

Modelagem Térmica de Transformadores de Potência Baseada em um Sistema Fuzzy Evolutivo *Set-Membership* Gaussiano Multivariado ^{*}

Marcos V. G. da Rocha ^{*} Kaike Sa T. R. Alves ^{**}
Michel B. Hell ^{***} Fernando L. C. Oliveira ^{****}
Eduardo P. de Aguiar ^{*,**}

^{*} Programa de Pós-Graduação em Engenharia Elétrica, Universidade
Federal de Juiz de Fora, Juiz de Fora, MG (e-mail:
marcos.rocha2019@engenharia.ufjf.br,
eduardo.aguiar@engenharia.ufjf.br)

^{**} Programa de Pós-Graduação em Modelagem Computacional,
Universidade Federal de Juiz de Fora, Juiz de Fora, MG (e-mail:
kaike.alves@engenharia.ufjf.br)

^{***} Departamento de Engenharia Elétrica, Universidade Federal de Juiz
de Fora, Juiz de Fora, MG (e-mail: michel.hell@ufjf.edu.br)

^{****} Departamento de Engenharia Industrial, Pontifícia Universidade
Católica do Rio de Janeiro, Rio de Janeiro, RJ (e-mail:
cyrino@puc-rio.br)

Abstract: This work presents a new evolving fuzzy system based on the concept of Set-Membership filtering and in the Multivariable Gaussian clustering for the thermal modeling of power transformers. This new system, called Set-Membership evolving Multivariable Gaussian, works by adjusting the learning rate in the evolving fuzzy modeling system, thus limiting the error during the learning process, which reduces the computational complexity of the model. In order to prove the effectiveness of the proposed model, experimental tests were performed with data obtained from a actual transformer for different load conditions. Comparisons with alternative evolving and non-evolving approaches suggested in the literature show that the proposed model reach better performance and presents a competitive number of rules, suggesting that the model is flexible and efficient approach in the solution of proposed problem.

Resumo: Neste trabalho é apresentado um novo sistema fuzzy evolutivo baseado no conceito de filtragem *Set-Membership* e no agrupamento Gaussiano Multivariado para a modelagem térmica de transformadores de potência. Este novo sistema, denominado *Set-Membership* evolutivo Gaussiano Multivariado, atua ajustando a taxa de aprendizagem no sistema de modelagem fuzzy evolutivo, limitando assim o erro durante o processo de aprendizagem, o que reduz a complexidade computacional do modelo. A fim de comprovar a eficácia do modelo proposto testes experimentais foram realizados com dados obtidos de um transformador real para diversas condições de carregamento. Comparações com abordagens alternativas, evolutivas e não evolutivas, sugeridas na literatura mostraram que o modelo proposto obteve melhor desempenho e apresenta um número competitivo de regras, sugerindo ser uma abordagem flexível e eficiente na solução do problema proposto.

Keywords: Set-Membership Filtering; Multivariable Gaussian Evolving Clustering; Evolving Fuzzy Systems; Power Transformers; Thermal Modeling.

Palavras-chaves: Filtragem *Set-Membership*; Agrupamento Gaussiano Multivariado Evolutivo; Sistema Fuzzy Evolutivo; Transformador de Potência; Modelagem Térmica.

1. INTRODUÇÃO

O transformador de potência é um dos principais equipamentos no sistema de distribuição de energia elétrica e também um dos mais caros, exigindo apurada gestão de manutenção. O transformador tem a função de aumentar a tensão antes de ser transmitida, com vistas à redução do desperdício de energia ao percorrer longas distâncias, além de reduzir esta tensão a fim de fornecer energia ao consumidor final de forma segura (Alves et al., 2020).

Um fator que requer especial atenção durante a operação do transformador é sua temperatura de operação, em particular a chamada temperatura de ponto quente (do inglês *hot-spot temperature*), que é a temperatura mais alta nos enrolamentos de alta e de baixa tensão. Este fator impacta diretamente na vida útil do isolamento que, por sua vez, pode determinar o fim da vida útil do equipamento. Desta forma o constante monitoramento da temperatura de ponto quente representa um importante ramo de estudo no planejamento e operação de sistemas elétricos de potência (Mikha-Beyranvand et al., 2019).

De fato, um conhecimento mais preciso acerca da temperatura de ponto quente pode ser utilizado para aumentar a capacidade operativa do transformador sem afetar sua vida útil residual, o que tende a reduzir o custo de operação das empresas de energia, além de aumentar a confiabilidade do sistema, melhorando assim a competitividade destas empresas no mercado.

Atualmente um dos modelos mais aceitos para estimar a temperatura de ponto quente em transformadores de potência é o determinístico baseado na norma *IEEE Standard C57.91-2011* (IEEE, 2012). Essa abordagem possui uma série de simplificações, onde fatores de segurança conservadores são utilizados na computação, o que faz com que a máxima transferência de potência calculada possa ser 20-30% menor que a capacidade nominal do equipamento (Hell et al., 2008). Desse modo, técnicas de modelagem mais precisas surgem como uma importante alternativa a fim de otimizar o uso e aumentar o tempo de vida dos transformadores.

