

METODOLOGIA BASEADA NO ALGORITMO ADABOOST COMBINADO COM REDE NEURAL PARA LOCALIZAÇÃO DO DISTÚRPIO DE AFUNDAMENTO DE TENSÃO

FABBIO A. S. BORGES¹, RICARDO A. L. RABELO¹, MARCEL A. ARAUJO², RICARDO A. S. FERNANDES³

¹*Programa de Pós-Graduação em Ciência da Computação da Universidade Federal do Piauí
Campus Universitário Ministro Petrônio Portella CEP: 64049-550 Teresina - PI*

²*Unidade Acadêmica do Cabo de Santo Agostinho - Universidade Federal Rural De Pernambuco
Rua Dom Manoel de Medeiros, s/n – Dois Irmãos – Recife, PE, CEP 52.171-900*

³*Departamento de Engenharia Elétrica, CCET - Universidade Federal de São Carlos Rodovia Washington
Luís, km 235 - SP-310, CEP 13565-905, São Carlos – SP*

*E-mails: fabbioanderson@gmail.com, ricardoalr@ufpi.edu.br,
ricardo.asf@ufscar.br, assim@dominio.pais*

Abstract— The correct location of the voltage sag sources is not a trivial task, because of the short duration of these events and for rapid propagation in the distribution feeder. This paper proposes a method based in ensemble method of the type Adaboost with neural networks as base classifiers for determines the area where the voltage sag source is located. A voltage sag at the a bus affects all of the other feeders, i.e. this disturbance is propagated in the all system. The data management from smart meters installed in distribution feeders and decision support tools can become a viable alternative. In this sense, the smart meters could extract feature of the voltage sag and sent it to the utility. At the utility side, the AdaBoost performs location of the region by measuring the input's features similarity to examples from the training set. For this purpose, it was necessary analyze the relevance of each feature extracted from smart meters' voltage signals establish the structure which best represents propagation the disturbance in system. The AdaBoost whit Neural Network was tested in different Cenários of the IEEE 13-bus test feeder and was able to estimate the region with a good accuracy.

Keywords— AdaBoost distribution feeders, disturbance location, neural networks, voltage sag, power quality.

Resumo— A correta localização dos distúrbios de afundamento de tensão no sistema de distribuição não é uma tarefa trivial, devido à curta duração desses eventos e sua rápida disseminação na rede. Este artigo propõe a aplicação do algoritmo Adaboost com Redes Neurais para estimar a região de origem do distúrbio. A ocorrência do afundamento de tensão no sistema afeta todos as barras, ou seja, esse distúrbio é propagado em todo o sistema. Assim, o gerenciamento de dados, por meio dos *smart meters* combinado com ferramentas de classificação torna-se uma alternativa viável para auxiliar na localização. Nesse sentido, os *smart meters* conseguem extrair as características do distúrbio de afundamento de tensão medido e enviar para a concessionária. No lado da concessionária, os valores de características de vários medidores são agregados e utilizados como entrada do AdaBoost. Para tanto, foi necessário analisar a relevância do conjunto de característica extraída dos sinais de tensão, de modo a comprovar se o vetor extraído evidencia a disseminação do distúrbio na rede. O AdaBoost com Rede Neural foi testado em diferentes cenários do alimentador de teste IEEE de 13 barramentos e foi capaz de estimar a região com uma boa precisão.

Palavras-chave— AdaBoost, Sistema de Distribuição, Localização do distúrbio, Rede Neural, Afundamento de tensão, qualidade de energia

1. Introdução

O distúrbio de afundamento de tensão corresponde a uma redução entre 0,9 e 0,1 p.u. do valor eficaz da tensão nominal por um curto período de tempo e destacam-se como sendo a alteração da forma de onda que mais se manifesta nas redes elétricas (Dugan et al., 2002). A principal causa da ocorrência desses eventos corresponde a curto-circuito no sistema de energia e sua presença ocasiona danos aos consumidores, uma vez que as cargas possuem restrita tolerância em relação à tensão de alimentação (IEEEStd1159, 2009). Portanto, é importante garantir uma boa qualidade de energia elétrica por meio da eliminação desse distúrbio.

