

Modelagem Térmica de Transformadores de Potência Baseada em SODA e Sistema de Inferência Fuzzy Otimizado por Enxame de Partículas [★]

Danilo P. M. de Souza^{*} Eduardo P. de Aguiar^{*,**}
 Kaike Sa T. R. Alves^{*} Marcos V. G. da Rocha^{**}
 Thiago E. Fernandes^{***} Michel B. Hell^{****}
 Fernando L. C. Oliveira[†] Eliane da S. Christo[‡]

^{*} Programa de Pós-Graduação em Modelagem Computacional.
 Universidade Federal de Juiz de Fora, Juiz de Fora-MG.

^{**} Programa de Pós-Graduação em Engenharia Elétrica. Universidade
 Federal de Juiz de Fora, Juiz de Fora-MG.

^{***} Departamento de Engenharia de Produção e Mecânica.
 Universidade Federal de Juiz de Fora, Juiz de Fora-MG.

^{****} Departamento de Circuitos Elétricos, Universidade Federal de Juiz
 de Fora, Juiz de Fora-MG.

[†] Departamento de Engenharia Industrial. Pontifícia Universidade
 Católica do Rio de Janeiro, Rio de Janeiro-RJ.

[‡] Programa de Pós-Graduação em Engenharia de Produção,
 Universidade Federal Fluminense, Volta Redonda-RJ.

E-mails: danilopms@id.uff.br, eduardo.aguiar@engenharia.ufjf.br,
 kaike.alves@engenharia.ufjf.br, marcos.rocha2019@engenharia.ufjf.br,
 thiago.esterici@engenharia.ufjf.br, michel.hell@ufjf.edu.br,
 cyrino@puc-rio.br, elianechristo@id.uff.br

Abstract: Several studies have been oriented towards the development of more accurate thermal models and with lower computational cost for power transformers. Motivated by the need for adaptable systems, evolutionary intelligent systems have received great attention in problems of various types of problems. This work presents a new method of parameter adjustment of a fuzzy inference system (FIS) through particle swarm optimization (PSO). To determine the number of FIS pertinence functions, the Self-organized direction aware (SODA) algorithm is used. This new model, called SODA-FIS-PSO, has as main objective to minimize the error during the learning process. The model is applied to data from a real transformer for various loading conditions. The results show better performance when compared with alternative evolutionary and non-evolutionary approaches suggested in the literature.

Resumo: Diversos estudos tem sido orientados no sentido de desenvolver modelos térmicos mais precisos e com menor custo computacional para transformadores de potência. Motivados pela necessidade de sistemas adaptáveis, os sistemas inteligentes evolutivos vêm recebendo grande atenção em problemas de vários tipos de problemas. Este trabalho apresenta um novo método de ajuste de parâmetros de um sistema de inferência fuzzy (FIS) através de otimização por enxame de partículas (PSO). Para a determinação do número de funções de pertinência do FIS, é utilizado o algoritmo Self-organized direction aware (SODA). Este novo modelo, denominado SODA-FIS-PSO, tem como principal objetivo minimizar o erro durante o processo de aprendizagem. O modelo é aplicado em dados de um transformador real para diversas condições de carregamento. Os resultados apresentam melhor desempenho quando comparados com abordagens alternativas evolutivas e não evolutivas sugeridas na literatura.

Keywords: Particle Swarm Optimization; Fuzzy Inference Systems; SODA; Power Transformers; Thermal Modeling.

