiana utilizada pela TS, assim como ocorre na TW, a sua largura é variável de acordo com a frequência do sinal, como expresso na Equação 3.

$$\sigma(f) = \frac{1}{|f|} \tag{3}$$

Assim, a equação final da TS fica como apresentado na Equação 4.

$$S_x(\tau, f) = \frac{|f|}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x(t) e^{\frac{-(t-\tau)^2 f^2}{2}} e^{-j2\pi f t} dt$$
(4)

2.4 Discretização dos Sinais

Após a extração das características efetuada pela TS, foram obtidos 32 níveis de frequência para cada fase da tensão de entrada. Porém, para simplificar a análise, esses níveis foram agrupados 4 a 4, resultando em 8 conjuntos de níveis por fase, como ilustrado na Figura 3. Entretanto, para se ter um valor quantitativo como entrada e não um sinal no tempo, os níveis de frequências obtidos ainda precisam ser discretizados para serem utilizados como entrada para o classificador. Para efetuar a discretização, foi testado o valor de máximo e a energia do sinal, sendo utilizada esta última por ter apresentado melhor resposta nos testes.

Figura 3. Níveis de frequência obtidos pela transformada S simplificados e discretizados pelo uso da energia do sinal.

Devido às amplitudes dos sinais de entrada serem bastante diferentes entre elas, o valor da energia dos mesmos apresentava grande desproporcionalidade. Assim, foi feita a conversão da energia do sinal para decibéis, o que deixou os valores de energia mais próximos e proporcionou uma melhor comparação.

Com os 8 valores de energia obtidos para cada uma das três fases, tem-se um total de 24 valores de energia que são utilizados de entrada para o classificador. Todavia, utilizar todas a entradas pode ser prejudicial ao desempenho final do classificador e gerar um grande esforço computacional para o treino. Assim, foi efetuada uma seleção das entradas do sistema de classificação de modo proporcional entre cada uma das fases.

Para a seleção das entradas do classificador foi utilizada a Característica de Operação do Receptor, ou *Receiver Operating Characteristic* (ROC), ou simplesmente curva ROC (Powers, 2011).

A curva ROC é uma representação gráfica entre os verdadeiros positivos e os falsos positivos para diferentes limiares de separação da variável analisada. Para elucidar a aplicação da curva ROC, a Figura 4 apresenta a curva ROC para 3 entradas genéricas distintas.



Figura 4. Curva ROC para 3 entradas em um problema de classificação.

De modo a mensurar a capacidade da variável em classificar os dados corretamente, utiliza-se a área sob a curva ROC. Assim, quanto maior a área, melhor é a contribuição da entrada para a correta classificação. Considerando a curva ROC das 3 entradas ilustradas na Figura 4, a listagem por ordem decrescente de relevância para a classificação seria a entrada 2, 1 e 3, respectivamente.

Neste trabalho, a curva ROC foi utilizada para selecionar as entradas dos classificadores e assim reduzir o esforço computacional que um grande número de entradas pode ocasionar.

2.5 Classificadores

Neste trabalho foram analisados dois classificadores diferentes, sendo um classificador baseado em lógica fuzzy e outro baseado em RNA treinada com o uso do ELM.

2.5.1 Sistema Fuzzy

As variáveis de entrada do sistema fuzzy possuem funções de pertinência do tipo trapezoidal, como apresentado de forma genérica na Figura 5. Na figura, o parâmetro α representa o ponto de interseção entre as duas funções de pertinência e o β define a distância entre os dois pontos onde as funções passam a ter valores diferentes de zero. O parâmetro α define a posição das funções de pertinência e o β a inclinação delas.

Quanto à saída do sistema fuzzy, as funções de pertinência foram definidas conforme ilustradas na Figura 6.



Figura 5. Funções de pertinência genéricas para um sistema de inferência fuzzy.



Figura 6. Funções de pertinência genéricas para um sistema de inferência fuzzy.

Para concluir o projeto do classificador fuzzy é necessário o ajuste das funções de pertinência de cada uma das entradas e as regras. Entretanto, devido à ausência de um especialista no problema para efetuar esse ajuste, foi necessário o uso de um algoritmo de otimização. Devido ao foco do trabalho ser na detecção do ilhamento, buscou-se um algoritmo simples e que necessitasse de poucos ajustes para encontrar uma solução adequada.