Os métodos de localizados do distúrbio de qualidade de energia elétrica têm como finalidade apontar o local, no sistema de distribuição, de origem do distúrbio, sendo o primeiro passo para se diagnosticar o problema. Por consequência medidas de controle po-

dem ser executadas de modo a aumentar a qualidade de energia. No entanto, essa tarefa não é trivial, pelo fato de que os afundamentos de tensão ocorrem em um curto intervalo de tempo e se propagam ao longo de todo sistema (Chang and Chao, 2008).

Considerando as técnicas encontradas na literatura, observa-se que os métodos tipicamente determinam se o distúrbio foi gerado a montante ou a jusante do ponto de medição, com base em vários critérios, tais como a energia da perturbação (Parsons et al., 2000), relação entre a tensão e a corrente durante a queda (Li et al., 2003).

A estimativa exata da região de localização, ao contrário da posição relativa desempenha um papel fundamental nas decisões a serem tomadas pelo utilitário.

Nesse contexto, os métodos para localização devem analisar as informações coordenadas de vários medidores. Baseado na comunicação bidirecional estabelecida nas redes *Smart Grids*, novos métodos para localização podem ser desenvolvidos. (Erolkantarci and Mouftah, 2015) eles realizam um proces-

samento dos dados advindos dos medidores inteligentes para determinar padrões e inferir na localização dos distúrbios.

Em (Faisal and Mohamed, 2009) (Shareef e Mohamed, 2013), o local de origem do afundamento de tensão é determinado analisando a tensão estimada em cada barra, por meio de uma Rede Neural Artificial com função de base radial (RBF – *Radial Basis Function*). Em (Shareef et al., 2013), a Transformada-S é utilizada para extrair as características do sinal, enquanto o SVM (*Support Vector Machine*) é responsável por definir a zona de ocorrência do distúrbio.

Os métodos acima não analisam a influências das características topológicas e operacionais dos sistemas de distribuição. Portanto, eles têm suas limitações e não conseguem alcançar cobertura e desenvolvimento satisfatórios. Portanto, é necessário investigar novos métodos para a localização da fonte geradora de afundamento que contemple as características topológicas do sistema.

Diante disso, esse artigo propõe o desenvolvimento de um algoritmo que aponta a zona de localização do distúrbio a partir da análise das características simples extraídas do distúrbio evidenciado em cada ponto de medição. Os dados de características são utilizados como entrada do método AdaBoost. O método determina a região analisando as características do sinal de tensão em todos os pontos durante a ocorrência do distúrbio.

Para este efeito, foi necessário analisar os recursos extraídos do sinal de tensão e determinar a relevância de cada característica. Assim, o sistema de distribuição é dividido em regiões e a metodologia estima a região de localização do afundamento de acordo com as características de entrada para o método AdaBoost.

2 ADABOOST

AdaBoost ou Adaptive Boosting é um *ensemble method* que corresponde a uma classe de algoritmos de aprendizagem de máquina que são formados por vários classificadores. A saída do algoritmo corresponde ao resultado combinado da saída dos classificadores que compõem o método (Baig et al., 2017).

O ensemble do tipo Boosting constrói, na fase de treinamento, hipóteses (modelos de classificadores) sucessivas, de tal modo que exemplos classificados incorretamente por hipóteses anteriores sejam melhor classificados pelas hipóteses seguintes (Freund e Schapire, 2006). Após treinado, a saída é obtida combinando todas saídas produzidas por cada hipótese. O algoritmo utilizado para treinar cada modelo de classificador é denominado algoritmo base. Geralmente as árvores de decisão são utilizadas.

Assim, no treinamento o método induz de modo iterativo T modelos de classificadores. A construção da hipótese h_t é influenciada pelas amostras que foram classificadas incorretamente na hipótese anterior

ou h_{t-1} . A cada iteração t o método boosting gera uma hipótese a partir do conjunto de treinamento, o qual é formado pelo vetor de entrada, a saída desejada e também por um vetor de distribuição dos pesos D_t que quantifica a importância da amostra de entrada para a nova hipótese.

A nova hipótese deve priorizar a classificação correta dos dados que foram classificados de forma incorreta pela hipótese anterior. A nova hipótese é construída com objetivo de corrigir as classificações errôneas da hipótese anterior. Portanto, essas amostras devem apresentar um alto valor de peso.