Palavras-chaves: Otimização por Enxame de Partículas; Sistema de Inferência Fuzzy; SODA; 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 da 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

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 de um *FIS* (*fuzzy inference system* -FIS) (Takagi and Sugeno, 1985) para resolução de um problema de regressão não linear relacionado à modelagem térmica de transformadores de potência. Para geração do *FIS* é utilizado o algoritmo SODA (*Self-Organised Direction Aware Data Partitioning Algorithm* (Gu et al., 2018)) que determina o número de funções de pertinência *fuzzy* que posteriormente são otimizadas por *PSO* (*particle swarm optimization*) (Kennedy, 1995). Este novo modelo, denominado **SODA-FIS-PSO**, tem como principal característica a limitação do aumento do erro durante o processo de aprendizagem, o que reduz a sua complexidade computacional, 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 **SODA-FIS-PSO** 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

* Os autores agradecem o apoio da CAPES, CNPq, FAPEMIG e UFJF pelo suporte financeiro.

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:

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

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 n 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. MODELO PROPOSTO

Nessa seção é apresentado o modelo proposto neste trabalho. Para tanto, serão introduzidos os conceitos de algoritmo de direção auto-organizável (*self-organized direction aware* - SODA), sistema de inferência *fuzzy* (*fuzzy inference system* - FIS), e de otimização por enxame de partículas (*particle swarm optimization* - PSO).

3.1 SODA

Para expressar esse método, considera-se um conjunto de dados $\{x_1, x_2, x_3, \dots\}$ em um espaço R^m , em que $x_i = [x_{i,1}, x_{i,2}, \dots, x_{i,m}]^T \in R_m$ é um vetor dimensional, $i = 1, 2, 3, \dots$; m é a dimensionalidade; onde o índice i ($i = 1, 2, 3, \dots$) indica as instâncias de tempo da i -ésima amostra de dados. Portanto, dentro do conjunto de dados observado na instância n -ésima denotada por $\{x_1, x_2, \dots, x_n\}$, também consideramos o conjunto de valores exclusivos classificados das amostras de dados $\{u_1, u_2, \dots, u_{n_u}\}$ ($u_i = [u_{i,1}, u_{i,2}, \dots, u_{i,m}]^T \in R_m$) de $\{x_1, x_2, \dots, x_n\}$ e os números normalizados correspondentes correspondentes de repetições $\{f_1, f_2, \dots, f_n\}$, em que n_u ($1 \geq n_u \leq n$) é o número de amostras de dados exclusivas e $\sum_{i=1}^{n_u} f_i = 1$. As derivações a seguir são padronizadas para a n -ésima instância de tempo, a menos que haja uma declaração específica (Gu et al., 2018).

Componentes de Distância/Dissimilaridade em SODA A abordagem SODA, neste trabalho, emprega (Gu et al., 2018):

- (1) uma componente de magnitude $d_M(x_i, x_j)$ baseada na métrica de distância Canberra;
- (2) uma componente angular $d_A(x_i, x_j)$ baseada em similaridade de cosseno;

Operadores EDA A recém-introduzida Análise Empírica de Dados (*Empirical Data Analysis*-EDA) (Gu et al., 2018) é uma metodologia alternativa para aprendizado de máquina, totalmente baseada em amostras de dados reais observadas empiricamente (Angelov et al., 2017a,b).

Os operadores de EDA incluem (Gu et al., 2018):

(1) Proximidade cumulativa:

A proximidade cumulativa, π de x_i ($i = 1, 2, \dots, n$) é definida como (Angelov, 2014; Angelov et al., 2017b):

$$\pi_n(x_i) = \sum_{j=1}^n d^2(x_i, x_j) \quad (6)$$

Em que $d(x_i, x_j)$ indica a distância/dissimilaridade entre x_i e x_j .

(2) Densidade local:

A densidade local D é definida como o inverso da proximidade cumulativa normalizada e indica diretamente o padrão principal dos dados observados. A densidade local, D de x_i ($i = 1, 2, \dots, n; n_u > 1$) é definida da seguinte forma (Angelov et al., 2017a,b):

$$D_n(x_i) = \frac{\sum_{j=1}^n \pi_n(x_j)}{2n\pi_n(x_i)} \quad (7)$$

Na abordagem de particionamento de dados SODA proposta, uma vez que ambos os componentes, a magnitude (métrica) e a angular são igualmente importantes, a densidade local de $x_i (i = 1, 2, \dots, n; n_u > 1)$ é definida como a soma da métrica local baseada em Canberra ($D_n^M(x_i)$) e a densidade local com base em ângulos ($D_n^A(x_i)$).

