

Avaliação de Técnicas para Detecção de Eventos em Sistemas de Potência

Riani da Boa Morte Silva, Vitor Hugo Ferreira
Programa de Pós-graduação em Engenharia Elétrica e de Telecomunicações (PPGEET)
Universidade Federal Fluminense
Niterói, Brasil
rianibms@id.uff.br, vitor@vm.uff.br

Resumo — Este trabalho tem o objetivo de avaliar técnicas para detecção automática de eventos em sistemas de potência. Três métodos foram avaliados: rede neural com Inferência Bayesiana aplicada no treinamento de perceptrons de múltiplas camadas; Filtro de Kalman e Operador de Energia de Teager. Para validar e comparar os métodos são utilizadas bases de dados geradas sinteticamente para sistemas de transmissão e distribuição de energia elétrica. Os critérios utilizados para avaliar a ferramenta de melhor desempenho consistiram na análise do erro médio entre o instante de tempo detectado e o real instante de início do evento e a avaliação do tempo de simulação computacional. Neste sentido, para o problema de transmissão, a técnica baseada em Filtro de Kalman destacou-se em relação às outras técnicas avaliadas quando da análise do erro de estimação. Por outro lado, no sistema de distribuição, a técnica de detecção automática baseada em Inferência Bayesiana obteve o melhor resultado de precisão. No entanto, constatou-se que o Operador de Energia de Teager foi o método mais rápido em ambos os casos, haja vista a simplicidade dos cálculos envolvidos.

Palavras-chave – Detecção de eventos em sistemas de potência, Rede Neural, Filtro de Kalman, Operador de Energia de Teager, qualidade de energia.

I. INTRODUÇÃO

Manter a qualidade na prestação do serviço de transmissão de energia elétrica tem sido um dos desafios das empresas do setor devido à alta complexidade do sistema. Neste cenário cresce a importância e o interesse por sistemas de suporte à tomada de decisão que contribuam para melhoria do processo de diagnóstico de falhas em linhas de transmissão promovendo o restabelecimento célere da função em questão. No âmbito de média e baixa tensão de responsabilidade das distribuidoras de energia, o aumento no uso de equipamentos computadorizados altamente sensíveis às perturbações do sistema elétrico tem levado a exigências cada vez mais rigorosas na qualidade da energia fornecida ao consumidor. Com intuito de melhorar a qualidade do serviço de fornecimento de energia aos consumidores, cresce o interesse em sistemas de monitoramento em tempo real capazes de identificar sinais de diferentes eventos e tomar as decisões apropriadas para a operação e manutenção do sistema.

A proliferação de sistemas de monitoramento ao longo dos sistemas de potência em conjunto com o aumento da capacidade de processamento dos computadores tem permitido o surgimento de metodologias e sistemas computacionais para automação da atividade de diagnóstico, tendo por objetivo auxiliar a tomada de decisão tanto na operação em tempo real quanto em ambiente de planejamento. Neste contexto, os sistemas de suporte relacionados ao processamento de informações oriundas de eventos podem ser divididos em duas vertentes: processamento de alarmes e análise de eventos. Em linhas gerais, os sistemas para processamento de alarmes realizam a filtragem de todos os alarmes disponíveis para o operador visando fornecer para este uma visão global do estado operativo atual do sistema, incluindo possíveis estados de falha. Já os sistemas de análise de eventos realizam o processamento somente de informações diretamente relacionadas com defeitos (medidas e/ou alarmes), dedicando sua atuação somente para auxílio à tomada de decisão durante a ocorrência de eventos ou para avaliação posterior de ocorrências.

Na literatura associada a sistemas para análise de eventos, a tarefa de diagnóstico de eventos pode ser dividida em três módulos: detecção, classificação e localização. O processo de detecção como um todo envolve duas fases distintas: a identificação dos instantes de tempo em que ocorre a transição - geralmente chamado de fase de disparo, e a segmentação da forma de onda em blocos de tempo desmembrados. A fase de segmentação divide o sinal em estado transitório e quasi-estacionário, o que permite a análise da forma de onda de modo independente.

