



MONITORAMENTO EM TEMPO REAL DE TRANSFORMADORES DE DISTRIBUIÇÃO

Leandro José Duarte*¹ e Alan Petrônio Pinheiro¹.

¹FEELT – Universidade Federal de Uberlândia

Resumo - Este trabalho apresenta um algoritmo de detecção de anomalias para monitoramento contínuo em tempo real da saúde de transformadores e previsão de possíveis falhas. O núcleo do sistema é um modelo genérico adaptativo que não depende dos parâmetros medidos específicos que determinam a saúde de um determinado transformador. Duas abordagens diferentes das atuais baseadas em limiares são introduzidas para prever mudanças abruptas e graduais. Este algoritmo trabalha como um agente de software autônomo que atualiza continuamente seu modelo de decisão implementando um algoritmo de aprendizagem não-supervisionado. A da validação do algoritmo proposto se dá por meio de experimentos simulados.

Palavras-Chave - Manutenção baseada na condição, Modelo adaptativo, Smart Grids, Transformadores de distribuição.

REAL-TIME MONITORING OF DISTRIBUTION TRANSFORMERS

Abstract - This paper presents an anomaly detection algorithm for continuous real-time monitoring of the health of transformers and forecasting possible failures. The core of the system is a generic adaptive model that does not depend on the measured parameters, which determine the health of a given transformer. Two approaches other than the current ones available at the thresholds are introduced for abrupt and gradual changes. This algorithm works as an autonomous software agent that updates its decision model by implementing an unsupervised learning algorithm. The validation of the proposed algorithm takes place through simulated experiments.

Keywords – Adaptive model, Condition-based maintenance, Distribution transformers, Smart Grids.

I. INTRODUÇÃO

Atualmente a detecção de falhas em transformadores baseia-se na identificação de anormalidades entre os valores atuais e nominais de certas características do transformador, como temperatura, tensão e corrente. Este pressuposto necessita de um conhecimento detalhado das propriedades estruturais e dinâmicas do transformador e seus modos de operação e de falha. Geralmente os transformadores não têm a capacidade de autodiagnóstico ou de detecção de falhas. Além disso, as características nominais, juntamente com os modos de operação e falha mudam ao longo do tempo devido ao desgaste natural e o envelhecimento. Diante disso são necessárias abordagens alternativas que possam diminuir a necessidade de análise dos modos específicos de operação e falha do transformador aplicando métodos e algoritmos genéricos não supervisionados.

No aprendizado em tempo real é possível que métodos de detecção de anomalias onde a principal suposição é que a mudança de comportamento do transformador devido a falhas leva a erros quantificáveis entre as características previstas e reais do transformador. Alguns dos principais desafios para o método de detecção de anomalias incluem: a capacidade de executar como um agente autônomo, uso de algoritmos de aprendizagem que não requerem intervenção e supervisão humana, configuração simplificada com número mínimo de parâmetros a serem estimados com antecedência, minimização de possíveis alarmes falsos.

Este trabalho irá apresentar um algoritmo de detecção de anomalias para monitoramento contínuo em tempo real da saúde de transformadores e previsão de possíveis falhas. O cerne do sistema é um modelo genérico e adaptativo que não depende de parâmetros ou limiares específicos. O algoritmo é alimentado com uma combinação de características proveniente de sensores de tensão, corrente e temperatura instalado no transformador. Este conjunto de variáveis medidas, chamado de conjunto de características, é normalizado e mapeado em tempo real para o espaço das componentes principais. Os dois primeiros componentes principais do vetor de características são continuamente monitorados e visualizados. É aplicado um algoritmo de clusterização não supervisionado para identificar padrões estáveis que constituem diferentes modos operacionais do transformador. Duas estratégias alternativas a aquelas

*leandro.duarte@ufu.br

convencionais baseadas em limiares fixos são introduzidas para prever mudanças abruptas e gradualmente desenvolvidas no comportamento de transformadores.