Inicialmente foi utilizado um algoritmo chamado *Simulated Annealing* (SA), que foi desenvolvido tendo como base o processo de recozimento do aço (*annealing*, em inglês). Neste processo o material é aquecido e depois resfriado a uma taxa constante de modo a remover o estresse interno do material (Kirkpatrick et al., 1983). De modo similar, o SA possui uma variável interna de temperatura que está relacionada à aleatoriedade da busca no universo de soluções. Com o passar das iterações, a temperatura reduz, tornando a busca mais focada e menos aleatória.

Posteriormente, após conseguir alguns resultados, verificou-se que as taxas de acerto na classificação obtida com a otimização do SA poderiam ser melhoradas. Por suspeitar-se que a busca realizada pelo algoritmo estava ficando restrita a certas regiões, optou-se por utilizar uma nova ferramenta de otimização capaz de explorar diferentes soluções para se obter maiores taxa de acerto. Deste modo, o Algoritmo Genético (AG) foi escolhido por atender as especificações requeridas.

2.5.2 RNA

Com relação ao classificador baseado em RNA, este foi implementado utilizando uma arquitetura do tipo *feedforward* com apenas uma camada escondida com função de ativação sigmoidal. A camada de saída possui apenas um neurônio, devido ao problema de classificação ser binário, com função de ativação linear. Com relação a quantidade de neurônios na camada escondida da RNA, foi efetuado um estudo para verificar a quantidade de neurônios que possibilitaria a melhor resposta para cada caso e algoritmo de treinamento. Nesse estudo foram efetuados 50 treinamentos para cada topologia e a que apresentou melhor resposta foi escolhida como a topologia final.

Outra análise efetuada com a RNA foi a comparação dos dois algoritmos de treinamentos apresentados anteriormente, o *Backpropagation* (BP) e ELM. O algoritmo de treinamento ELM foi primeiramente publicado em um trabalho de Huang et al. (2006). O objetivo de seu desenvolvimento foi em resolver os problemas de mínimos locais, *overfitting* e elevado tempo de treinamento relacionados ao BP.

2.6 Dados das Simulações

Os dados utilizados para o treinamento e teste dos classificadores foram extraídos do sistema modelado no *software* ATP. Foram extraídos os dados de 4 diferentes eventos: faltas, entradas/saídas de cargas e ilhamentos. Os detalhes referentes a cada uma das situações analisadas estão detalhados abaixo.

• Treinamento: 3429 casos

- Faltas: foram aplicados os 11 tipos de falta em todas as 11 barras do alimentador 1 com 3 valores de impedância de falta (0 Ω , 25 Ω e 50 Ω), totalizando 363 casos;

- Entrada/saída de carga: foram combinadas as cargas conectadas às 9 últimas barras do alimentador 1 com dois valores de potência gerada pelo GD (0,5 p.u. e 1,0 p.u.), totalizando 1022 casos para entrada e 1022 para saída de carga;

- Ilhamento: com a abertura do disjuntor entre as barras 2 e 3, foi feita a combinação das cargas de todas as 9 barras presente no sistema ilhado com dois valores de potência gerada (0,5 p.u. e 1 p.u.), resultando em 1022 casos de ilhamento.

• Teste: 19149 casos

- Faltas: foram aplicadas os 11 tipos de falta em todas as 11 barras do alimentador 1 com 6 valores de impedância de falta (5 Ω , 10 Ω , 20 Ω , 30 Ω , 40 Ω e 45 Ω), totalizando 726 casos;

- Entrada/saída de carga: foram combinadas as cargas conectadas às 9 últimas barras do alimentador 1 (sendo 11 cargas divididas em grupos comerciais e residenciais) com três valores de potência gerada pelo GD (0,6 p.u., 0,75 p.u. e 0,9 p.u.), totalizando 6141 casos para entrada e 6141 para saída de carga;

- Ilhamento: com a abertura do disjuntor entre as barras 2 e 3, foi feita a combinação das cargas de todas as 9 barras presente no sistema ilhado (sendo 11 blocos de carga) com três valores de potência gerada (0,6 p.u., 0,75 p.u. e 0,9 p.u.), resultando em 6141 casos de ilhamento.