A fase de detecção é necessária para identificação do instante de tempo de ocorrência do evento causador da falha. Neste sentido, para aplicações on-line a etapa de detecção do evento é realizada pelo sistema de proteção. Em sistemas de diagnóstico off-line desenvolvidos para análise *ex-post* de ocorrências, a etapa de detecção do instante de ocorrência do evento é importante para filtragem das informações necessárias para as análises subsequentes, incluindo a eventual sincronização de dados caso os registros não possuam uma mesma referência temporal [1]. As metodologias propostas para detecção fazem uso das oscilografias fornecidas pelos

registradores de eventos. A análise destes sinais pode ser feita a partir da comparação entre amostras consecutivas no tempo ou entre conjuntos de amostras coletadas antes (pré-falta) e depois (pós-falta) do instante de tempo em avaliação [2]. Estes sistemas podem ser utilizados inclusive para análise da atuação dos sistemas de proteção frente à ocorrência de eventos. A maioria dos sistemas de diagnóstico existentes na literatura e em uso no setor elétrico mundial é desenvolvida para aplicações off-line de análise de ocorrências, com a proteção efetiva do sistema de transmissão ficando a cargo de equipamentos tradicionais (relés e disjuntores).

Este trabalho tem o objetivo de avaliar técnicas automáticas para detecção de eventos em sistemas de potência. Após a análise da literatura técnica [3] foram selecionadas três técnicas automáticas baseadas em análise de dados (do inglês *data-driven*): operador de energia de Teager, filtro de Kalman e inferência bayesiana aplicada ao desenvolvimento de MLPs (perceptrons de múltiplas camadas). Estas técnicas foram selecionadas em função do seu destacado nível de autonomia, i.e., poucos parâmetros a serem selecionados *ad-hoc* pelo usuário, como também pelo desempenho relatado na literatura em termos de capacidade de detecção.

II. METODOLOGIAS UTILIZADAS

A. Operador de Energia de Teager

O operador de energia de Teager (OET) é um operador não linear cuja finalidade inicial era estimar a energia do processo mecânico associado a um sinal composto por uma única frequência. A utilização desse operador para detecção de anormalidades em sinais temporais fundamenta-se no trabalho proposto por Kaiser em 1993 e abordado em [4], uma vez que quando aplicado a sinais não estacionários é possível se obter o realce dos instantes de variações abruptas do sinal.

Para tanto, a energia $\psi[x(n)]$ de um sinal periódico $u(n) \in \mathbb{R}$, $n \in \mathbb{N}$, pode ser estimada pela expressão:

$$\psi[u(n)] = [u(n)]^2 - u(n+1)u(n-1) \quad (1)$$

A partir do cálculo de $\psi[z(n)]$ para cada amostra do sinal, pode-se empregar a metodologia de comparação com um determinado limiar para identificação dos instantes de transição de estados (normal e evento). O processo de determinação do limiar começa com a seleção de um número fixo de oscilografias normais. Cada amostra da oscilografia normal é percorrida sendo calculada para cada ponto a energia $\psi[x(n)]$ utilizando a expressão (1). O maior valor de energia é então definido como o limiar de detecção. Isso indica que o limiar escolhido está no limite superior do ruído existente nas oscilografias normais. Esta definição do limiar indica que um sinal recebido com energia superior ao de uma oscilografia normal será identificado como evento.

Com essa escolha, assume-se um limiar constante para cada nova oscilografia, visto que o cálculo do limiar depende da entrada de oscilografias normais pré-evento.