O restante desse trabalho é organizado da seguinte forma. A seção II trata de um Modelo de Detecção de Anomalias Adaptativo que é usado para explicar dinamicamente os dados monitorados em uma estrutura de tomada de decisão que reflete a natureza dos dados de saúde do transformador. O algoritmo real é apresentado na Seção III. A Seção IV discute duas aplicações do algoritmo para previsão de falhas em um experimento simulado.

II. DETECTOR DE ANOMALIAS ADAPTATIVO

As capacidades de diagnóstico dos sistemas convencionais de manutenção preditiva baseiam-se na aplicação de diferentes tipos de limiares, modelos e regras para quantificar a relação entre os valores atuais e seus limiares. Durante o funcionamento do transformador, os limiares permanecem geralmente inalterados, exceto se um especialista intervir para forçar sua alteração, embora as características do transformador mudem gradualmente podendo resultar em falsos alarmes. A situação é ainda mais complicada já que o transformador tem modos de operação diferentes (subcarregado, nominal, sobrecarregado etc.) exigindo diferentes conjuntos de limiares. O modelo adaptativo proposto tenta eliminar a necessidade de identificação manual dos valores limiares e sua atualização durante o processo de monitoramento, isso é possível graças a uma abordagem que utiliza uma técnica de aprendizagem não supervisionada para aprender continuamente os parâmetros necessários para identificar qualquer mudança significativa no padrão de características monitoradas.

A entrada para o Detector de Anomalias Adaptativo é um vetor de características que descreve o estado do transformador usando as leituras dos sensores. O espaço de características é decomposto em várias regiões que representam assinaturas do transformador em diferentes condições de funcionamento. Essas regiões são essencialmente um conjunto de clusters MMG (Modelos de Mistura Gaussiana), esse trabalho chama esses clusters de Modos de Operação MO, estes são atualizados dinamicamente à medida que novos vetores de características são aplicados.

Os MOs estão associados a assinaturas do transformador suficientemente distintas, mas recorrentes, por exemplo, modos de operação sobrecarregado ou subcarregado. É esperado em condições normais que transformador possa alternar entre os modos de operação, mas que permaneça pelo menos por um curto período de tempo dentro de um desses modos. Durante o tempo que o transformador permanece dentro de um MO tem-se a expectativa de ver padrões semelhantes que podem ser ligeiramente diferentes, mas que permanecem dentro da mesma fronteira de condições de operação. Este é o pressuposto central para modelar esses conjuntos de vetores de características como clusters. A falta de limites bem definidos dos MO e as transições graduais entre eles é a razão para considerar aglomerados adaptativos.

Vemos a adaptação dos MOs como um processo que consiste em duas fases: criação de novos MOs e atualização contínua dos MOs existentes. A fase de criação representa uma mudança dramática no espaço de características, a causa

dessa mudança pode ser um novo modo de operação ou uma falha. A fase de atualização corresponde às mudanças graduais nas características da máquina.

As falhas são vistas como potenciais novos modos de operação porque assim como eles demonstram padrões que não foram observados anteriormente. A principal diferença entre eles e os modos de operação reais são dois: as falhas incluem menos vetores de características do que os modos de operação normais e elas têm vida útil limitada. O número de vetores de características atribuídos a um MO e sua idade, ou seja, o período de tempo desde a criação são os fatores para quantificar a saúde de um MO. Portanto, a criação extensiva de novos clusters MO com menos vetores pertencentes a eles pode ser usada para diagnosticar uma falha em oposição a um novo modo operacional. Esse tipo de falha é chamado de falha drástica.

Este trabalho apresenta um Detector de Anomalias Adaptativo que é implementado em tempo real como um agente inteligente autônomo que avalia automaticamente cada novo vetor de características X^B para avaliar a saúde do transformador. A natureza não supervisionada do algoritmo de aprendizagem é o que torna possível ele operar de forma autônoma, sem qualquer suporte manual ou calibração.

III. ALGORITMO ADAPTATIVO DE DIAGNÓSTICO

São necessárias quatro fases para a execução do Algoritmo Adaptativo de Diagnóstico: Extração de características, Inicialização, Monitoramento e Prognóstico.