Após induzido o novo classificador, o algoritmo de treinamento do método AdaBoost atualiza a distribuição de pesos D_t do conjunto de treinamento obtendo uma nova distribuição D_{t+1} que será utilizada para treinar a próxima hipótese. A atualização é feita conforme (1).

$$D_{t+1}(x_i) = \frac{D_t(x_i)}{Z_t} * \begin{cases} e^{(-\gamma_t)} & \text{se } h_t(x_i) = y_i \\ e^{(\gamma_t)} & \text{se } h_t(x_i) \neq y_i \end{cases} \quad (1)$$

onde y_i é a saída desejada, γ_t e Z_t são, respectivamente, a importância associada, e o termo normalizador da hipótese h_t , obtido por (2) e (3).

$$\gamma_t = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_t}{\varepsilon_t} \right) \quad (2)$$

$$Z_t = \sum_{i=1}^n D_t(x_i) * e^{(-\gamma_t y_i h_t(x_i))} \quad (3)$$

onde o erro de treinamento ε_t da hipótese h_t é obtido por (4)

$$\varepsilon_t = \sum_{i: h_t(x_i) \neq y_i} D_t(x_i) \quad (4)$$

Logo, o objetivo de cada hipótese é minimizar o erro do treinamento e quanto menor for a taxa de erro maior será a importância da hipótese para o modelo AdaBoost.

O processo continua até que seja gerada T hipótese. Após o processo de treinamento ser finalizado, os parâmetros γ_t e o modelo de cada hipótese t são armazenados sendo utilizados para classificar novas amostras. A saída de uma nova amostra é obtida a partir de uma votação ponderada de cada hipótese com sua importância associada, conforme (5)

$$H(x) = \text{sign} \left(\sum_{t=1}^T \gamma_t h_t(x) \right) \quad (5)$$

O processo de treinamento e execução do método AdaBoost é representado na Figura 1.

No trabalho o classificador base corresponde a uma Rede Neural Artificial do tipo Perceptron Multi Camada (PMC). As Redes Neurais são modelos computacionais inspirados no cérebro humano, que por sua vez conseguem adquirir e manter o conhecimento. Suas principais características são a capacidade

de de aprendizado e habilidade de generalização. A arquitetura PMC, é aplicada em tarefas de reconhecimento de padrões, aproximação funcional, identificação e controle.




Figura 1. AdaBoost scheme.

As RNA que compõem o modelo AdaBoost são definidas com a mesma estrutura de camadas escondidas. Assim, o número de entrada e o número de neurônios na camada de saída são definidos de acordo com a estrutura do conjunto de treinamento do AdaBoost. Para a indução de cada hipótese neural do AdaBoost foi escolhido o algoritmo *Levenberg-Marquardt*, pois acelera o processo de convergência, quando comparado com o algoritmo *backpropagation* convencional.

3. Metodologia Proposta

A metodologia proposta faz uso do método AdaBoost composto por classificadores bases do tipo Rede Neural *Perceptron* Multicamada para analisar os sinais de tensão fornecidos pelos *smart meters* durante a ocorrência do evento. O algoritmo deve retornar como saída uma região/zona de localização que deve compreender a barra de origem do distúrbio de afundamento de tensão.

Para o desenvolvimento da metodologia faz-se necessário primeiro extrair as características dos distúrbios presentes nos sinais de tensão fornecidos pelos *smart meters* e que são agregados na central de controle e processamento. Essas características devem exprimir o comportamento do afundamento de tensão que é originado em um ponto do sistema e refletido ao longo de toda a rede de distribuição. Em seguida o conjunto das características é utilizado como entrada para o método AdaBoost.

Ao utilizar um método de classificação para o problema de localização, faz-se necessário dividir o sistema de distribuição em classes. Cada classe é definida como uma zona/região composta por um conjunto de um ou mais nós que compõem o sistema de distribuição. Logo, o classificador AdaBoost induzido deve estimar a zona/região do sistema que agrega a

barra de origem do distúrbio. A Figura 2 apresenta um fluxograma da metodologia proposta.

Para o desenvolvimento da metodologia faz-se necessário a obtenção de um banco de informações com as simulações que originam evento de afundamento de tensão. Esse banco de informações será utilizado na fase de treinamento e validação. Além disso, é interessante analisar se as características de entrada representam a disseminação do distúrbio ao longo da rede. Cada uma das etapas do algoritmo desenvolvido será descrita nas subseções seguintes.




Figura 2. Fluxograma da metodologia proposta.

2.1 Simulação do Afundamento de Tensão

O método foi desenvolvido considerando o sistema teste do IEEE 13 Barras (Figura 3), o qual foi modelado por meio do software ATP (Alternative Transient Program).