B. Filtro de Kalman

O filtro de Kalman (FK) é um tipo especial de filtro cuja principal característica é a estimação ótima recursiva dos estados e dos parâmetros do modelo. O filtro de Kalman realiza essa estimação através de um processo de predição-correção no qual são representadas as relações entre as medidas e os estados, bem como as relações entre os estados atuais e anteriores. Para tanto, faz-se necessária a representação do modelo em equações de estado conforme demonstra a sua formulação básica, dada pelas equações de estado e observação, representadas pelas equações (2) e (3) respectivamente [4]:

$$\underline{x}(n) = \underline{A}(n-1)\underline{x}(n-1) + \underline{w}(n) \quad (2)$$

$$\underline{z}(n) = \underline{C}(n)\underline{x}(n) + \underline{v}(n) \quad (3)$$

sendo $\underline{x}(n) \in \mathbb{R}^s$ o vetor com s variáveis de estado;

$\underline{A}(n) \in \mathbb{R}^s \times \mathbb{R}^s$ a matriz responsável pela transição entre dois estados subsequentes;

$\underline{C}(n) \in \mathbb{R}^m \times \mathbb{R}^s$ a matriz de observação que relaciona os estados $\underline{x}(n)$ com as medidas

(observações) $\underline{z}(n) \in \mathbb{R}^m$; $\underline{w}(n) \in \mathbb{R}^s$ o ruído gaussiano do modelo com vetor média nulo e matriz de covariância dada por $\underline{Q} \in \mathbb{R}^s \times \mathbb{R}^s$; e $\underline{v}(n) \in \mathbb{R}^m$ o ruído gaussiano de

medição com vetor média nulo e matriz de covariância dada por $\underline{Q} \in \mathbb{R}^m \times \mathbb{R}^m$.

O cálculo do filtro de Kalman é feito de maneira recursiva, utilizando uma estimativa inicial do vetor de estados e da matriz de covariância $\underline{\hat{P}}(n-1)$. Com esses valores calcula-se o ganho $\underline{K}(n)$ do filtro para o instante n :

$$\underline{K}(n) = \underline{\hat{P}}(n-1)[\underline{C}(n)]^T [\underline{C}(n)]^T \underline{\hat{P}}(n-1)[\underline{C}(n)]^T + \underline{Q}_v]^{-1} \quad (4)$$

sendo a operação $*$ o operador complexo conjugado. Esta formulação baseada em números complexos, aplicada para estimação espectral, é utilizada para detecção de eventos em sistemas de potência [4]. Com o ganho, pode-se atualizar a matriz de covariância e o vetor de estados, utilizando também a própria medida $\underline{z}(n)$ para correção:

$$\underline{\hat{P}}(n) = \underline{\hat{P}}(n-1)(I - \underline{K}(n)\underline{C}(n)) \quad (5)$$

$$\underline{\hat{x}}(n) = \underline{\hat{x}}(n-1) + \underline{K}(n)[\underline{z}(n) - \underline{C}(n)\underline{\hat{x}}(n-1)] \quad (6)$$

sendo o termo $[\underline{z}(n) - \underline{C}(n)\underline{\hat{x}}(n-1)]$ o próprio resíduo de predição. O último estágio do processo é a atualização do vetor de estados e de sua matriz de covariância:

$$\underline{x}(n+1) = \underline{A}(n)\underline{x}(n) \quad (7)$$

$$\underline{\hat{P}}(n+1) = \underline{A}(n)\underline{\hat{P}}(n)[\underline{A}(n)]^T + \underline{Q}_w \quad (8)$$

Esse processo é repetido para todas as amostras do sinal de entrada. A partir dos resíduos estimados a cada amostra, pode-se empregar a metodologia de comparação com o limiar automaticamente calculado através do conceito do limiar universal apresentado a seguir.

A ideia principal do cálculo automático do limiar baseia-se na proposta de [1] e [5]. Basicamente é a aplicação do conceito de um limiar universal, cujo cálculo é fundamentado no erro absoluto do sinal. Sua proposição inicial era voltada para redução de ruído de um sinal no domínio *wavelet*. Porém, sua aplicação pode ser bastante útil para determinação automática de limiares em resíduos de modelos de estimação espectral. Sua fundamentação teórica considera que é possível utilizar esse limiar no cenário em que o ruído possui uma distribuição normal com média nula e variância constante. Sendo assim, a determinação deste limiar é dada por [4]:

$$\text{limiar} = \frac{\sigma}{0,6725} \sqrt{2 \ln(N)} \quad (9)$$

sendo N o comprimento do sinal e σ a mediana do erro absoluto do sinal estimado em relação à observação.