A. Extração de características

A fase de Extração de características é essencialmente uma transformação do conjunto sinais coletado diretamente dos sensores instalados no transformador em um conjunto de características X^B que descrevem o sinal sob certas suposições.

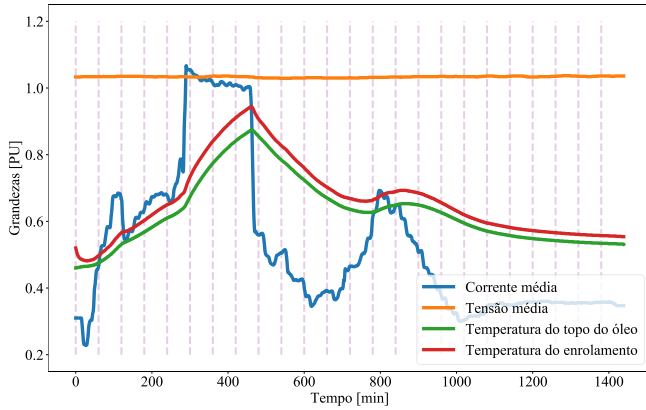
Nesse trabalho é usando sinais de tensão, corrente, temperatura do topo do óleo e temperatura do ponto mais quente do enrolamento. Esses sinais são amostrados a cada minuto e armazenados em uma série temporal, um exemplo desses sinais é mostrado na Figura 1.

Primeiro todos os sinais são divididos em conjuntos de tamanho predefinido em minutos, por exemplos conjuntos de 60 minutos totalizando 60 pontos, cada conjunto de pontos passam pelo processo de extração de características onde é coletado:

- Autocorrelação
- Centroide
- Número de picos de máximo
- Número de picos de mínimo
- Soma das diferenças absolutas
- Energia total
- Inclinação
- Área sob a curva
- Entropia
- Distância entre o máximo e o mínimo

As características dos pontos que formam o conjunto de tensão, corrente e temperaturas são concatenados formando a amostra X^B .

Figura 1: Curva de magnetização em função do campo aplicado.



B. Inicialização

Na fase de Inicialização, o algoritmo coleta novos dados até que um número predefinido de vetores de características, N , necessário para a inicialização seja alcançado. O limite inferior para N é estimado a partir do número mínimo de parâmetros independentes da matriz de covariância amostral

$$N_{min} = \frac{K(K+1)}{2} \quad (1)$$

onde K é a dimensão do vetor de características. Quando pelo menos $n = N_{min}$ vetores são acumulados o pré-processamento dos vetores de características bruto é realizado. O pré-processamento inclui normalização e transformação de dados para o espaço dos dois primeiros componentes principais.

1) Pré-processamento

Quando $n \geq N_{min}$ vetores de características m -dimensionais X^B são acumulados é feito a normalização para garantir que todas as características estejam dentro da mesma magnitude em suas variações independentemente de seus significados físicos:

$$X = \frac{(X^B - \overline{X^B})}{\sqrt{\text{diag}(S^B)}} \quad (2)$$

onde $\overline{X^B}$ é a média e S^B é a matriz de covariância dos n vetores de características brutos X^B . Na etapa seguinte, os vetores de características são transformados para o espaço dos dois primeiros componentes principais, aplicamos a Transformação das Componentes Principais para extrair os dois primeiros componentes principais dominantes dos vetores de características normalizados. Ao realizar a Decomposição em Valores Singulares da matriz de covariância S dos vetores de características normalizados X :

$$S = V \Lambda V^T \quad (3)$$

obtemos o Vetor de Características Transformado:

$$x = XV^{(2)} \quad (4)$$

O Vetor de Características Transformado x é um vetor linha que contém os dois primeiros componentes principais do vetor de características. A matriz de transformação $V^{(2)}$ é formada pelas duas primeiras colunas da matriz quadrada V de acordo com a Decomposição em Valores Singulares da matriz de covariância S .