3 Resultados e Discussões

Primeiramente, para se ter um valor de referência para a taxa de acerto dos classificadores, foi modelado um relé de sub/sobre frequência configurado com diferentes valores de limiar de detecção. Para avaliar o relé convencional modelado, frente ao conjunto de teste, calculou-se a sua taxa de acerto (TA), taxa de falsos negativos (TFN) e taxa de falsos positivos (TFP), apresentados na Tabela 1. O cálculo de cada uma das métricas foi realizado de acordo com as equações abaixo (Fawcett, 2006; Powers, 2011).

$$TA = \frac{VP + VN}{P + N} = \frac{VP + VN}{VP + FN + FP + VN}$$
(5)

$$TFN = \frac{FN}{P} = \frac{FN}{FN + VP} \tag{6}$$

$$TFP = \frac{FP}{N} = \frac{FP}{FP + VN} \tag{7}$$

Onde VP é o número de casos de verdadeiro positivo, ou seja, onde o evento foi classificado corretamente como ilhamento. VN, por sua vez, é o número de casos de verdadeiro negativo, isto é, casos em que o evento é classificado corretamente como não ilhamento (entrada/saída de carga ou faltas). FN é o número de casos de falso negativo, ou seja, casos positivos classificados incorretamente como negativos. FP é o número de casos de falso positivo, que são casos negativos classificados erroneamente como positivos. P e N são o número total de casos positivos e negativos, respectivamente.

Tabela 1. Taxa de acerto do relé convencional para diferentes valores de ajuste.

Limiar [Hz]	TA	TFN	TFP
1,00	89,49%	31,20%	0,74%
0,50	$94,\!84\%$	$5,\!60\%$	4,95%
0,25	67,47%	$1,\!17\%$	$47,\!34\%$

Percebe-se que o limiar de detecção de 0,50 Hz foi o melhor ajuste para o relé de frequência pois proporcionou a maior taxa de acerto e valores razoáveis para TFN e TFP. Assim, este valor será utilizado de base para comparação com as técnicas inteligentes propostas.

3.1 Classificador Fuzzy

Como mencionado anteriormente, o processo de ajuste das funções de pertinência e do conjunto

de regras foi realizado com o uso de algoritmos de otimização.

Para o classificador fuzzy, as entradas foram limitadas em apenas três valores de energia do espectro de frequência, sendo um para cada fase do sistema $(Ea_{f3}, Eb_{f6} \ e \ Ec_{f8})$. Isso foi feito para simplificar o classificador e, assim, reduzir o esforço computacional durante a fase de ajuste dos parâmetros. A escolha das entradas foi realizada de forma empírica com base nos valores da curva ROC.

Inicialmente, foi utilizado o algoritmo de otimização SA para definir os melhores valores para os parâmetros do sistema fuzzy. Todavia, devido à resposta final ser dependente do ponto inicial e da aleatoriedade presente no algoritmo, foi efetuada a otimização do classificador fuzzy 30 vezes consecutivas. A melhor resposta encontrada nesta etapa foi considerada como a configuração final para o classificador e foi utilizada para efetuar as demais análises de desempenho do classificador. A Tabela 2 apresenta os índices de desempenho do melhor ajuste encontrado usando o SA.

Tabela 2. Desempenho do classificador fuzzy ajustado com o Simulated Annealing.

TA	TFN	TFP
95,92%	$2,\!91\%$	$4,\!63\%$

Mesmo com um resultado encontrado pelo SA ter sido melhor que o relé convencional, foi observado que durante o ajuste do sistema fuzzy o SA não estava convergindo para soluções apropriadas. A Figura 7 apresenta as amostras de teste com diferentes marcadores, possibilitando a visualização de como as amostras foram classificadas.



Figura 7. Resultado visual das classificações dos eventos utilizando o Fuzzy ajustado pelo SA.