C. Modelos Neurais Autônomos

Em [6] foi desenvolvido um modelo neural autônomo originalmente aplicado para previsão de carga e utilizado neste trabalho para estimação das formas de onda de tensão e corrente visando identificar as variações abruptas relacionadas com ocorrência de eventos. O método desenvolvido é automático, analítico e acoplado tanto para seleção do espaço de entrada quanto para o controle de complexidade, incluindo a seleção do modelo. O método desenvolvido baseia-se na inferência bayesiana no treinamento de perceptrons de múltiplas camadas, do inglês *multi-layered perceptrons* – MLPs.

Definida a estrutura a ser utilizada, ou seja, número de camadas ocultas, número de neurônios por camada e tipo de função de ativação de cada neurônio, dado o conjunto $D = \{X, Y\}$, $X = \{\underline{x}_1, \dots, \underline{x}_N\}$, $Y = \{d_1, \dots, d_N\}$, $\underline{x} \in \mathbb{R}^n$, $\underline{x} = [x_1, \dots, x_n]^T$, $d \in \mathbb{R}$ e $d = F(\underline{x}) + \zeta$, o objetivo do treinamento do modelo, sob o ponto de vista da inferência bayesiana, reside na determinação do vetor de parâmetros $\underline{w} \in \mathbb{R}^M$ que maximize a probabilidade a *posteriori* $p(\underline{w}|Y, X)$, dada por:

$$p(\underline{w}|Y, X) = \frac{p(Y|\underline{w}, X) p(\underline{w}|X)}{p(Y|X)} \quad (10)$$

Para determinação dos valores mais prováveis para os hiperparâmetros, a probabilidade a *posteriori* destes, $p(\alpha, \beta|Y)$, deve ser maximizada. Aplicando a regra de Bayes, é obtida a seguinte expressão para esta probabilidade:

$$p(\alpha, \beta|Y) = \frac{p(Y|\alpha, \beta) p(\alpha|\beta)}{p(Y)} \quad (11)$$

Técnicas baseadas na teoria do caos (teorema de *Takens*) são aplicadas para definição do espaço de entrada inicial por meio de valores atrasados da série temporal a ser modelada (tensão ou corrente). Este conjunto inicial de entradas é utilizado para treinamento dos MLPs utilizando inferência bayesiana em uma técnica conhecida como determinação automática de relevância (do inglês *automatic relevance determination* - ARD). Esta técnica permite ordenar as

entradas de acordo com a sua relevância para a estimação da saída do modelo, permitindo assim inferir de forma analítica as variáveis mais importantes. Visando identificar as variáveis irrelevantes, permitindo assim que as mesmas sejam excluídas do modelo final visando contribuir para o desempenho do modelo, é aplicada uma estratégia para definição automática de limiares de relevância. Para tanto, são inseridas variáveis aleatórias de prova ao conjunto inicial, as quais são geradas artificialmente sem correlação com a saída. Após a estimação do modelo utilizando o ARD e o consequente ordenamento das variáveis relevantes, aquelas consideradas menos relevantes que as variáveis de prova são excluídas do conjunto de entradas. Feita esta seleção, o modelo é novamente treinado considerando somente as entradas relevantes previamente selecionadas, reduzindo a necessidade de intervenção de especialistas para a escolha dos sinais mais relevantes.

Nesta seção foi apresentado de forma sucinta o método baseado em modelos neurais autônomos. Para maiores detalhes sugere-se a consulta do trabalho descrito em [6].

III. BASE DE DADOS UTILIZADAS: TRANSMISSÃO E DISTRIBUIÇÃO

Neste trabalho foram avaliadas técnicas para detecção automática de eventos tanto em linhas de transmissão quanto em sistemas de distribuição. A avaliação foi feita por meio da geração de cenários de eventos por meio de simulações em ATP e MATLAB®. O sistema de detecção foi implementado em MATLAB®. Os critérios utilizados para avaliação dos detectores foram o tempo de simulação do detector para uma oscilografia com monitoramentos distintos e o erro médio associado à estimativa em relação ao valor real do instante de tempo que ocorre o defeito.