Ao introduzir a Transformação das Componentes Principais é deseja-se eliminar as características redundantes, ou seja, correlacionados e permitir uma visualização no plano cartesiano. Com menos características diminui os problemas de proximidade conhecidos ao usar métricas de distância euclidianas em espaço dimensional elevado [1].

2) Inicialização dos modos operacionais

Quando os n vetores de características são armazenados não se sabe o número de MOs que eles abrangem, portanto, este processo estima o número desconhecido MOs existentes e inicializa cada um deles. Aplicamos o algoritmo de clusterização de Maximização de Expectativas Gananciosas MEG [2] para identificar os clusters correspondentes a diferentes modos operacionais. O algoritmo de clusterização MEG é baseado na estimativa incremental de densidade de probabilidade de misturas de várias Funções Densidade de Probabilidade, nesse caso particular, de Funções Densidade de Probabilidade Gaussianas e usa uma combinação de pesquisa global e local cada vez que um novo componente randomizado é inserido na mistura. O algoritmo MEG é aplicado nos n Vetores de Características Transformados x que são obtidos na Seção III.B.1.

Como resultado da clusterização MEG tem-se o número de MOs iniciais, os centros dos MOs μ_k e as matrizes de covariância s_k . Mais dois parâmetros são inicializados para cada MO: δ_k é o número de Vetores de Características Transformados x associado ao k -ésimo MO e ξ_k é um parâmetro indicando o tempo(número da amostragem) que o k -ésimo cluster foi criado. Esses dois parâmetros são posteriormente utilizados para calcular um valor agregado Ψ_k que caracteriza a saúde do k -ésimo MO.

C. Monitoramento

Depois que os OMs iniciais são criados começa-se a monitorar novos vetores de características onde todos os parâmetros são recursivamente atualizados usando uma versão modificado do algoritmo Welford [3] e a avaliação contínua de saúde e previsão de falhas é realizada.

1) Pré-processamento

Toda vez que um novo vetor de características bruto X^B é coletado atualiza-se recursivamente a média $\overline{X^B}$ e a covariância S^B como mostrado pelas Equações 5 e 6:

$$\overline{X^B} = \overline{X^B} + \frac{1}{\delta} (X^B - \overline{X^B}) \quad (5)$$

$$S^B = S^B + \frac{1}{\delta} \left[(X^B - \overline{X^B})^T (X^B - \overline{X^B}) - S^B \right] \quad (6)$$

onde a taxa de aprendizagem δ (número da amostragem atual, que representa o número total de vetores de características) controla o equilíbrio entre os vetores de características anteriores e atuais. Após a atualização da média $\overline{X^B}$ e do desvio padrão S^B dos dados brutos o novo vetor de característica bruto pode ser normalizado usando a Equação 2. A nova matriz de covariância S dos vetores de características normalizados é atualizada da seguinte forma:

$$S = S + \frac{1}{\delta} (X^T X - S) \quad (7)$$

Com isso é possível por meio da Decomposição em Valores Singulares, Equação 3, determinar a matriz de transformação $V^{(2)}$. O vetor de característica normalizado x é mapeado para o espaço das duas primeiras componentes principais por meio da Equação 4.

2) Atualizando os MOs

Supondo que m MOs foram identificados na fase de Inicialização, aplica-se uma versão modificada da regra k-NN (k-nearest neighbors) [4] para atualizar os MOs. Sempre que um Vetor de Características Transformado x é recebido verifica-se a semelhança deste com cada um dos MOs existentes avaliando as distâncias de Mahalanobis:

$$d_j = \sqrt{(x - \mu_k) s_j^{-1} (x - \mu_k)^T} \quad (8)$$

A menor distância determina o índice j do MO mais próximo, ou seja:

$$j = \operatorname{argmin}_j(d), \quad j = [1, m - 1] \quad (9)$$

Para que um Vetor de Características Transformado x pertença ao j -ésimo MO a Equação 10 deve ser satisfeita.

$$d_j < \chi_{2,\beta}^2 \quad (10)$$

onde $\chi_{2,\beta}^2$ é o $(1-\beta)$ -ésimo valor da distribuição qui-quadrado com 2 graus de liberdade, e β é a probabilidade de um alarme falso [5], por exemplo, $\chi_{2,0,0027}^2 = 11,8290$ corresponde à conhecida regra de limite de $\pm 3\sigma$. O $\chi_{2,\beta}^2$ define probabilisticamente as fronteiras dos MOs.