Nos últimos anos diversos estudos tem sido orientados no sentido de desenvolver modelos térmicos mais precisos e com menor custo computacional para transformares de potência. Em particular, modelos baseados em Redes Neurais Artificiais (Galdi et al., 2000), Sistemas Fuzzy (Ippolito, 2004) e suas hibridizações (Hell et al., 2007, 2008) tem sido amplamente aplicados ao problema proposto devido principalmente à sua capacidade de aprender relacionamentos não lineares complexos e de tratar naturalmente dados imprecisos.

Entretanto, apesar dos bons resultados obtidos, esses modelos não possuem uma importante característica que se

* Os autores agradecem o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (processo 433389/2018-4), Fundação de Amparo à Pesquisa do Estado de Minas Gerais - FAPEMIG (APQ-02922-18) e Universidade Federal de Juiz de Fora - UFJF, pelo suporte financeiro.

deseja em aplicações no mundo real: não são adaptativos. Espera-se que o comportamento do transformador a ser modelado mude devido a variações nas entradas, mudanças estruturais, ações de manutenção, envelhecimento natural, dentre outros fatores. Assim, um modelo pode ser invalidado após um período de tempo se os parâmetros ou a estrutura deste modelo não se adaptarem para lidar com essas alterações (Souza et al., 2012).

Assim, motivados pela necessidade de sistemas adaptáveis, os sistemas inteligentes evolutivos (P. Angelov, 2010) vêm recebendo grande atenção nos últimos anos, sendo largamente aplicados a problemas de modelagem, controle, previsão, classificação e processamento de dados em ambientes dinâmicos e não estacionários (Vieira et al., 2018). Em particular, dois modelos evolutivos, chamados *evolving Multivariable Gaussian* (eMG) (Lemos et al., 2011) e *Enhanced Set-Membership evolving Participatory Learning with Kernel Recursive Least Squares* (ESM-ePL-KRLS) (Alves et al., 2020) foram recentemente aplicados à modelagem térmica de transformadores de potência, obtendo resultados que superaram seus concorrentes na literatura, surgindo como alternativas promissoras no tratamento do problema proposto.

Este trabalho propõe a aplicação do conceito de filtragem *Set-Membership* (SM) (Clarke and de Lamare, 2011; Aguiar et al., 2017) ao modelo evolutivo Gaussiano Multivariado (eMG) a fim criar um novo sistema para modelagem térmica de transformadores de potência. Este novo modelo, denominado *Set-Membership* evolutivo Gaussiano Multivariado (SM-eMG), tem como principal característica a limitação do aumento do erro durante o processo de aprendizagem, o que reduz a complexidade computacional do modelo, levando a um modelo mais preciso e que apresenta menor custo computacional em relação aos propostos na literatura.

O restante deste artigo está estruturado da seguinte forma: A Seção 2 resume o modelo determinístico, que é o modelo atual usado para prever a temperatura de ponto quente. A Seção 3 introduz o modelo SM-eMG proposto neste trabalho. A Seção 4 apresenta e discute os resultados experimentais obtidos pelo modelo proposto. E por fim, a Seção 5 apresenta as conclusões do trabalho.

2. MODELAGEM TÉRMICA DE TRANSFORMADORES DE POTÊNCIA

O modelo determinístico proposto na *IEEE Standard C57.91-2011* (IEEE, 2012) é um modelo clássico utilizado na estimação da temperatura do ponto quente de um transformador de potência. Este modelo é composto por uma série de equações diferenciais cujos cálculos requerem o uso dos conceitos de curvas de carga e condições de operação.

Conforme detalhado em (IEEE, 2012) a estimação da temperatura de ponto quente usando o modelo determinístico é feita conforme o procedimento resumido a seguir.

Primeiramente, a elevação máxima da temperatura no topo do óleo ($\Delta\Theta_{TO,U}$) é calculada através seguinte equação:

$$\Delta\Theta_{TO,U} = \Delta\Theta_{TO,R} \left[\frac{K^2 R + 1}{R + 1} \right]^q \quad (1)$$

em que $\Delta\Theta_{TO,R}$ é a elevação nominal da temperatura do topo de óleo acima da temperatura ambiente, K é a corrente de carga, R é a razão entre perda de carga em relação a carga nominal e a carga não perdida, para uma determinada posição de *tap* e q é uma constante obtida empiricamente e que depende do método de refrigeração do equipamento.

Usando a Equação (1) e a temperatura ambiente (Θ_A), o incremento na temperatura do topo de óleo (Θ_{TO}) é encontrado pela equação diferencial expressa a seguir:

$$\tau_{TO} \frac{d\Theta_{TO}}{dt} = [\Delta\Theta_{TO,U} + \Theta_A] - \Theta_{TO} \quad (2)$$

em que τ_{TO} é a constante de tempo da temperatura do topo de óleo.