Ainda em relação à Figura 7, há 3 planos que ilustram as fronteiras de separação do classificador fuzzy para cada uma das entradas. Percebe-se que a otimização, a qual foi responsável por ajustar a posição dos planos de separação, rejeitou a influência da entrada Ea_{f3} , representada pelo plano em vermelho, deslocando-a para a extremidade direita do espaço de amostras. Isso mostra que o algoritmo de otimização SA não conseguiu encontrar uma solução melhor por estar se limitando a ajustar certos valores dos parâmetros do classificador fuzzy e não ter alterado outros. Por esse motivo, optou-se por efetuar a otimização com o uso de um algoritmo diferente, sendo utilizado o AG.

A fim de encontrar a melhor resposta do AG foram testadas diferentes tamanhos da população com 16, 32, 64, 128 e 256 indivíduos em cada geração. Assim, para cada um dos valores da quantidade de indivíduos o algoritmo foi executado 10 vezes. Os valores de desempenho da melhor configuração do classificador fuzzy para cada tamanho da população estão apresentados na Tabela 3.

Tabela 3. Desempenho do classificador fuzzy ajustado com o AG.

População	TA	TFN	TFP
16	83,97%	$45,\!12\%$	$2,\!30\%$
32	95,86%	4,09%	4,16%
64	96,15%	$3,\!92\%$	$3,\!81\%$
128	97,18%	5,28%	1,66%
256	95,98%	$3{,}08\%$	4,46%

Como apresentado na Tabela 3, o melhor resultado foi encontrado com uma população de 128 indivíduos. A taxa de acerto de 97, 18% encontrada pelo AG foi superior a obtida com o uso do SA (95,92%), mostrando que a utilização de um diferente algoritmo de otimização possibilitou melhor desempenho ao classificador fuzzy.

A Figura 8 apresenta as amostras de teste e os planos de separação do classificador fuzzy otimizado com o uso do AG. É possível ver que o AG conseguiu otimizar a classificação utilizando as 3 entradas disponíveis, resultando em um desempenho superior ao do SA.



Figura 8. Resultado visual das classificações dos eventos utilizando o Fuzzy ajustado pelo AG.

Apesar dos dois classificadores fuzzy terem obtidos resultados com elevada taxa de acerto, os mesmos apresentam a desvantagem de elevado esforço computacional.

3.2 RNA

Por apresentar um treinamento mais curto, quando comparado com a otimização do classificador fuzzy, foram analisadas 6 topologias diferentes. Isso foi feito para analisar a relação das entradas com a taxa final de acerto da classificação. As topologias analisadas estão representadas na Tabela 4.

Tabela 4. Topologias analisadas para o classificador baseado em RNA.

Topologia	Número de entradas	Fase A	Fase B	Fase C
1	3	$\uparrow = E_{f3}$	$\uparrow = E_{f1}$	$\uparrow = E_{f8}$
2	3	$\uparrow = E_{f3}$	$\uparrow = E_{f1}$	$\downarrow = E_{f5}$
3	3	$\uparrow = E_{f3}$	$\downarrow = E_{f6}$	$\uparrow = E_{f8}$
4	3	$\downarrow = E_{f5}$	$\uparrow = E_{f1}$	$\uparrow = E_{f8}$
5	6	$\uparrow \downarrow = E_{f3} \ e \ E_{f5}$	$\uparrow \downarrow = E_{f1} \ e \ E_{f6}$	$\uparrow \downarrow = E_{f8} \ e \ E_{f5}$
6	24	$E_{f1}, E_{f2}, \cdots, E_{f8}$	$E_{f1}, E_{f2}, \cdots, E_{f8}$	$E_{f1}, E_{f2}, \cdots, E_{f8}$

A topologia 1 possui como entrada o nível de energia com maior área sob a curva ROC (indicada pela seta orientada para cima) de cada uma das fases do sistema. As topologias 2, 3 e 4 apresentam uma combinação entre as entradas com maior e menor área sob a curva ROC, sendo utilizadas uma entrada por fase. Na topologia 5 foram utilizadas 6 entradas, com a maior e menor área sob a curva ROC para cada fase. Já na topologia 6, foram utilizadas todas as 24 entradas disponíveis.

Para modelar a RNA é necessário determinar a quantidade de neurônios presentes na camada neural intermediária. Esse valor foi encontrado de forma empírica variando a quantidade de neurônios de 5 até 300, sendo realizados 50 treinamentos para cada topologia. Com base na taxa de acerto média do teste, foi adotada a quantidade de neurônios que conseguiu a melhor taxa de acerto como sendo a configuração ideal para a topologia em análise.