Se a condição descrita pela Equação 10 estiver satisfeita, o Vetor de Características Transformado x é atribuído ao j -ésimo MO que tem seu centro μ_j , covariância s_j , idade ξ_j , e número total de vetores de características δ_k :

$$\delta_j = \delta_j + 1 \quad (11)$$

$$\mu_j = \mu_j + \frac{1}{\delta_j} (x - \mu_j) \quad (12)$$

$$s_j = s_j + \frac{1}{\delta_j} \left[(x - \mu_j)^T (x - \mu_j) - s_j \right] \quad (13)$$

$$\xi_j = \xi_j \quad (14)$$

Caso contrário, um novo MO é criado:

$$m = m + 1 \quad (15)$$

$$\delta_m = 1 \quad (16)$$

$$\mu_m = x \quad (17)$$

$$s_m = s_j \quad (18)$$

$$\xi_m = \delta \quad (19)$$

onde δ é o número da amostragem atual que define o tempo em que o m -ésimo foi criado.

O novo centro do MO é inicializado com o Vetores de Características Transformados x , a matriz inicial de covariância é inicializada com a covariância do j -ésimo MO.

3) Saúde dos MOs

O parâmetro δ_i conta o número de Vetores de Características Transformados que se enquadram no limite $\chi_{2,\beta}^2$ do i -ésimo MO e parâmetro ξ_i conta a idade (qual o número da amostragem que o MO foi criado) do i -ésimo MO. Seus valores normalizados

$$\bar{\delta}_i = \frac{\delta_i}{\delta}; \quad \bar{\xi}_i = \frac{\min_i(\xi_i)}{\xi_i}; \quad (20)$$

definem o fator de saúde do i -ésimo MO:

$$\Psi_i = \bar{\delta}_i \bar{\xi}_i, \quad i = [1, m] \quad (21)$$

Quanto maior o fator de saúde, maior a chance de que esse MO caracterize um estado saudável do transformador.

D. Prognóstico

1) Falhas graduais no transformador

As falhas graduais no transformador geralmente estão associadas a pequenas mudanças no desempenho do equipamento e são devidas a desgastes naturais. As falhas graduais podem ser vistas e analisadas nas características extraídas do transformador. As falhas graduais podem ser usadas como aviso precoce para falhas mais graves.

Seja x o Vetor de Características Transformado pertencente ao j -ésimo MO. O fator de saúde Ψ_j define uma possível falha gradual, se o j -ésimo MO é caracterizado por um grande valor de saúde Ψ_j então não há indicação de falha gradual, no entanto se, a transição para um MO com um baixo valor de saúde Ψ_j aponta para uma potencial falha gradual.

2) Falhas drásticas no transformador

As falhas drásticas devem-se a mudanças bruscas na dinâmica do transformador, uma vez que vetores de características repetitivos estão associados a um MO e conseqüentemente a um alto valor de Ψ , as falhas drásticas estão ligadas à criação de MOs mais novos contendo um conjunto muito limitado de vetores de características e, portanto, um pequeno valor de saúde.

A criação intensiva de novos MOs com poucos Vetores de Características Transformados aponta que a dinâmica do transformador mudou drasticamente, esta situação indica uma falha drástica. A mudança drástica do número total de MOs é usada para prever possíveis falhas desse tipo. Dado o número total atual de MOs como n_{MO} . A média μ_{MO} e a variância σ_{MO} são atualizadas usando novamente o algoritmo Welford modificado

$$\mu_{MO} = \mu_{MO} + \frac{1}{\alpha} (n_{MO} - \mu_{MO}) \quad (22)$$

$$\sigma_{MO} = \sigma_{MO} + \frac{1}{\alpha} [(n_{MO} - \mu_{MO})^2 - \sigma_{MO}] \quad (23)$$

onde α é a quantidade atual de vezes que o número de MOs foi alterado. O valor inicial de μ_{MO} é o número de MOs identificados na fase de inicialização e o valor inicial de σ_{MO} é zero.