Então a elevação máxima da temperatura do ponto quente ($\Delta\Theta_{H,U}$) é computada como segue:

$$\Delta\Theta_{H,U} = \Delta\Theta_{H,R} K^{2m} \quad (3)$$

em que $\Delta\Theta_{H,R}$ é a elevação nominal da temperatura de ponto quente acima da temperatura do topo de óleo e m é uma constante obtida empiricamente e que depende do método de refrigeração do equipamento.

A elevação da temperatura do ponto quente acima da temperatura do topo de óleo ($\Delta\Theta_H$) é calculada usando $\Delta\Theta_{H,U}$ obtido da Equação (3), de acordo com a seguinte equação diferencial:

$$\tau_H \frac{d\Delta\Theta_H}{dt} = \Delta\Theta_{H,U} - \Delta\Theta_H \quad (4)$$

em que τ_H é a constante de tempo da temperatura do ponto quente e $\Delta\Theta_H$ é a elevação da temperatura do ponto quente acima da temperatura do topo de óleo.

E por fim, a temperatura do ponto quente é calculada em função de Θ_{TO} e $\Delta\Theta_H$ de acordo com a Equação 5:

$$\Theta_H = \Theta_{TO} + \Delta\Theta_H. \quad (5)$$

Devido às simplificações de cálculos na modelagem, geralmente adota-se uma margem de segurança na operação e os transformadores podem operar entre 20% e 30% menos que sua capacidade nominal, de forma que, a cada cinco transformadores, ocorre uma perda de operação que equivale a um transformador operando em sua capacidade nominal (Hell et al., 2008). Nesse sentido, o principal objetivo deste artigo é propor um modelo inteligente capaz de modelar a temperatura de ponto quente com alta acurácia, possibilitando assim a plena utilização dos equipamentos instalados sem impactar na vida útil destes equipamentos.

3. SISTEMA FUZZY EVOLUTIVO SET-MEMBERSHIP GAUSSIANO MULTIVARIADO

Nessa seção o modelo proposto neste trabalho é apresentado. Para tanto, inicialmente serão apresentados os conceitos de Agrupamento Gaussiano Multivariado evolutivo (*multivariable Gaussian evolving clustering* - MGEC) e de

filtragem *Set-Membership*, bem como o modelo evolutivo Gaussiano Multivariado (*evolving multivariable Gaussian* - eMG). Em seguida, o modelo *Set-Membership* evolutivo Gaussiano Multivariado (SM-eMG) é então introduzido.

3.1 MGEC

O Agrupamento Gaussiano Multivariado evolutivo (MGEC) integra o sistema eMG. Este é baseado no conceito de aprendizagem participativa. Sua estrutura de aprendizagem é apresentada na Figura 1

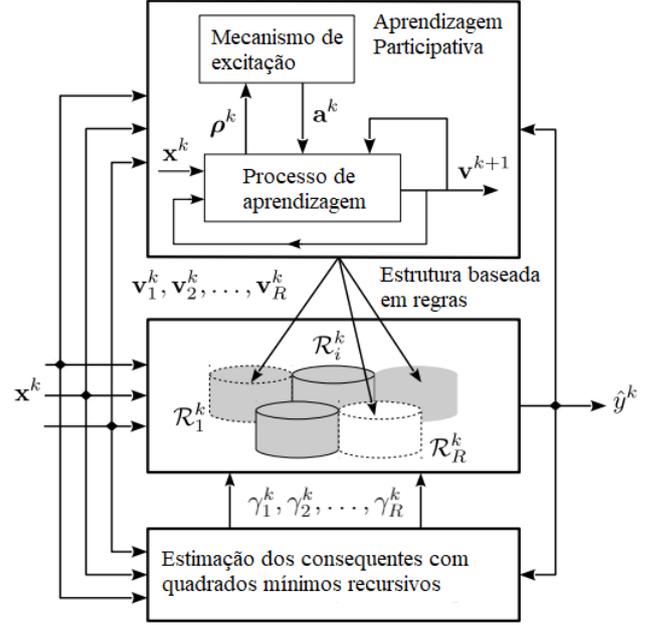


Figura 1. Mecanismo de aprendizagem do modelo eMG (Vieira et al., 2018)

De acordo com (Lemos et al., 2011), para atualizar a estrutura de *cluster* é utilizada uma medida de compatibilidade $\rho_i^k \in [0, 1]$, que indica o grau de compatibilidade de uma nova observação com a estrutura de *cluster* atual, e um índice de excitação $a_i^k \in [0, 1]$, que é o resultado de um mecanismo de excitação que indica se a estrutura atual deve ser revisada após a chegada de novas entradas. São definidos valores limites para ambos parâmetros ρ_i^k e a_i^k , são eles (T_ρ) e (T_a), respectivamente. A partir desses parâmetros, a criação, atualização ou combinação de regras é determinada.