(3) **A densidade global (Gu et al., 2018):**

A densidade global é definida para amostras de dados exclusivas, juntamente com o número correspondente de repetições no conjunto/fluxo de dados. Tem a capacidade de fornecer distribuições multimodais automaticamente, sem a necessidade de decisões do usuário, procedimentos de pesquisa/otimização ou algoritmos de agrupamento. A densidade global de uma amostra de dados exclusiva, $u_i (i = 1, 2, \dots, n_u; n_u > 1)$ é expressa como o produto de sua densidade local e seu número de repetições consideradas como uma ponderação fator (Angelov et al., 2017b) da seguinte maneira:

$$D_n^G(u_i) = f_i D_n(u_i) \quad (8)$$

Como pode-se ver pelas equações acima, os principais operadores de EDA: proximidade cumulativa (π), densidade local (D) e densidade global (D^G) podem ser atualizados recursivamente, o que mostra que a proposta do algoritmo SODA é adequado para processamento *on-line* de transmissão de dados.

Algoritmo SODA para particionamento de dados As principais etapas do algoritmo SODA incluem: formar um número de planos de DA a partir das amostras de dados observadas usando ambos, as densidades baseadas em magnitude e ângulos; identificar os pontos focais usando a granularidade γ dos resultados do agrupamento e se relacione à desigualdade Chebyshev (Angelov et al., 2017b); e por fim, use-se os pontos focais para particionar o espaço de dados em nuvens de dados. O procedimento detalhado do algoritmo de particionamento SODA proposto é apresentado por (Gu et al., 2018).

Algoritmo de agrupamento O objetivo desse algoritmo é reunir todos os planos de DA que mantêm informações pertencentes ao mesmo grupo. Além de se relacionar com cada amostra de dados contida nesses planos, um rótulo que foi usado no módulo de classificação. Os grupos de dados são: ferramentas de séries temporais adequadas na condição ($Index = 0$) e ferramentas de séries temporais inadequadas na condição ($Index = 1$). A saída fornecida pelo SODA é um vetor com dimensão equivalente ao número de séries temporais no conjunto de dados. O vetor contém o índice correspondente do plano DA ao qual cada série pertence. Considerando o número de séries temporais, foi calculada a porcentagem de dados pertencentes a cada grupo (0 ou 1) em cada plano de DA e adotada como parâmetro de condição no algoritmo de agrupamento. Portanto, se um plano DA contiver mais de 67% dos dados pertencentes a um dos grupos, o algoritmo rotulará seus dados com o índice do grupo. Os aviões DA com menos de 67% dos dados pertencentes a um dos grupos seriam desconsiderados, devido ao fato de que, assumindo que

seus dados pertencessem a um desses grupos, levaria a uma classificação enganosa.

3.2 FIS

Um sistema de inferência *fuzzy* trata-se da classificação de determinado valor baseado em regras de inferência. Estas regras por sua vez são construídas a partir de operações próprias da lógica *fuzzy* (estas operações são extensões da lógica booleana) sobre conjuntos *fuzzy*. As funções de pertinência são responsáveis por mapear o conjunto de dados com números reais para o conjunto *fuzzy*. Estes conjuntos, as funções de pertinência bem como as regras, são contruídos com base em conhecimentos de pessoa especialista no problema ou extraídas dos dados numéricos.