Para formulação das oscilografias de entrada no sistema de detecção automática, utilizou-se de formulações matemáticas capazes de representar um sistema de distribuição genérico, as quais foram desenvolvidas em [7] e detalhadas em [3]. Por outro lado, para o sistema de transmissão as oscilografias foram geradas sinteticamente a partir da modelagem realizada no programa ATP®. Foi simulada a linha de transmissão LT Tijuco Preto – Cachoeira Paulista 500 kV – Circuito 2 de propriedade da Cachoeira Paulista Transmissora de Energia (CPTe) e suas vizinhanças. O diagrama completo do sistema de transmissão utilizado no estudo é ilustrado na Figura 1. Esta linha foi considerada visto que está sendo desenvolvido um sistema inteligente para diagnóstico de falhas em linhas de transmissão dedicado à linha em questão [8]. Os eventos (curtos circuitos entre fases, envolvendo a terra, francos ou por meio de resistências) foram representados por meio de chaves posicionadas ao longo da linha em análise.

As variáveis para monitoramento do sistema de transmissão puderam ser escolhidas entre tensão monofásica da fase A, tensões trifásicas, corrente monofásica da fase A, correntes trifásicas e tensões e correntes trifásicas. No entanto, observou-se que o monitoramento de variáveis trifásicas é suficiente para o problema de detecção do evento de forma correta, visto que o monitoramento de variáveis monofásicas atrapalharia o desempenho do detector em se tratando de falta

envolvendo uma ou mais fases não monitoradas. O monitoramento das correntes junto com as tensões se torna mais relevante quando o objetivo é a classificação do defeito.

Como o foco deste trabalho é apenas a detecção do defeito, monitorar as tensões trifásicas ou as correntes trifásicas torna-se suficiente para solução do problema.




Figura 1 - Configuração da rede adotada nos estudos de transitórios eletromagnéticos

Para o problema de distribuição, o monitoramento se restringiu às tensões trifásicas. A restrição ocorreu devido à ausência de dados reais de um sistema de distribuição para simulação em ATP, com os eventos de qualidade de energia (sag, swell, com e sem harmônicos) sendo simulados sinteticamente por meio de expressões matemáticas.

Os critérios utilizados para avaliar a ferramenta de melhor desempenho consistiram na análise do erro entre o instante de tempo detectado e o real e a avaliação do tempo de simulação computacional. Essas duas variáveis se tornam importantes quando da definição da aplicação do detector.

IV. PARAMETRIZAÇÕES DOS DETECTORES

A. Operador de Energia de Teager – OET

O método de detecção baseado no Operador de Energia de Teager se torna uma técnica de fácil implementação, visto que sua formulação matemática apenas depende de amostras atual, anterior e posterior para realizar o cálculo utilizado na detecção de eventos. Sendo assim, não há parâmetros a definir neste modelo.

B. Filtro de Kalman - FK

Neste modelo alguns parâmetros necessitam ser especificados para que seja possível realizar a previsão através do Filtro de Kalman. Pela formulação matemática do Filtro de

Kalman descrito pelas equações (2) e (3), observa-se a necessidade de definição da matriz de transição entre estados, $\underline{A}(n) \in \mathbb{R}^s \times \mathbb{R}^s$, além da matriz de observação, $\underline{C}(n) \in \mathbb{R}^m \times \mathbb{R}^s$, a matriz de covariância do ruído do modelo, $\underline{Q} \in \mathbb{R}^s \times \mathbb{R}^s$, e a matriz de covariância do ruído da medição, $\underline{R} \in \mathbb{R}^m \times \mathbb{R}^m$. Visando destacar o aspecto automático de cada método, adotou-se a ausência de harmônicos nas oscilografias, com cada oscilografia sendo analisada de forma independente. Portanto, o vetor de medidas é composto por um escalar $z(n) \in \mathbb{R}$ e o respectivo ruído branco associado passa a ser representado pela variância Q_w , dada pela variância da oscilografia normal utilizada para treinamento dos detectores. Desse modo a matriz de transição entre estados é dada por:

$$\underline{A} = \begin{bmatrix} \cos(w_1) & -\sin(w_1) \\ \sin(w_1) & \cos(w_1) \end{bmatrix} \quad (1)$$

onde $w_1 = 2\pi f_0 / f_t$, com f_t dado pela frequência de amostragem (nesse trabalho igual a 100 [kHz]) e f_0 a frequência fundamental da rede elétrica (igual a 60 [Hz]). Visto que os estados são determinísticos, $\underline{Q} = \underline{0}$.

Por fim, partindo da premissa que as oscilografias serão normalizadas no intervalo $[-1 \ 1]$ antes da apresentação das mesmas ao detector, a matriz de observação $\underline{C}(n)$ foi definida como um vetor de comprimento 2 assumindo os valores $C = [1 \ 0]$.

C. Rede Neural Autônoma – Bayesiano

Por se tratar de um método autônomo, poucos parâmetros necessitam ser definidos, são eles o número mínimo de neurônios, o nível de significância do teste de hipótese da teoria do caos e o nível de significância do detector. Neste trabalho, definiu-se o número mínimo de neurônios na camada escondida variando entre $m_{\min} = 1$ e $m_{\max} = 25$. Apesar de escolhido de forma heurística, este número máximo foi definido tendo em mente o número de padrões disponíveis para treinamento e a quantidade de parâmetros a serem estimados. Já o nível de confiança do detector foi considerado igual a 99%.

V. RESULTADOS

As ferramentas de detecção de eventos foram desenvolvidas e avaliadas como mostra a Figura 2. Nesta seção serão apresentados os resultados obtidos pelos três detectores criados, tanto para o problema de transmissão, quanto para o problema de distribuição. A análise de desempenho dos métodos de detecção de evento será feita com base no erro médio associado a cada estimativa e o tempo de simulação computacional.




Figura 2 - Fluxograma da ferramenta de detecção desenvolvida

A. Detecção de evento no sistema de transmissão

Nesta etapa os detectores foram simulados variando o tipo de falta aplicado, a localização da falta, a resistência de falta e o instante de aplicação da mesma. O período de amostragem foi igual a 0,01 [s].

A premissa utilizada para medição do tempo de simulação do detector foi a simulação de apenas um evento com monitoramento de tensão monofásica ou tensões trifásicas ou corrente monofásica ou correntes trifásicas ou correntes e tensões trifásicas.

A Tabela 1 mostra os resultados obtidos para simulação dos três detectores quando da ocorrência de diferentes faltas no sistema de transmissão modelado. No geral, o detector que apresentou o menor erro de sua estimativa em relação ao correto instante de aplicação do evento foi o detector baseado

no Filtro de Kalman. Em contrapartida, o detector mais rápido é o que se baseia na metodologia do Operador de Teager, haja vista a simplicidade do cálculo envolvido. O detector baseado em rede neural com inferência Bayesiana obteve resultados medianos em relação à sua acurácia, porém no quesito velocidade de simulação obteve os piores resultados quando comparado aos outros dois métodos. Já o Filtro de Kalman, com relação à velocidade de simulação, obteve resultados medianos.

Tabela 1 - Desempenho dos métodos de detecção de faltas em linha de transmissão

Grandezas	Critério	Detector		
		Bayesiano	FK	OET
Tensão Monofásica	Erro médio (s)	0.01897 ± 0.03304	0.00093 ± 0.00764	0.00106 ± 0.00890
	Tempo médio de simulação (s)	10.69398	1.63618	0.57163
Tensões Trifásicas	Erro médio (s)	0.00211 ± 0.01141	0.00029 ± 0.00018	0.06760 ± 0.00340
	Tempo médio de simulação (s)	24.17046	2.52334	0.28123
Corrente Monofásica	Erro médio (s)	0.00646 ± 0.02365	0.00237 ± 0.01314	0.00651 ± 0.02264
	Tempo médio de simulação (s)	10.75117	0.86492	0.2425
Correntes Trifásicas	Erro médio (s)	0.00161 ± 0.01075	0.00105 ± 0.00721	0.07081 ± 0.00340
	Tempo médio de simulação (s)	31.32785	2.4272	0.28342
Tensões e Correntes Trifásicas	Erro médio (s)	0.00110 ± 0.00839	0.00029 ± 0.00018	0.07081 ± 0.00340
	Tempo médio de simulação (s)	31.32785	4.60018	0.29744