Por exemplo, se a medida de compatibilidade da observação atual for menor que o seu limite para todos os *clusters* e o índice de excitação for maior que o seu limite, então, uma nova regra é criada. De outra forma, o *cluster* com a maior compatibilidade é ajustado como a seguir:

$$v_i^{k+1} = v_i^k + G_i^k (x^k - v_i^k) \quad (6)$$

em que x^k é o valor de entrada na etapa k , v_i^k é o centro de *cluster*, para $i = 1, \dots, c^k$, em que c^k é o número de *clusters* na etapa k e G_i^k é definido como:

$$G_i^k = \alpha (\rho_i^k)^{1-a_i^k} \quad (7)$$

e $\alpha \in [0, 1]$ é a taxa de aprendizagem. Esse parâmetro que será atualizado pelo algoritmo *Set-Membership*.

3.2 eMG

O modelo eMG é um modelo fuzzy evolutivo funcional de Takagi-Sugeno (eTS) (P. Angelov, 2004) no qual a base de regras é continuamente atualizada através de um algoritmo de agrupamento baseado no paradigma do aprendizado participativo (Yager, 1990), as funções de pertinência no antecedente das regras são funções Gaussianas multivariadas que são adotadas para preservar informações entre as interações das variáveis de entrada e que utiliza o algoritmo de mínimos quadrados recursivos ponderados para estimar os parâmetros dos consequentes das regras (Lemos et al., 2011).

No eMG a saída do modelo é a média ponderada das saídas de cada regra, ou seja:

$$\hat{y}^k = \sum_{i=1}^{c^k} \Psi_i(x^k) y_i^k \quad (8)$$

com funções de pertinência normalizadas:

$$\Psi_i(x^k) = \frac{\exp\left[(x^k - v_i^k) \Sigma_i^{-1} (x^k - v_i^k)^T\right]}{\sum_{i=1}^{c^k} \exp\left[(x^k - v_i^k) (\Sigma_i^{-1})^{-1} (x^k - v_i^k)^T\right]} \quad (9)$$

em que v_i^k e Σ_i^k são o centro e a matriz de dispersão do i ésimo *cluster* da função de pertinência na etapa k , determinados através de um algoritmo de agrupamento participativo.

Portanto, os parâmetros consequentes e a matriz Q_i das fórmulas de atualização para a regra i em cada iteração k são os seguintes:

$$\gamma_i^{k+1} = \gamma_i^k + Q_i^{k+1} x^k \Psi_i(x^k) \left[y_i^k - \left((x^k)^T \gamma_i^k \right) \right] \quad (10)$$

$$Q_i^{k+1} = Q_i^k - \frac{\Psi_i(x^k) Q_i^k x^k (x^k)^T Q_i^k}{1 + (x^k)^T Q_i^k x^k}. \quad (11)$$

Assim, a base de regras pode ser atualizada pela adição de um novo *cluster* ou pela mescla de dois *clusters* já existentes. No primeiro caso, os parâmetros consequentes são calculados como a média ponderada dos parâmetros dos *clusters* existentes.

$$\gamma_{novo}^k = \frac{\sum_{i=1}^{c^k} \gamma_i^k \rho_i^k}{\sum_{i=1}^{c^k} \rho_i^k}. \quad (12)$$

no segundo caso, se dois *clusters* i e j forem mesclados, os parâmetros consequentes serão calculados da seguinte forma:

$$\gamma_{novo}^k = \frac{\gamma_i^k \rho_i^k + \gamma_j^k \rho_j^k}{\rho_i^k + \rho_j^k}. \quad (13)$$

Nos dois casos, a matriz Q é definida como $Q_{novo}^k = \omega I_{m+1}$, em que I_{m+1} é uma matriz identidade $m + 1$ e

ω é um grande valor real, por exemplo, $\omega \in [10^2, 10^4]$. O valor ω usado neste trabalho é 10^3 .

Pode-se ver uma detalhada discussão sobre o modelo de agrupamento evolutivo Gaussiano multivariado (MGEC) e o modelo evolutivo Gaussiano Multivariado (eMG) em (Lemos et al., 2011).

3.3 SM-eMG

O SM é um algoritmo adaptativo que ajusta determinado parâmetro como uma função dos erros do modelo. A atualização é realizada comparando o erro com um valor padrão preestabelecido. Se o valor do erro for maior que um limite ($\bar{\gamma}$), então a variação da taxa de aprendizagem (α) aumenta para melhorar o aprendizado do modelo. Caso contrário, α é zerado para reduzir o custo computacional. Os autores em (Clarke and de Lamare, 2011; Aguiar et al., 2017) comprovam que o SM é uma filtragem adaptativa que limita o aumento do erro e reduz a complexidade computacional.

O SM-eMG proposto nesse trabalho foi baseado no modelo eMG apresentado em (Lemos et al., 2011). A principal contribuição do SM-eMG em relação ao eMG consiste na adoção de uma nova estratégia baseada em *Set-Membership*, aplicada na atualização da taxa de aprendizagem α retratada na Equação 7. O mecanismo proposto para atualizar α é apresentado a seguir:

$$\alpha^k = \begin{cases} 1 - \frac{\bar{\gamma}}{|\tilde{e}^k|}, & \text{if } |\tilde{e}^k| > \bar{\gamma} \\ 0, & \text{caso contrário.} \end{cases} \quad (14)$$

em que \tilde{e}_i^k é o erro na i ésima iteração.