Figura 3. IEEE 13-barras test feeder.

O distúrbio de afundamento de tensão é gerado a partir de simulações de curtos-circuitos monofásico envolvendo a fase A, B e C, curtos-circuitos bifásicos envolvendo a fase AB, AC e BC e curtos-circuitos trifásicos no sistema IEEE 13 barras. Assim, para gerar distúrbios com diferentes magnitudes e durações, em cada simulação foram alterados o ângulo de incidência e a resistência do curto-circuito. No trabalho considera-se seis valores de resistência de falta, que são 0.5, 1, 1.5, 3, 5, 7 e 10 ohms e quatro valores diferentes de ângulo de incidência que são 0°, 90°, 180° e 360°. Os curtos-circuitos foram aplicados em cada barra do sistema de acordo com as fases que

compõem a barra. A Tabela 1 descreve o tipo de curto-circuito aplicado em cada barra do sistema.

Tabela 1. Tipo de curto-circuito aplicado em cada barra

Tipo de curto-circuito	Barras
Curto-circuito trifásico	632,633,634, 671, 675 e 680
Curto-circuito monofásico envolvendo a fase A	632,633,634, 671, 675, 680, 684 e 652
Curto-circuito monofásico envolvendo a fase B	632,633,634,671, 675, 680, 645 e 646
Curto-circuito monofásico envolvendo a fase C	632,633,634, 652, 671,675, 680, 645, 646 e 611
Curto-circuito bifásico envolvendo a fase AB	632,633,634,671,675 e 680
Curto-circuito bifásico envolvendo a fase AC	632,633,634,671,675 e 680
Curto-circuito bifásico envolvendo a fase BC	632,633,634,671,675 e 680

Destaca-se que a barra 692 foi negligenciada pelo fato que está localizada no mesmo local da barra 671, sendo separada apenas por uma chave. Em cada simulação, considerou-se uma taxa de amostragem de 256 pontos/ciclo.

Após cada simulação os valores de tensão medido em cada nó do sistema são armazenados. Assim, obtém-se um banco de informações necessário para treinar e validar o algoritmo proposto. O processo de construção do banco de dados é feito a partir da comunicação entre o ATP® e MATLAB®.

2.2 Análise das características extraídas

Após a obtenção do banco de informações, determina-se as características que podem ser extraídas do afundamento de tensão medido em cada barra. As características extraídas sintetizam a característica de cada distúrbio.

Desse modo, depois de realizadas as simulações o sinal de tensão em cada barra é armazenado no banco de dados e processado. O processamento ocorre a partir de cálculos para extração de características das formas de onda de tensão medidas em cada barra do sistema no instante que o distúrbio ocorre. As características calculadas foram o *Root Mean Square* (RMS), Valor de Pico e Fator de Forma, que são expressas, respectivamente, em (6), (7) and (8):

$$V_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N v_i^2} \quad (6)$$

$$V_{peak} = V_{RMS} \cdot \sqrt{2} \quad (7)$$

$$FF = \frac{\frac{1}{N} \sum_{i=1}^N v_i}{V_{RMS}} \quad (8)$$

onde v_i representa o i^{th} ponto medido do sinal de tensão que caracteriza o distúrbio e N é a quantidade de pontos de cada distúrbio analisado .

A partir da extração de característica o sinal de tensão medido em cada barra é resumido em um vetor de três características.

Após definidas as métricas, duas simulações são analisadas para fim de determinar se as características extraídas representam o comportamento do sistema de acordo com o local de origem falta. Assim, analisa-se se as características definem a propagação do distúrbio independentemente do local de aplicação do curto-circuito.

Para este propósito, as Tabelas 2 e 3 apresentam, respectivamente, os valores de características que foram extraídos em cada barra resultante das simulações de um curto-circuito monofásico localizado na barra 632 (início do sistema) e na barra 611 (final do sistema).

A Tabela 2 descreve os dados para uma simulação de curto-circuito monofásico na barra 632, observa-se que para essa situação os valores de características obtidos são próximos, exceto o valor extraído do distúrbio evidenciado na barra 650 que corresponde a subestação. O nó 611 distante da origem do evento apresentou o menor valor da característica RMS e valor de pico. Por outro lado, o valor mais baixo para a característica fator de forma foi calculado em uma barra mais próxima ao local de origem. Para este cenário, conclui-se que o distúrbio flui da origem para as extremidades.