Uma falha drástica é identificada se existe uma condição fora de controle:

$$\frac{(n_{MO} - \mu_{MO})^2}{\sigma_{MO}} < \chi_{1,\beta}^2 \quad (24)$$

onde $\chi_{1,\beta}^2$ é o valor $(1 - \beta)$ da distribuição qui-quadrado com 1 grau de liberdade, e β é a probabilidade de um alarme falso, um exemplo é $\chi_{1,0,0027}^2 = 9$ que corresponde à conhecida regra $\pm 3\sigma$ para escalares.

IV. APLICAÇÃO EM UM AMBIENTE SIMULADO

O algoritmo proposto é testado com uma serie de dados simulados. A natureza sazonal diária dos transformadores permite que um conjunto saudável de leituras diárias seja extrapolada para ser o modo de operação durante um longo período. O cenário da Figura 2 é simulado durante 100 dias e posteriormente o cenário da Figura 3 passa a caracterizar o transformador, a cada 60 minutos os dados passam pela extração de características que gera 40 características que representam os sinais de tensão, corrente e as temperaturas durante os 60 minutos.

Durante 40 dias o sistema realiza a inicialização armazenado as amostras X^B para calcular \bar{X}^B e S^B . Com a matriz de covariância S gerada com os vetores de características X^B normalizados com \bar{X}^B e S^B é calculado a matriz de transformação $V^{(2)}$ para o espaço das duas componentes principais. Com o algoritmo Maximização de Expectativas Gananciosas MMG é inicializado os modos de operação MOs, como pode ser visto na Figura 2 apenas um MO é inicializado.

Após a fase de inicialização é feito o monitoramento e prognóstico em tempo real. A partir do dia 100 surge um novo MO. É interessante notar que que fator de saúde dos MOs são 0,921 e 0,14, mas o alarme da Equação 24 não é acionado.

Para gerar uma falha drástica é imposto que o transformador opere com cenário como os mostrados na Figura 4 que criam MOs com poucos Vetores de Características Transformados x , e então o alarme da Equação 24 é acionado e pode se concluir que o transformador está operando com uma falha.

Figura 2: Único MO criado durante o processo de inicialização




Figura 3: Novo MO com pequeno fator de saúde criado durante a fase de monitoramento, indicação de possível falha gradual.





Figura 4: Criação de muitos MOs com pequenos fatores de saúde, transformador com falha drástica.



V. CONCLUSÕES

Foi apresentado um algoritmo que opera em tempo real atuando como um agente inteligente autônomo que avalia automaticamente os sinais gerados e avalia a condição do transformador atualizado seus próprios parâmetros e estrutura. O algoritmo foi testado com dados e situações simuladas onde mostrou competência na previsão e identificação precoce de falhas graduais e drásticas.

AGRADECIMENTOS

Este trabalho foi financiado pela Companhia Energética de Brasília (CEB) por meio do projeto de P&D ANEEL nº 05160-1805/2018. Além da CEB, os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

- [1] C. Aggarwal, A. Hinneburg and D. Keim, "On the Surprising Behavior of Distance Metrics in High Dimensional Space", Database Theory — ICDT 2001, pp. 420-434, 2001
- [2] N. Vlassis and A. Likas, "A Greedy EM Algorithm for Gaussian Mixture Learning", Neural Processing Letters, vol. 15, no. 1, pp. 77-87, 2002.
- [3] B. Welford, "Note on a Method for Calculating Corrected Sums of Squares and Products", Technometrics, vol. 4, no. 3, pp. 419-420, 1962.
- [4] B. Everitt, Cluster Analysis, 5th ed. Hoboken: Wiley, 2011.
- [5] D. Montgomery and G. Runger, Estatística aplicada e probabilidade para engenheiros, 5th ed. Rio de Janeiro: Livros Técnicos e Científicos, 2003.