3.3 PSO

PSO é uma meta-heurística de inteligência de enxame (*swarm intelligence*-SI) baseada no comportamento natural da população de certos animais, como por exemplo uma revoadada, um cardúme, dentre outros Kennedy (1995). No algoritmo cada indivíduo é chamado de partícula e este se comporta de forma descentralizada e auto-organizados (Rosendo, 2010).

$$\begin{aligned} v_i^{(it)} &= v_i^{(it-1)} \times w^{(it)} \\ &+ c_1 \times rand() \times (x_i^{(it-1)} - p_{best_i}) \\ &+ c_2 \times rand() \times (x_i^{(it-1)} - g_{best}) \quad (9) \\ x_i^{(it)} &= x_i^{(it-1)} + v_i^{(it)} Fc_i^{(it)} = f(x_i^{(it)}) \quad (10) \\ p_{best_i} &= \min(Fc_i) \quad (11) \\ g_{best} &= \min(p_{best_i}) \quad (12) \end{aligned}$$

Em que $v_i^{(it)}$ e $x_i^{(it)}$ é a velocidade e posição da partícula i no instante it , respectivamente; c_1 e c_2 são os coeficientes de aprendizado da partícula e do enxame, respectivamente; $rand()$ são valores reais aleatórios contidos no intervalo $[0; 1]$; $w^{(it)}$ é o coeficiente de inércia da velocidade; p_{best_i} e g_{best} são as melhores posições de cada partícula e do enxame, respectivamente; $Fc_i^{(it)}$ é a função custo da partícula i no instante it calculada em função da posição x_i^{it} desta mesma partícula nesse mesmo instante.

O desempenho do PSO depende muito da escolha de parâmetros apropriados. O fator de inércia é um parâmetro deste algoritmo que foi proposto pela primeira vez por Shi e Eberhart para trazer um equilíbrio entre as características de exploração do PSO. Este parâmetro w exerce controle sobre a velocidade de mudança de posição de cada partícula. Há diversas propostas para os valores do fator de inércia, que vão desde variações aleatórias apresentada (Kennedy, 1995) a um fator de inércia para cada partícula conforme o desempenho destas partículas (Panigrahi et al., 2008), onde há um *rank* de posições onde as melhores partículas têm seus fatores de inércia com valores menores. Como esta decisão está relacionada ao fato de que conforme as iterações ocorrem o erro entre valores reais e calculados tendem a diminuir, e por isso deve-se diminuir a velocidade de mudança das partículas, ou seja, o fator de inércia é uma função do erro. Para

problemas de minimização, pode-se ainda considerar o fator de inércia como diretamente proporcional à função custo do PSO:

$$w_i^{(it)} = f(\text{erro}_i^{(it-1)}) \quad (13)$$

$$\text{erro}_i^{(it)} = Fc_i^{(it)} \quad (14)$$

$$Fc_i^{(it)} = \sqrt{\frac{\sum_{j=1}^{N_d} (FIS_i^{(it)}(\text{Entrada}_j) - \text{Saida}_j)^2}{N_d}} \quad (15)$$

$$w_i^{(it)} = \frac{Fc_i^{(it-1)}}{\max(Fc^{(it-1)})} ; w_i^{(1)} = 1 \quad (16)$$

Em que $w_i^{(it)}$ é o fator de inércia da partícula i na iteração it ; $Fc_i^{(it)}$ é o valor da função custo do PSO para a partícula i na iteração it ; $\max(Fc^{(it-1)})$ é o valor máximo da função custo na iteração $it - 1$ (o custo da pior partícula nesta iteração); $FIS_i^{(it)}(\text{Entrada})$ é o valor obtido como saída para o FIS obtido por meio da partícula i na iteração it quando os dados de 1 a N_d são aplicados à entrada deste FIS; Entrada_j são os j - ésimos valores de cada vetor de entrada; Saida_j é o j - ésimo valor real previamente conhecido.

3.4 Etapas do modelo proposto

O modelo proposto é apresentado de forma sucinta na Figura 1.