Tabela 2 Características extraídas do afundamento de tensão medido em cada barra para curto-circuito monofásico envolvendo a fase C aplicado na Barra 632.

Barra	RMS	Valor de Pico	Fator de Forma
611	0.52025	0.74141	-0.045955
632	0.52840	0.75353	-0.045598
633	0.52781	0.75271	-0.045592
634	0.52775	0.75262	-0.045590
645	0.52814	0.75312	-0.045420
646	0.52762	0.75235	-0.045348
671	0.52123	0.74317	-0.046023
675	0.52077	0.74251	-0.045933
680	0.52123	0.74317	-0.046023
684	0.52073	0.74228	-0.045988
692	0.52123	0.74317	-0.046023
650	0.61403	0.86653	-0.008474

Tabela 3. Características extraídas do afundamento de tensão medido em cada barra para curto-circuito monofásico envolvendo a fase C aplicado na Barra 611.

Barra	RMS	Valor de Pico	Fator de Forma
611	0.467	0.652	-0.0660
632	0.554	0.776	-0.0239
633	0.553	0.775	-0.0239
634	0.553	0.775	-0.0239
645	0.553	0.775	-0.0238
646	0.553	0.774	-0.0238
671	0.503	0.702	-0.0366
675	0.503	0.701	-0.0366
680	0.503	0.702	-0.0366
684	0.485	0.677	-0.0508
692	0.503	0.702	-0.0366
650	0.626	0.881	-0.0046

Ao analisar a Tabela 3, constata-se que o evento de afundamento de tensão é mais severo nas barras próximas ao local de origem do curto-circuito, sendo que o menor valor das características RMS, valor de pico e fator de forma foi evidenciado no local de aplicação do curto-circuito. Nesse cenário quanto mais distante a barra da origem do evento, menos severo é o distúrbio evidenciado na barra.

A partir desta análise foi possível observar que as características extraídas descrevem o comportamento do sistema na ocorrência de um distúrbio de afundamento de tensão de acordo com local de origem, ou seja, diferentes locais geram diferente comportamentos que são refletidos nos valores de características.

Em nós próximos da subestação que são menos susceptíveis aos distúrbios os valores de características estão próximos entre si. De modo contrário, quando a fonte de afundamento de tensão estiver localizada no final do alimentador, a perturbação tem uma intensidade maior no nó onde a fonte está localizada. Essa discrepância entre os valores é evidenciada por meio das características apresentadas na Tabela 3.

Portanto, o conjunto de características consegue destacar as semelhanças entre os distúrbios detectados em torno da região de origem do evento e apresenta dissimilaridades para distúrbios evidenciados longe da zona de origem do distúrbio e são bons indicadores para a localização da fonte de tensão.

Dessa forma, o método AdaBoost pode ser treinado e validado em diferentes cenários, utilizando como entrada o vetor de característica extraído de cada sinal de tensão enviado pelos *smart meters* instalados.

4 Cenários de Testes

A eficiência do método proposto pode ser influenciada pelo número de medidores instalados no sistema, pois quanto menor o número de medidores menor a quantidade de informação a respeito do fluxo do evento de afundamento de tensão.

Com o objetivo de investigar o desempenho e a robustez da metodologia de acordo com a quantidade de medidores no sistema, três topologias de medição foram consideradas, as quais se diferenciam de acordo com o número de medidores ativos no sistema. A Tabela 4 descreve as características de cada topologia, apresentando o número total de medidores e as barras que eles são instalados.

Na Topologia#1 os *smart meters* são instalados em todas as barras do sistema, com exceção da barra 692 que está no mesmo local da barra 670, sendo separada somente por uma chave, portanto é desconsiderada. Nesse caso, é possível obter informações do distúrbio em toda barra. Entretanto, a utilização de muitos medidores não é viável devido ao alto custo de sua instalação. A Topologia#3 destaca apenas 4 medidores ativos, sendo 3 localizados na extremidade (634 646 611) do sistema e 1 no ramo principal

(671). Essa topologia é a que apresenta o menor número de medidores e o menor custo, por consequência é a que fornece o menor número de informação. Por fim, a Topologia#2 corresponde a uma configuração intermediária entre a Topologia#1 e a Topologia#3.

Tabela 4. Descrição da topologia de medição.