Adicionalmente, um limite inferior (IL) e um limite superior (SL) são predefinidos para limitar α , visando melhorar os resultados das previsões e para α não atingir valores inconsistentes. Em outras palavras, $\alpha \in [IL, SL]$, em que $IL \geq 0$, $SL \leq 1$ e $IL \leq SL$.

4. RESULTADOS EXPERIMENTAIS

Para avaliar a eficácia do método proposto neste trabalho, o modelo apresentado é aplicado na modelagem da temperatura de ponto quente de um transformador real. As características do referido equipamento são apresentadas na Tabela 1.

Tabela 1. Características do transformador de potência experimental.

Perdas no cobre	776 W
Ano de fabricação	MACE/1987
Perdas no ferro	195 W
Classificação da placa de identificação	25 kVA
Dimensões do tanque	64 × 16 × 80 cm ³
Temperatura do topo do óleo sob carga máxima	73.1 °C
Tipo de refrigeração	ONAN
$V_{primario}/V_{secundario}$	10 kV / 380 kV
Peso do núcleo e do conjunto da bobina	136 kg
Peso do óleo	62 kg

Os conjuntos de dados coletados deste transformador são os mesmos apresentados em (Alves et al., 2020) e foram obtidos através de um sistema de medição composto por

três sensores de temperatura de fibra óptica e um sensor de corrente de efeito hall. Os dois primeiros sensores de temperatura (S1 e S2) foram inseridos no espaçador entre os discos no topo dos enrolamentos de alta e baixa tensão, como mostra a Figura 2.

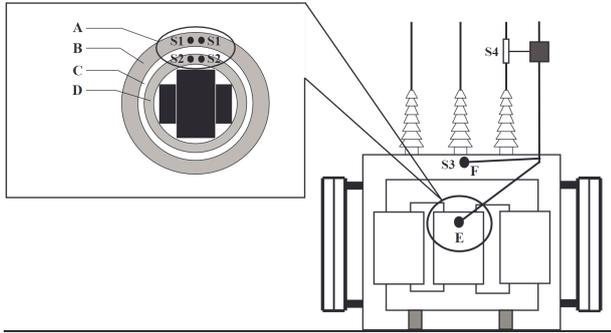


Figura 2. Localização dos sensores no transformador, em que: (A) medição de ponto quente; (B) enrolamento de alta tensão; (C) duto de óleo; (D) enrolamento de baixa tensão; (E) ponto quente e (F) topo do óleo (Alves et al., 2020).

A agregação dos valores obtidos desses dois sensores fornece uma medida do valor real da temperatura de ponto quente do transformador (Θ_H). O terceiro sensor de temperatura (S3) foi inserido na parte superior do tanque e fornece o valor real da temperatura de topo do óleo (Θ_{TO}). O sensor de corrente de efeito hall (S4) fornece o valor real da corrente de carga (K) do transformador.

Nos experimentos, dois conjuntos de dados compostos pelos registros das temperaturas e da corrente de carga adquirida de cada sensor em um intervalo de 24h com uma taxa de amostragem de 5 minutos foram utilizados para avaliar os modelos propostos. A Figura 3 mostra o conjunto de dados utilizado para treinamento. Para cobrir todas as condições de operação dos transformadores, duas condições de carga diferentes foram consideradas: *i*) Conjunto de dados 1: sem sobrecarga e *ii*) Conjunto de dados 2: com sobrecarga. As Figuras 4 e 5 mostram o comportamento das temperaturas de ponto quente e de topo de óleo para uma dada corrente de carga para essas duas condições de carga.

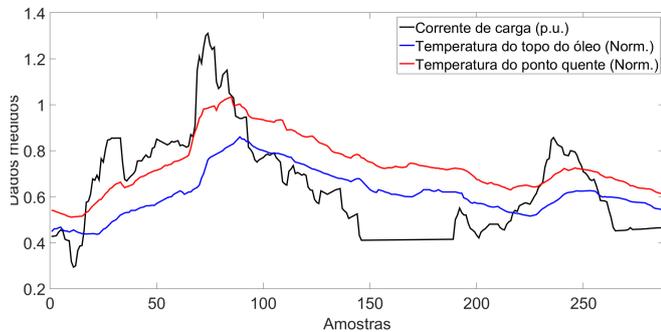


Figura 3. Conjunto de dados de treinamento

Assim sendo, o objetivo dos modelos testados é estimar a temperatura de ponto quente a partir da corrente de carga e da temperatura de topo de óleo. Diferentes estudos (Galdi et al., 2000; Villacci et al., 2005; Hell et al., 2007) e