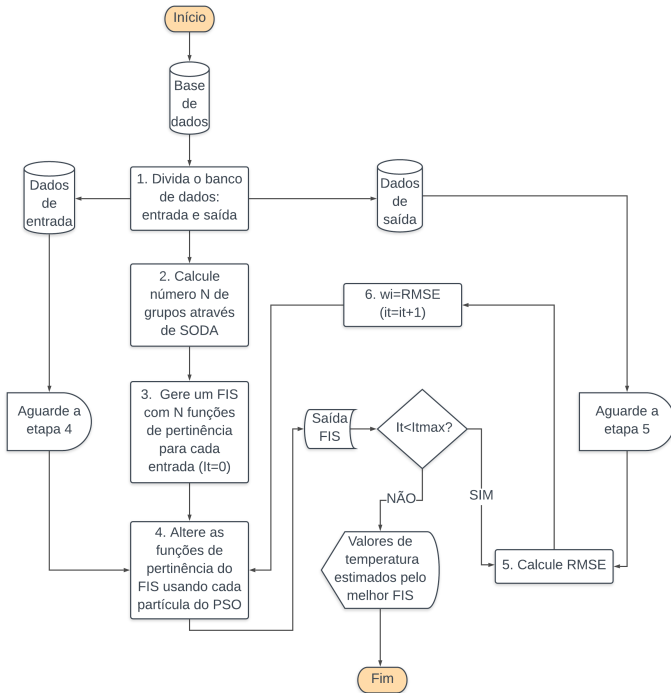


Figura 1. Fluxograma do modelo proposto.

- (1) O banco de dados é separado em três vetores de dados de entrada (temperatura do óleo - Θ_{TO} , corrente de carga - K , corrente de carga atrasada a um passo - $q^{-1}K$) e um vetor de dados de saída (temperatura do ponto quente - Θ_H);

- (2) O algoritmo SODA é aplicado aos dados de entrada e saída. Como resposta é dado um número N de conjuntos;
- (3) É gerado um FIS com um número N de funções de pertinência para cada uma das três entradas e para a saída do banco de dados;
- (4) Nesta etapa, a cada iteração it do PSO, cada partícula do enxame realiza alterações nas funções de pertinência do FIS;
- (5) Para avaliar a qualidade destas alterações os dados de entrada (Θ_{TO} , K e $q^{-1}K$) são aplicados ao FIS obtendo um vetor resposta $FIS_i^{(it)}(\text{Entrada})$ que por sua vez é comparado ao vetor Θ_H (temperatura do ponto quente). O resultado desta comparação se dá por meio do cálculo do $RMSE$;
- (6) O $RMSE$ entre estes valores de $FIS_i^{(it)}(\text{Entrada})$ e Θ_H atualiza o valor do fator de inércia da partícula i para a iteração seguinte ($it + 1$). O processo de aplicação do PSO ao FIS se repete até que o número máximo de iterações (it_{max}) do PSO seja atingido. Com isso o FIS modificado pela melhor partícula do PSO na última iteração é o que apresenta o menor valor de $RMSE$ entre sua saída FIS e os valores reais de temperatura do ponto quente.

4. RESULTADOS EXPERIMENTAIS

Para avaliar a eficácia do método proposto neste trabalho com dados reais, o modelo apresentado é aplicado na modelagem da temperatura de ponto quente de um transformador real.

Os conjuntos de dados coletados deste transformador são os mesmos apresentados em (Hell et al., 2008) 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. 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 3 e 4 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 1: condição sem sobrecarga




Figura 4. Conjunto de dados 2: condição com sobrecarga

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 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 **SODA-FIS-PSO** proposto neste trabalho, estão 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: $IL = 0.00001$, $SL = 0.1$, $\bar{\gamma} = 0.0170$ para o conjunto de dados 1 e $\bar{\gamma} = 0.0110$ 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).