	Quantidade de Medidores	Barras que os medidores estão ativados
Topologia #1	12	[650 632 633 634 646 645 671 675 684 611 652 680]
Topologia #2	6	[650 634 646 675 611 680]
Topologia #3	4	[634 646 671 611]

O número de regiões/zonas, nas quais o sistema é dividido também pode interferir diretamente no resultado da metodologia proposta. Cada zona corresponde a uma saída do AdaBoost e dizem respeito as classes do problema.

A fragmentação da rede de distribuição em várias regiões acarreta em uma maior segmentação do espaço de busca e, por consequência, pode influenciar na eficácia do classificador, pois as regiões podem apresentar padrões semelhantes. Por outro lado, em um cenário, no qual o sistema de distribuição é dividido em um pequeno número de regiões, cada uma agrega uma quantidade expressiva de barras. Assim, nessa situação a saída do método irá apontar uma região de origem extensa, composta por vários nós, o que não é viável para o problema.

Assim, é importante analisar a forma como as zonas/regiões são divididas de modo a determinar a influência no método. Para definir a quantidade de medidores e a configuração das zonas é necessário avaliar a topologia da rede, distância entre os nós e as fases de cada barra. O trabalho analisa a eficácia da metodologia proposta a partir de três tipos de divisão do sistema IEEE 13 barras. A Tabela 5 apresenta cada uma das três configurações analisadas.

Tabela 5. Descrição de cada divisão analisada do sistema de teste IEEE 13 barras.

	R_1	R_2	R_3	R_4	R_5
Divisão #1.	[645 646 632 633 634]	[671 692 675 680]	[611 684, 652]	-	-
Divisão #2.	[645 646]	[632 633 634]	[671 692 675 680]	[611 684 652]	-
Divisão #3.	[645 646]	[632 633 634]	[671 680]	675	[611 684 652]

A Tabela 5 destaca em cada linha as barras que compõem as zonas de acordo com as divisões analisadas. Assim, a Divisão#1 é formada por três zonas. A Divisão#2 é formada por quatro zonas. A Divisão#3 é estruturada por 5 zonas.

Considerando as três topologias de medição e as três configurações de divisões, têm-se nove cenários de teste para a metodologia. É importante comentar que as propriedades de cada cenário alteram a estrutura de entrada e saída dos classificadores AdaBoost construídos.

Com relação a entrada, cada medidor instalado envia informação do sinal de tensão que caracteriza o distúrbio detectado para a central de controle. Em seguida, a metodologia extrai de cada sinal recebido três características (RMS, Valor de Pico e Fator de Forma) que são utilizadas como entrada do método AdaBoost com Rede Neural. A entrada do algoritmo em cada cenário corresponde ao número de medidores ativos multiplicado pelo tamanho do vetor de característica extraído. Por sua vez, o número de classe de saída está equívale a quantidade de zona/região que a rede foi dividida.

Assim, após definida as características de cada cenário é possível obter a estrutura, em termos do número de entrada e saída dos modelos AdaBoost que são induzidos, como apresenta a Tabela 6.

Tabela 6. Descrição dos Cenários Analisados

	Estrutura Ada Boost	Topologia de Medição	Divisão
Cenário #1	Entradas: 36 Classe de Saída: 3	Topologia #1	Divisão #1.
Cenário #2	Entradas: 36 Classe de Saída: 4	Topologia #1	Divisão #2.
Cenário #3	Entradas: 36 Classe de Saída: 5	Topologia #1	Divisão #3.
Cenário #4	Entradas: 18 Classe de Saída: 3	Topologia #2	Divisão #1.
Cenário #5	Entradas: 18 Classe de Saída: 4	Topologia #2	Divisão #2.
Cenário #6	Entradas: 18 Classe de Saída: 5	Topologia #2	Divisão #3.
Cenário #7	Entradas: 12 Classe de Saída: 3	Topologia #3	Divisão #1.
Cenário #8	Entradas: 12 Classe de Saída: 4	Topologia #3	Divisão #2.
Cenário #9	Entradas: 12 Classe de Saída: 5	Topologia #3	Divisão #3.

De acordo com a Tabela 6 o melhor cenário para a tarefa de localização corresponde ao Cenário#1, pois o sistema apresenta medidores ativos em todos os nós, sendo totalmente observado e é dividido em poucas regiões. De modo contrário, o pior cenário corresponde ao Cenário#9, uma vez que é caracterizado pela Topologia #3 que possui somente quatro medidores ativos e a rede de distribuição é dividida em cinco regiões.