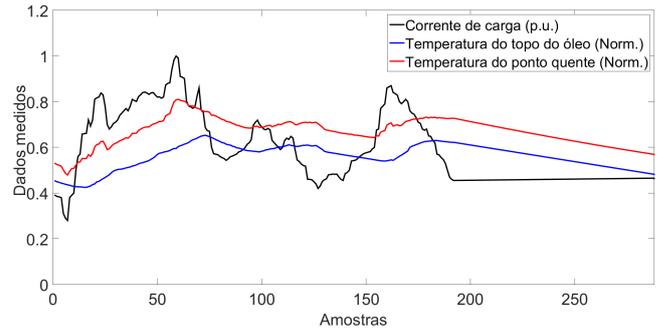


Figura 4. Conjunto de dados 1: condição sem sobrecarga

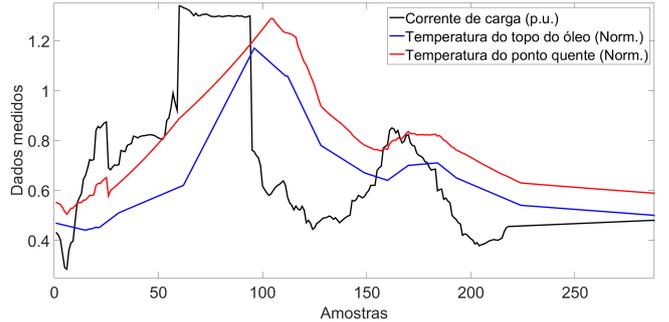


Figura 5. Conjunto de dados 2: condição com sobrecarga

testes experimentais indicam que as entradas de modelo relevantes para este caso são a corrente de carga (K), a temperatura de topo de óleo e a corrente de carga atrasada em um passo ($q^{-1}K$, em que q^{-1} é o operador de atraso). Essa opção demonstrou reduzir a sensibilidade do modelo em relação às flutuações nos parâmetros térmicos, que podem variar consideravelmente de um transformador para outro (Hell et al., 2008).

Para provar a eficiência do modelo proposto na estimativa da temperatura de ponto quente dos transformadores de potência seus resultados são comparados com outros modelos evolutivos e não evolutivos (estrutura fixa) descritos na literatura. Dentre os modelos não evolutivos implementados estão o modelo determinístico baseado na *IEEE Standard C57.91-2011* (IEEE-DM) descrito na Seção 2, um modelo baseado em Rede Neural *Perceptron* Multicamadas (MLP) e um modelo baseado em um sistema de inferência adaptativa neurofuzzy (ANFIS) (Jang, 1993). Já entre os modelos evolutivos implementados, além do modelo SM-eMG proposto neste trabalho, estão o modelo eMG descrito na seção 3.2, o modelo *evolving Participatory Learning with Kernel Recursive Least Squares* (ePL-KRLS) proposto em (Vieira et al., 2018), e os modelos *Set-Membership evolving Participatory Learning with Kernel Recursive Least Squares* (SM-ePL-KRLS) e *Enhanced Set-Membership evolving Participatory Learning with Kernel Recursive Least Squares* (ESM-ePL-KRLS) propostos em (Alves et al., 2020).

Na avaliação de desempenho destes modelos foram utilizadas 3 métricas de desempenho: o RMSE (*root mean squared error*), o NDEI (*nondimensional error index*) e o MAE (*mean absolute error*). Além disso, para uma validação estatística do desempenho destes modelos, também foi realizado o teste Morgan-Granger-Newbold (MGN), introduzido em (Diebold and Mariano, 2002).

Os parâmetros utilizados pelos modelos evolutivos foram definidos como sendo: $\lambda = 0.05$, $\alpha = 0.01$, $w = 25$ e $\Sigma_{init} = 2 \times 10^{-2} I_3$. Além disso, o SM-eMG possui os seguintes parâmetros adicionais: $IL = 0.00001$, $SL = 0.1$, $\bar{\gamma} = 0.0270$ para o conjunto de dados 1 e $\bar{\gamma} = 0.0150$ para o conjunto de dados 2. Os parâmetros $\bar{\gamma}$ foram escolhidos como o melhor resultado entre 700 simulações, para cada conjunto de dados, começando em $\bar{\gamma} = 0.001$ até $\bar{\gamma} = 0.7$.

Já os parâmetros utilizados na modelagem determinística (IEEE-DM) do transformador experimental foram os seguintes:

$$R = 4, \Delta\Theta_{H,R} = 5^\circ \text{ C}, \Delta\Theta_{TO,R} = 54^\circ \text{ C}, \Theta_{H,R} = 80^\circ \text{ C}$$

$$\Theta_{A,R} = 21^\circ \text{ C}, q = 0.8, m = 0.8, \tau_{TO} = 3 \text{ h}, \tau_H = 0.1 \text{ h}$$

A rede neural MLP foi implementada com uma única camada oculta com 4 neurônios treinados com o algoritmo de retropropagação. O modelo ANFIS foi implementado com quatro conjuntos fuzzy para cada variável de entrada e quatro regras fuzzy geradas por meio do procedimento de agrupamento fuzzy *c-means* (Alves et al., 2020). As Tabelas 2 e 3 mostram os resultados obtidos para todos os modelos implementados, NR é o número de regras.