Portanto, para detecção de faltas em linhas de transmissão, o Filtro de Kalman e o Operador de Teager possuem os melhores resultados. O que pode diferenciar a escolha entre os dois métodos está na aplicação. O Operador Energia de Teager para fazer a estimativa da amostra atual, necessita da amostra seguinte. Sendo assim, o detector está sempre defasado de uma amostra, o que dificulta seu emprego em sistemas de detecção on line. Em contrapartida, o detector com Filtro de Kalman pode ser empregado para detecção on line, visto que para fazer a estimativa da amostra atual, necessita apenas da amostra anterior. No entanto, este detector precisa ser melhorado para que o tempo de simulação diminua consideravelmente a ponto de conseguir prever se há ou não falta no sistema num tempo menor ou igual ao período do sistema.

B. Detecção de evento no sistema de distribuição

Nesta etapa os detectores foram simulados variando apenas o tipo de evento aplicado, não houve variação dos parâmetros associados. A premissa utilizada para medição do tempo de simulação do detector foi a simulação de apenas um

evento com monitoramento de tensões trifásicas. Os resultados são apresentados na Tabela 2, com período de amostragem igual a 0,01 [s].

Tabela 2 - Desempenho dos métodos de detecção de eventos de qualidade de energia na distribuição

Detector	Erro médio (s)	Tempo médio de simulação (s)
Bayesiano	0.00026 ± 0.00042	73.03278
Filtro de Kalman	0.00037 ± 0.00062	17.80972
Operador de Teager	0.12875 ± 0.12999	0.09123

Neste contexto, o detector que apresentou o menor erro associado à sua estimação foi o detector baseado em rede neural com inferência Bayesiana. Em contrapartida, o detector mais rápido é o que se baseia na metodologia do Operador de Teager para estimar o instante de tempo. O Filtro de Kalman obteve resultados medianos tanto na sua acurácia, quanto na velocidade.

VI. CONCLUSÕES

É importante destacar um fator crucial quando se trata de ferramenta para detecção automática de evento. Se o intuito é a aplicação on line, então o tempo médio que a ferramenta leva para detectar o instante da falta, é um fator relevante, tendo em vista sua aplicação para tomada de decisão. Por outro lado, quando trata-se de análise de eventos em um sistema de forma off line, como acontece por exemplo no setor de análise de defeitos nas empresas do ramo de sistemas de potência, o tempo para detecção não é o fator crucial e sim a precisão da ferramenta.

Devido à formulação matemática do Operador de Energia de Teager, pode-se concluir que sua utilização se restringe a aplicações off line, visto que para análise do instante t , o detector necessita do valor da variável no instante $t+1$, o que não ocorre nos métodos do Filtro de Kalman e Inferência Bayesiana. Por se tratar de um modelo autoregressivo, o Filtro de Kalman apenas necessita do instante de tempo anterior para prever o atual. Além disso, para seu treinamento, ou seja, para definição de seus parâmetros, basta uma amostra do sinal num intervalo de tempo anterior ao evento. De forma similar, o modelo baseado em inteligência artificial, a rede neural com Inferência Bayesiana, apenas necessita de uma amostra do sinal para que seja capaz de prever qualquer instante à frente. Portanto, os métodos do Filtro de Kalman e de Inferência Bayesiana se destacam quando se trata de previsão on time.

Neste sentido, para o problema de transmissão, a técnica baseada em Filtro de Kalman destacou-se em relação às outras técnicas avaliadas quando da análise da precisão do método. Em contrapartida, o método mais rápido na detecção de evento em sistema de transmissão foi o baseado no Operador de Teager.