Seguindo a Tabela 6, são implementados 9 modelos de classificadores, cada um relacionado a um cenário específico. Eles foram induzidos com a mesma característica, mudando somente a estrutura de entrada e saída. Assim, são formados por 10 classificadores base do tipo Rede Neural Artificial (RNA) com arquitetura multicamadas. As RNAs que compõem

cada modelo AdaBoost induzido possuem a mesma estrutura, sendo constituídas por uma camada escondida composta por 8 neurônios. O número de entrada e neurônios da camada de saída são definidos de acordo com a estrutura de entrada e saída do classificador AdaBoost associado. Esta configuração foi escolhida de forma empírica. Quanto às funções de ativação, para a camada escondida, utilizou-se a tangente hiperbólica, e para a camada de saída empregou-se a função linear.

Para o treinamento de cada classificador AdaBoost com Rede Neural, foram considerados 70% dos casos da simulação pertencentes ao banco de dados. Esta quantidade de dados foi escolhida de forma que o método não sofra problemas de overfitting. Por sua vez, para verificar a eficiência desses classificadores, foi utilizado um conjunto formado por 30% das simulações restantes. Destaca-se que o resultado da validação da metodologia proposta é apresentado na seção seguinte.

5. Resultados e Discursões

No que se segue serão discutidos os resultados obtidos utilizando toda a abordagem proposta para localização dos distúrbios de afundamento de tensão no sistema IEEE 13 barras. A acurácia do método em cada cenário é comparada com os resultados obtidos pelos algoritmos de classificação do tipo árvore de decisão, RNA do tipo PMC e AdaBoost com árvore de decisão, os quais são induzidos a partir do mesmo conjunto de treinamento e validação utilizados na metodologia proposta. Os resultados são sumarizados na Tabela 7.

Tabela 7. Resultados

	AdaBoost com RNA	RNA	AdaBoost com Árvore de Decisão	Árvore de Decisão
Cenário #1	98,3%	97,6%	95,5%	91,9%
Cenário #2	98,6%	98,6%	96,2%	93,1%
Cenário #3	97,6%	94,0%	96,7%	92,9%
Cenário #4	98,3%	98,3%	95,7%	93,1%
Cenário #5	96,9%	96,9%	95,2%	92,6%
Cenário #6	96,0%	92,9%	92,6%	91,9%
Cenário #7	98,1%	98,1%	93,3%	88,6%
Cenário #8	96,7%	96,7%	93,1%	89,3%
Cenário #9	95,2%	88,8%	90,5%	87,6%

Pelos resultados observados na Tabela 7, pode-se verificar que independente do classificador utilizado e do cenário a taxa de acerto está situada acima de 86%. Portanto, as três características propostas na metodologia e que são extraídas dos sinais de tensão capturados pelos medidores durante a ocorrência do distúrbio conseguem expressar o comportamento do distúrbio de afundamento de tensão no sistema IEEE 13 barras. Na etapa de treinamento, o classificador generaliza esse comportamento, de modo a inferir na região de origem do distúrbio.

Com relação ao AdaBoost que é um *ensemble method* observa-se que tanto utilizando um classificador base do tipo RNA ou um classificador base do tipo árvore de decisão, a taxa de acerto é igual ou superior a acurácia alcançada pelo classificador com RNA ou o classificador com árvore de decisão. Logo, o *ensemble method* aumenta a performance dos outros algoritmos de classificação.

Adicionalmente, os resultados sumarizados na Tabela 7 mostram que a metodologia proposta no artigo que implementa o AdaBoost com Rede Neural Artificial foi a abordagem que apresentou os melhores resultados em cada um dos 9 cenários.

Destaca-se que a aplicação da metodologia proposta no Cenário#9 que é o pior caso e, por consequência, o mais propenso a erro alcançou uma acurácia 6% maior que os outros classificadores utilizados. Desse modo, a metodologia consegue combinar modelos de classificadores neurais fracos para formar um classificador forte para obter resultados satisfatórios mesmo em um cenário com poucos medidores de energia o que diminui o custo do método.

Com o objetivo de investigar o erro da metodologia, o resultado do Cenário#9 é analisado por meio de uma matriz de confusão ilustrada na Tabela 8. Esta matriz tem como objetivo mostrar o número da região estimada em relação aquela região esperada. A diagonal principal representa a quantidade de simulações classificadas de forma correta.