Tabela 2. Comparação de desempenho - Conjunto de dados 1

Algoritmo	RMSE	NDEI	MAE	NR
IEEE-DM (IEEE, 2012)	1.0245	16.1089	0.7524	-
MLP (Duda et al., 2012)	0.0467	0.7336	0.0343	4
ANFIS (Jang, 1993)	0.0124	0.1952	0.0091	4
ePL-KRLS (Vieira et al., 2018)	0.0137	0.2153	0.0101	1
eMG (Lemos et al., 2011)	0.0113	0.1791	0.0067	3
SM-ePL-KRLS (Alves et al., 2020)	0.0103	0.1624	0.0076	1
ESM-ePL-KRLS (Alves et al., 2020)	0.0103	0.1616	0.0075	1
SM-eMG	0.0096	0.1521	0.0062	3

Tabela 3. Comparação de desempenho - Conjunto de dados 2

Algoritmo	RMSE	NDEI	MAE	NR
IEEE-DM (IEEE, 2012)	0.4005	1.9446	0.2769	-
ANFIS (Jang, 1993)	0.0481	0.2340	0.0333	4
MLP (Duda et al., 2012)	0.0317	0.1539	0.0219	4
ePL-KRLS (Vieira et al., 2018)	0.0330	0.1615	0.0242	2
eMG (Lemos et al., 2011)	0.0330	0.1615	0.0196	3
SM-ePL-KRLS (Alves et al., 2020)	0.0265	0.1293	0.0188	1
ESM-ePL-KRLS (Alves et al., 2020)	0.0252	0.1231	0.0186	1
SM-eMG	0.0245	0.1197	0.0155	3

Nas Figuras 6 e 7 são apresentadas representações gráficas dos resultados obtidos neste trabalho. Para fins de visualização, apenas os modelos propostos neste trabalho são mostrados.

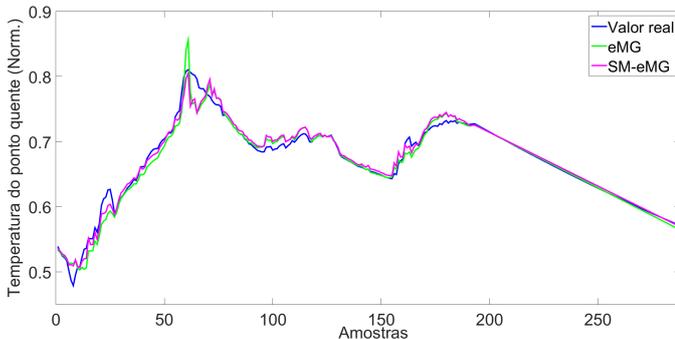


Figura 6. Estimativa de ponto quente, conjunto de dados 1

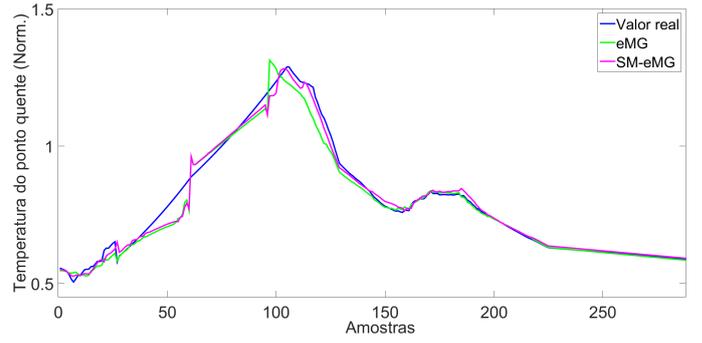


Figura 7. Estimativa de ponto quente, conjunto de dados 2

As Tabelas 2 e 3 mostram que o modelo proposto obteve os melhores resultados em geral, com um número competitivo de regras quando comparado com os melhores resultados dos outros modelos considerados.

A Tabela 4 apresenta os resultados dos testes MGN para os dois conjuntos de dados apresentados, considerando um nível de significância α_{MGN} de 5%. Dessa forma, é possível observar que para o conjunto de dados 1, a hipótese nula é aceita, assumindo que os modelos possuem a mesma acurácia. Considerando o conjunto de dados 2, a hipótese nula é rejeitada, assumindo que os modelos comparados têm acurácias diferentes.

Tabela 4. Resultados dos testes MGN.

Conjunto de dados	Modelo 1 x Modelo 2	MGN	p-valor
1	SM-eMG x eMG	0.6436	0.2613
2	SM-eMG x eMG	26.8007	0.0000

Vale ressaltar que o modelo proposto pode ser aplicado a transformadores reais em serviço através de algumas modificações simples no equipamento, tais como a instalação de um sensor de efeito hall para medir a corrente de carga e a inserção de um sensor de temperatura de fibra óptica na tampa de inspeção do transformador para medir a temperatura no topo do óleo. Essas modificações são não invasivas e têm um baixo custo de implementação. Muitos transformadores em operação já possuem esses sensores instalados, o que torna a abordagem proposta aplicável ao problema de estimativa da temperatura de ponto quente em um sistema elétrico de potência real.

5. CONCLUSÃO

Este artigo introduziu um novo modelo para lidar com a estimativa de temperatura do ponto quente em transformadores de potência, denominado SM-eMG. O modelo foi avaliado usando dados reais de modelagem térmica de transformadores de potência, em duas condições de carga consideradas: com e sem sobrecarga.