Para o modelo proposto são adotados os seguintes valores: O PSO é definido com uma população de 100 partículas, em posições iniciais aleatórias e em um espaço de busca variando de -25 a 25 . As velocidades máximas e mínimas são inicializadas com 5 , -5 e as velocidades iniciais com 0 . Aos coeficientes de aprendizado pessoal e global são atribuídos os valores de 1 e 2 . Já os fatores de inércia individuais são inicializados com 1 . É ainda estipulada 30 iterações.

Quanto ao FIS, este é do tipo Sugeno e é gerado com 16 funções de pertinência obtidos por SODA para cada uma das entradas e saída. As funções de entrada são do tipo gaussiana e as funções de saída do tipo linear. Para as

regras o método E equivale ao produto, e para o método OU equivale à soma algébrica. As regras numéricas são especificadas como uma matriz MR , em que cada uma de suas 16 linhas é uma regra. Para cada linha, a descrição numérica da regra possui 5 colunas. As primeiras 3 colunas especificam índices da função de associação de entrada com iguais valores. A próxima coluna especifica os índices da função de associação de saída com os mesmos valores dos índices da função de associação de entrada. A coluna 5 especifica o peso da regra com variação de 0 a 1. A coluna final especifica o operador difuso antecedente E representado pelo valor numérico 1. A matriz de regras numéricas MR é mostrada na Equação 17.

$$MR = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 \\ 2 & 2 & 2 & 2 & 1 & 1 \\ 3 & 3 & 3 & 3 & 1 & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 15 & 15 & 15 & 15 & 1 & 1 \\ 16 & 16 & 16 & 16 & 1 & 1 \end{bmatrix} \quad (17)$$

As Tabelas 1 e 2 mostram os resultados obtidos para todos os modelos implementados, NR é o número de regras. Observa-se que o modelo proposto obteve os melhores resultados em todas as métricas de comparações adotadas, exceto pelo número de regras.

Tabela 1. 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
ePL-KRLS (Vieira et al., 2018)	0,0137	0,2153	0,0101	1
ANFIS (Jang, 1993)	0,0124	0,1952	0,0091	4
eMG (Lemos et al., 2011)	0,0118	0,1856	0,0090	1
ESM-ePL-KRLS (Alves et al., 2020)	0,0103	0,1616	0,0075	1
SODA-FIS-PSO	0,0034	0,0540	0,0023	16

Tabela 2. 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
eMG (Lemos et al., 2011)	0,0388	0,1890	0,0183	4
ePL-KRLS (Vieira et al., 2018)	0,0330	0,1615	0,0242	2
MLP (Duda et al., 2012)	0,0317	0,1539	0,0219	4
ESM-ePL-KRLS (Alves et al., 2020)	0,0252	0,1231	0,0186	1
SODA-FIS-PSO	0,0152	0,0744	0,0097	16

Nas Figuras 5 e 6 representam graficamente os resultados obtidos neste trabalho. Para fins de visualização, apenas os modelos IEEE-DM, ESM-ePL-KRLS e SODA-FIS-PSO são mostrados.

A Tabela 3 apresenta os resultados dos testes MGN (Harvey et al., 1997) para dois conjuntos de dados: ESM-ePL-KRLS e SODA-FIS-PSO. Dessa forma, é possível observar que ambas simulações baseadas no modelo proposto apresentaram uma precisão estatisticamente melhor que o ESM-ePL-KRLS.

Tabela 3. Resultados dos testes MGN entre os modelos ESM-ePL-KRLS e SODA-FIS-PSO.