Tabela 8. Matriz de Confusão para Cenário #9

	R1	R2	R3	R4	R5	Total	(%)
R 1	27	6	0	0	0	33	81,8%
R 2	3	167	0	0	3	173	96,5%
R 3	0	0	120	0	0	120	100,0%
R 4	0	0	5	58	0	63	92,1%
R 5	0	0	0	3	28	31	90,3%

Pelos resultados observados na Tabela 8, pode-se verificar que a menor taxa de acerto é encontrada nas simulações onde o distúrbio de afundamento é originado em uma das barras que formam a Região 1, composta pelas barras 645 e 646. Dos 33 casos simulados nessa região o algoritmo proposto apontou que em 6 o distúrbio de afundamento foi originado na Região 2. Estas classificações errôneas estão intimamente relacionadas ao fato de que essas duas zonas estão próximas e localizadas próximas da subestação, onde a rede é robusta, sendo que um distúrbio originado em algum desses pontos é disseminado com característica semelhantes em todo o sistema.

6. Conclusões

Este trabalho apresenta uma metodologia baseada na *ensemble method* do tipo AdaBoost com algoritmo base Rede Neural Artificial modelo PMC para localizar a origem do distúrbio de afundamento de tensão em sistema de distribuição com *smart meters*. A metodologia analisa os sinais de tensão enviados

pelos *smart meters* para a central de controle e processamento durante a ocorrência do evento. As características RMS, Valor de Pico e Fator de Forma são extraídas de cada sinal recebido, e utilizadas como entrada do classificador AdaBoost. De acordo com os resultados obtidos foi possível observar que abordagem proposta consegue estimar de forma eficiente a região que engloba o local de origem do distúrbio em diferentes cenários. Os resultados do classificador AdaBoost com RNA foi comparado com outros classificadores e demonstram a alta capacidade dessa abordagem para ser usada na localização do distúrbio, mesmo em um sistema de distribuição elétrica com poucos medidores.

Referências Bibliográficas

- Baig, M. M. Awais, M. .M. and El-Alfy El-Sayed M. (2017), AdaBoost-based artificial neural network learning, *Neurocomputing*, vol. 248
- Chang, G., Chao, J., (2008). On tracking the source location of voltage sags and utility shunt capacitor switching transients. *IEEE Trans. Power Deliv.* 23, 2124–2131.
- Chang, G.W., Chao, J.P., Chu, S.Y., Chen, C.Y., (2007). A new procedure for tracking the source location of voltage sags, in: *IEEE Power Engineering Society General Meeting, PES*.
- Dugan, R.C., Mc Granaghan, M.F., Santoso, S., Beaty, H.W., (2002). *Electrical Power Systems Quality*, 3rd ed. New York.
- Erol-kantarci, M., Mouftah, H.T., (2015). Energy-Efficient Information and Communication Infrastructures in the Smart Grid : A Survey on Interactions and Open Issues 17, 179–197.
- Faisal, M.F., Mohamed, A., (2009). Identification of sources of voltage sags in the Malaysian distribution networks using SVM based S-transform, in: *TENCON 2009 - 2009 IEEE Region 10 Conference. IEEE*, pp. 1–6.
- Freund, Y. e Schapire, R. E. (1996) “Experiments with a New Boosting Algorithm,” In: L. Saitta, Ed., *Proceedings of the 13th International Conference on Machine Learning, Bari*, 3-6 .
- Kazemi, A., Mohamed, A., Shareef, H., Raihi, H., (2014). Accurate voltage sag-source location technique for power systems using GACp and multivariable regression methods. *Int. J. Electr. Power Energy Syst.* 56, 97–109.
- Li, C., Tayjasanant, T., Xu, W., Liu, X., 2003. Method for voltage-sag-source detection by investigating slope of the system trajectory. *IEE Proc. - Gener. Transm. Distrib.* 150, 367.
- Parsons, A.C., Grady, W.M., Powers, E.J., Soward, J.C., (2000). A direction finder for power quality disturbances based upon disturbance power and energy. *IEEE Trans. Power Deliv.*
- Shareef, H., Mohamed, A., Ibrahim, A., (2013). Identification of voltage sag source location using S and TT transformed disturbance power. *J. Cent. South Univ.* 20, 83–97.