Para avaliar e comparar os resultados, foram utilizadas métricas de erro RMSE, NDEI e MAE, o número de regras, bem como diferentes abordagens evolutivas e não evolutivas. Para apoiar a eficácia dos modelos propostos em comparação ao eMG, foram apresentados os resultados dos teste estatístico MGN.

Os resultados das simulações realizadas sugerem que o modelo proposto é uma opção altamente interessante para integrar uma ferramenta de suporte à decisão no gerenciamento operacional do sistema elétrico, visando controlar a corrente de carga e prolongar a vida útil dos transformadores de potência.

Perspectivas futuras deste trabalho incluem a integração do modelo proposto a uma ferramenta de suporte à decisão para auxiliar no planejamento e operação do sistema elétrico, em especial em condições onde há a necessidade de sobrecarga nos equipamentos. Além disso, se pretende implementar um sistema para atualizar os parâmetros iniciais do modelo em uso, e também investigar a utilização de um sistema de lógica fuzzy intervalar do tipo 2 (T2FLS) para lidar com a presença de incerteza nos conjuntos de dados.

REFERÊNCIAS

- Aguiar, E.P., de A. Nogueira, F.M., Vellasco, M.M.B.R., and Ribeiro, M.V. (2017). Set-membership type-1 fuzzy logic system applied to fault classification in a switch machine. *IEEE Transactions on Intelligent Transportation Systems*, 18(10), 2703–2712.
- Alves, K.S.T.R., Hell, M., Oliveira, F.L.C., and de Aguiar, E.P. (2020). An enhanced set-membership evolving participatory learning with kernel recursive least squares applied to thermal modeling of power transformers. *Electric Power Systems Research*, 184, 106334.
- Clarke, P. and de Lamare, R.C. (2011). Low-complexity reduced-rank linear interference suppression based on set-membership joint iterative optimization for ds-cdma systems. *IEEE Transactions on Vehicular Technology*, 60(9), 4324–4337.
- Diebold, F.X. and Mariano, R.S. (2002). Comparing predictive accuracy. *Journal of Business & Economic Statistics*, 20(1), 134–144.
- Duda, R.O., Hart, P.E., and Stork, D.G. (2012). *Pattern classification*. John Wiley & Sons.
- Galdi, V., Ippolito, L., Piccolo, A., and Vaccaro, A. (2000). Neural diagnostic system for transformer thermal overload protection. *IEEE Proceedings - Electric Power Applications*, 147(5), 415–421.
- Hell, M., Costa, P., and Gomide, F. (2007). Recurrent neurofuzzy network in thermal modeling of power transformers. *IEEE Transactions on Power Delivery*, 22(2), 904–910.
- Hell, M., Costa, P., and Gomide, F. (2008). Participatory learning in power transformers thermal modeling. *IEEE Transactions on Power Delivery*, 23(4), 2058–2067.
- IEEE (2012). IEEE guide for loading mineral-oil-immersed transformers and step-voltage regulators. *IEEE Std C57.91-2011 (Revision of IEEE Std C57.91-1995)*, 1–123.
- Ippolito, L. (2004). An adaptive fuzzy approach to predictive overload protection systems for power transformers. *Automatika: Journal of Automation, Measurement, Electronics, Computing and Communications*, 45(3-4), 169–178.
- Jang, J.S. (1993). Anfis: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665–685.
- Lemos, A., Caminhas, W., and Gomide, F. (2011). Multi-variable gaussian evolving fuzzy modeling system. *IEEE Transactions on Fuzzy Systems*, 19(1), 91–104.
- Mikha-Beyranvand, M., Faiz, J., Rezaeealam, B., Rezaei-Zare, A., and Jafarboland, M. (2019). Thermal analysis of power transformers under unbalanced supply voltage. *IET Electric Power Applications*, 13(4), 503–512.
- P. Angelov, D.F. (2004). An approach to online identification of takagi-sugeno fuzzy models. *IEEE Trans. Syst. Man Cybernetics*, 34(1), 484–498.
- P. Angelov, D. P. Filev, N.K. (2010). *Evolving Intelligent Systems: Methodology and Applications*. Wiley, IEEE Press.
- Souza, L., Lemos, A.P., Caminhas, W.M., and Boaventura, W. (2012). Thermal modeling of power transformers using evolving fuzzy systems. *Engineering Applications of Artificial Intelligence*, 25(5), 980–988.
- Vieira, R., Gomide, F., and Ballini, R. (2018). Kernel evolving participatory fuzzy modeling for time series forecasting. In *2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 1–9. IEEE.
- Villacci, D., Bontempi, G., Vaccaro, A., and Birattari, M. (2005). The role of learning methods in the dynamic assessment of power components loading capability. *IEEE Transactions on Industrial Electronics*, 52(1), 280–289.
- Yager, R. (1990). A model of participatory learning. *IEEE Trans. Syst. Man Cybernetics*, 20(5), 1229–1234.