Por outro lado, no sistema de distribuição, a técnica de detecção automática baseada em Inferência Bayesiana obteve melhores resultados quando da análise do erro médio de

estimação, ou seja, este método é mais preciso do que os outros. No entanto, o Operador de Energia de Teager permaneceu sendo o mais rápido, haja vista a simplicidade dos cálculos envolvidos.

REFERÊNCIAS

- [1] A. Ukil and R. Zivanovic, "Application of abrupt change detection in Power systems disturbance analysis and relay performance monitoring", IEEE Transactions on Power Delivery, vol. 22, n. 1, pp. 59-66, Jan. 2007.
- [2] S.R. Mohanty, A.K. Pradhan and A. Routray, "A cumulative sum-based fault detector for power system relaying application", IEEE Transactions on Power Delivery, vol. 23, n. 1, pp. 79-86, Jan. 2008.
- [3] R. B. M. Silva, "Avaliação de Técnicas para Detecção de Eventos em Sistemas de Potência", Dissertação de Mestrado, Niterói, Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações, Universidade Federal Fluminense, 2015.
- [4] A. E. Lazzaretti, "Segmentação, classificação e detecção de novas classes de eventos em oscilografias de redes de distribuição de energia elétrica", Tese de Doutorado, Curitiba, Universidade Tecnológica Federal do Paraná, 2015.
- [5] A. Ukil and R. Živanović, "Abrupt change detection in power system fault analysis using adaptive whitening filter and wavelet transform", Electric Power Systems Research, vol. 76, n. 9-10, pp. 815-823, June 2006.
- [6] V.H. Ferreira, "Desenvolvimento de modelos neurais autônomos para previsão de carga elétrica", Tese de Doutorado, Rio de Janeiro, UFRJ/COPPE, 2008.
- [7] T. K. Abdel-Galil, M. Kamel, A. M. Youssef, E. F. El-Saadany, M. M. A. Salama, "Power quality disturbance classification using inductive inference approach", IEEE Transactions on Power Delivery, v. 19, No. 4, Oct 2004.
- [8] V.H. Ferreira, C.H.C. Guimarães, G.G. Sotelo, J.C.S. de Souza, M.Z. Fortes, S.G. Júnior, R. Zanghi, R.B.M. Silva, V.R. de Oliveira, B. Chucó, M. Gonçalves, "Sistema inteligente para diagnóstico de faltas em linhas de transmissão, ETAPA 3: Desenvolvimento da metodologia para análise e diagnóstico de faltas em linhas de transmissão – Modelagem da rede equivalente e estudo dos transitórios de curto-circuito na LT 500 kV T. Preto / C. Paulista C2", Relatório Técnico de Projeto de Pesquisa e Desenvolvimento, Abril/2015.
- [9] F.N. Chowdhury, J.P. Christensen and J.L. Aravena, "Power System Fault Detection and State Estimation Using Kalman Filter with Hypothesis Testing", IEEE Transactions on Power Delivery, vol. 6, n. 3, pp. 1025-1030, Jul 1991.
- [10] S. Cerqueira, C. A. Duque, R. M. Trindade, M. V. Ribeiro, "Sistema Digital de Detecção e Classificação de Eventos de Qualidade de Energia", Revista IEEE América Latina, 2005.
- [11] D.M. Gilbert and I.F. Morrison, "A Statistical Method for the Detection of Power System Faults", International Journal of Electrical Power & Energy Systems, vol. 19, n. 4, pp. 269-275, May 1997.
- [12] M. Kezunovic and I. Rikalo, "Detect and Classify Faults Using Neural Nets", IEEE Computer Applications in Power, vol.9, no.4, pp. 42-47, Oct 1996.
- [13] J. Barros, J.M. Drake, "Realtime Fault Detection and Classification in Power Systems Using Microprocessors", IEE Proceedings – Generation, Transmission and Distribution, vol. 141, n. 4, pp. 315-322, Jul 1994.