Para comparar o desempenho do algoritmo de treinamento ELM com o BP foram treinadas 2 redes diferentes, sendo utilizada para cada uma delas a quantidade de neurônios que resultou na maior taxa de acerto. Para cada topologia foram executados 50 treinamentos, e os valores médios de acerto e tempo estão apresentados na Tabela 5.

Tabela 5. Comparativo da performance das 2 RNAs para cada uma das topologias estudadas.

Topologia	Algoritmo de treinamento	TA no teste	Número de neurônios	Tempo de treinamento
1	BP	89,45 %	20	0,124 s
1	ELM	91,90 %	110	0,120 s
2	BP	94,25 %	60	0,246 s
	ELM	93,55~%	90	0,104 s
3	BP	97,19 %	20	0,148 s
	ELM	97,00 %	30	$0,017 \ s$
4	BP	88,10 %	60	0,284 s
	ELM	94,36 %	40	0,028 s
5	BP	99,85~%	90	0,410 s
	ELM	99,96 %	150	0,181 s
6	BP	99,80 %	20	0,285 s
	ELM	99,98 %	220	0,253 s

Percebe-se que na maioria dos casos estudados, o ELM apresentou resultados melhores, com exceção apenas das topologias 2 e 3, em que a rede treinada com o BP apresentou a maior taxa de acerto. Evidencia-se que a diferença entre a taxa de acerto do ELM e do BP para as topologias 5 e 6 foi extremamente pequena. Em relação ao tempo de treinamento da RNA, o ELM apresentou tempos menores que BP para todas as análises, mostrando-se de acordo com o indicado na literatura (Huang et al., 2006).

3.3 Comparação das Técnicas de Detecção de Ilhamento

Para comparar os resultados dos classificadores modelados neste trabalho, foi considerada somente a RNA com a topologia 3, a qual possui as mesmas entradas que o classificador fuzzy. A Tabela 6 contém os índices de desempenhos dos melhores resultados obtidos pelas 5 proteções antiilhamento apresentadas anteriormente.

Tabela 6. Comparativo dos melhores resultados obtidos para as técnicas de detecção de ilhamento modeladas.

Método	TA	TFN	TFP
Relé de frequência	$94,\!84\%$	$5,\!60~\%$	4,95~%
Fuzzy SA	$95,\!92\%$	2,91~%	$4,\!63~\%$
Fuzzy AG	$97,\!18\%$	5,28~%	1,66~%
BP	97,90%	3,24~%	1,56~%
ELM	$97,\!61\%$	$3,\!00~\%$	2,10~%

Observa-se que todos os métodos passivos inteligentes propostos conseguiram uma taxa de acerto na detecção do ilhamento maior que a proteção convencional baseada na frequência. Outro ponto relevante, foi que os menores valores de TFN e TFP foram obtidos com os métodos que utilizam a RNA.

4 Conclusões

Este trabalho tem como tema a proteção dos sistemas elétricos de potência, mais especificamente, a proteção anti-ilhamento de geradores síncronos distribuídos com o uso de técnicas passivas inteligentes. Os métodos propostos utilizam técnicas de aprendizagem de máquina para distinguir condições de ilhamento dos demais eventos do sistema elétrico estudado, tendo como entrada medidas locais de tensão.

Com base nos resultados obtidos pode-se concluir que os métodos propostos conseguiram um desempenho superior quando comparados com a proteção convencional. Todos os métodos baseados em aprendizagem de máquina conseguiram reduzir o número de FN e FP, ou seja de ilhamentos não detectados e de falso *trips*, respectivamente. Sendo esses dois indicadores de extrema importância para a proteção anti-ilhamento. O classificador fuzzy teve uma taxa de acerto elevada. Porém, devido a necessidade da otimização das funções de pertinência e o conjunto de regras, o mesmo se torna um método que demanda bastante tempo para o ajuste das funções de pertinências e o conjunto de regras. Esse foi um do motivos pelo qual foi utilizado apenas 3 entradas para simplificar o classificador fuzzy. Um modelo com mais entradas demandaria ainda mais tempo para a otimização dos parâmetros. Entretanto, esse método ainda será estudado, procurando-se soluções paliativas para esse tempo de processamento.