Conjunto de dados	MGN	p -valor
1	170,5821	0,0000
2	13,2185	0,0000

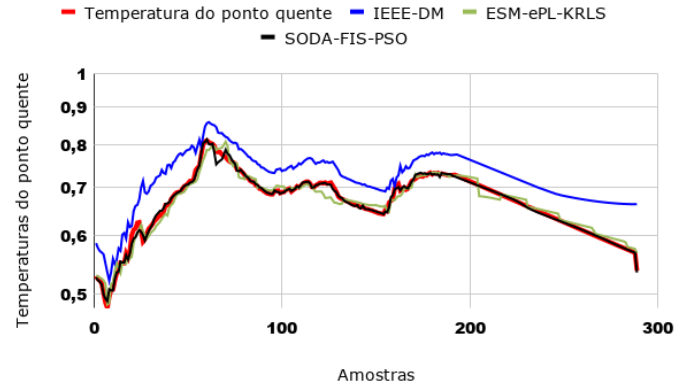


Figura 5. Estimação de ponto quente, conjunto de dados 1 normalizado. Transformador sem sobrecarga. Escala logarítmica.

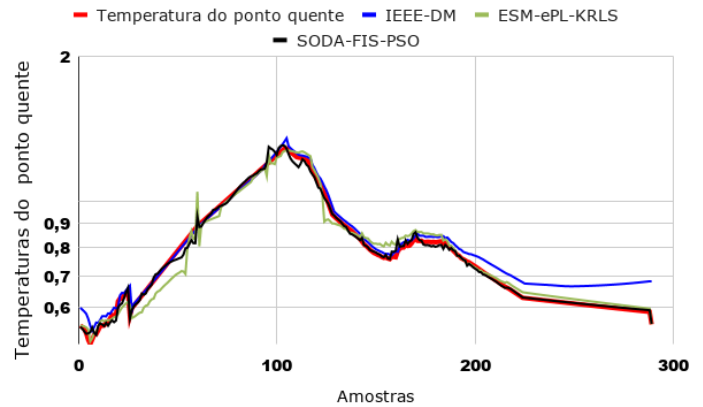


Figura 6. Estimação de ponto quente, conjunto de dados normalizado. Transformador com sobrecarga. Escala logarítmica.

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 SODA-FIS-PSO. 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 ESM-ePL-KLRS, foram apresentados os resultados dos teste estatístico.

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, minimizar superdimensionamentos 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, pretende-se gerar uma variação do algoritmo SODA aliando a robustez deste algoritmo com o agrupamento *fuzzy* presente no FCM, 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.

AGRADECIMENTOS

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.

REFERÊNCIAS

- 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.
- Angelov, P. (2014). Outside the box: an alternative data analytics framework. *Journal of Automation Mobile Robotics and Intelligent Systems*, 8(2), 29–35.
- Angelov, P., Gu, X., and Kangin, D. (2017a). Empirical data analytics. *International Journal of Intelligent Systems*, 32(12), 1261–1284.
- Angelov, P., Gu, X., and Príncipe, J.C. (2017b). A generalized methodology for data analysis. *IEEE transactions on cybernetics*, (99), 1–13.
- 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.
- Gu, X., Angelov, P., Kangin, D., and Principe, J. (2018). Self-organised direction aware data partitioning algorithm. *Information Sciences*, 423, 80–95.
- Harvey, D., Leybourne, S., and Newbold, P. (1997). Testing the equality of prediction mean squared errors. *International Journal of forecasting*, 13(2), 281–291.
- 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.
- Kennedy, J. (1995). Eberhart, r.: Particle swarm optimization. In *Proceedings of IEEE international conference on neural networks*, volume 4, 1942–1948. IEEE Press.
- 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. P. Filev, N.K. (2010). *Evolving Intelligent Systems: Methodology and Applications*. Wiley, IEEE Press.
- Panigrahi, B., Pandi, V.R., and Das, S. (2008). Adaptive particle swarm optimization approach for static and dynamic economic load dispatch. *Energy conversion and management*, 49(6), 1407–1415.
- Rosendo, M. (2010). Um algoritmo de otimização por nuvem de partículas para resolução de problemas combinatórios.
- 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.
- Takagi, T. and Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. *IEEE transactions on systems, man, and cybernetics*, (1), 116–132.
- 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.