O classificador baseado em RNA, além de possuir um tempo de treinamento da ordem de segundos, foi o método que obteve as maiores taxas de acerto. Isso se dá pela capacidade de generalização das RNAs, sendo capazes de lidarem bem com problemas de complexidade maior. Assim, mostrando-se como o mais promissor dos métodos aqui apresentados.

Para trabalho futuros, pode-se comparar a resposta do classificador com o uso da TW e da TS para a extração de características do espectro de frequência. Outro estudo pode ser realizado para analisar diferentes ferramentas para a seleção de atributos, além da inclusão de outros geradores no sistema em estudo.

Agradecimentos

Os autores gostariam de agradecer à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes), à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo n° 2017/16742-7, pelo suporte financeiro disponibilizado para a realização deste projeto de pesquisa e ao Laboratório de Sistemas de Energia Elétrica (LSEE) da EESC pelo apoio e infraestrutura fornecida.

References

- ANEEL (2018). Geração distribuída. http://www2.aneel.gov.br/scg/gd/VerGD.asp, acessado em 10/01/2018.
- ATPDraw (2017). ATPDraw The graphical preprocessor to ATP Electromagnetic Transients Program. http://www.atpdraw.net, acessado em 10/01/2018.
- CIGRÉ Task Force C6.04 (2014). Benchmark systems for network integration of renewable and distributed energy resources. Brochura Técnica 575.
- Daubechies, I. (1992). Ten Lectures on Wavelets.
- Fawcett, T. (2006). An introduction to ROC analysis, Pattern Recognition Letters 27(8): 861– 874.

- Fayyad, Y. and Osman, A. (2010). Neuro-wavelet based islanding detection technique, EPEC 2010 - IEEE Electrical Power and Energy Conference: Sustainable Energy for an Intelligent Grid.
- Huang, G. B., Zhu, Q. Y. and Siew, C. K. (2006). Extreme learning machine: Theory and applications, *Neurocomputing* **70**(1-3): 489–501.
- Kirkpatrick, S., Gelatt, C. D. and Vecchi, M. P. (1983). Optimization by simulated annealing, *Science* 220(4598): 671–680.
- Lidula, N. W. A. and Rajapakse, A. D. (2009). Investigation of a fast islanding detection methodology using transient signals, 2009 IEEE Power & Energy Society General Meeting pp. 1–6.
- Mahat, P., Chen, Z. and Bak-Jensen, B. (2008). Review of islanding detection methods for distributed generation, 2008 Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, number Abril, IEEE, pp. 2743– 2748.
- Mishra, M., Rout, P. K., Sahu, R., Ray, D. and Swarup, S. (2016). Study the performance of S-transform based extreme learning Machine for islanding detection in distributed generation, 2016 National Power Systems Conference (NPSC), IEEE, pp. 1–6.
- Moukadem, A., Abdeslam, D. O. and Dieterlen, A. (2014). Time-Frequency Domain for Segmentation and Classification of Nonstationary Signals: The Stockwell Transform Applied on Bio-signals and Electric Signals, John Wiley & Sons.
- Powers, D. M. W. (2011). Evaluation: From Precision, Recall and F-Measure To Roc, Informedness, Markedness & Correlation, Journal of Machine Learning Technologies 2(1): 37–63.
- Ray, P. K., Kishor, N. and Mohanty, S. R. (2012). Islanding and Power Quality Disturbance Detection in Grid-Connected Hybrid Power System Using Wavelet and S-Transform, *IEEE Trans. Smart Grid* 3(3): 1082–1094.
- Samantaray, S. R., El-Arroudi, K., Joos, G. and Kamwa, I. (2010). A fuzzy rule based approach for islanding detection in distributed generation, *IEEE Trans. Power Del.* 25(3): 1427–1433.
- Walling, R. A. and Miller, N. W. (2002). Distributed generation islanding-implications on power system dynamic performance, *IEEE Power Engineering Society Summer Meeting*, Vol. 1, pp. 92–96 vol.1.