

HEALTH INDEX PARA TRANSFORMADORES DE POTÊNCIA USANDO INTELIGÊNCIA DE ENXAME

RAMON ALVES DOS SANTOS*, NADIA NEDJAH*, LUIZA DE MACEDO MOURELLE*, LEONARDO TORRES BISPO DOS SANTOS†

**R. São Francisco Xavier, 524 - 5145F - Maracanã - 20550-900
Universidade do Estado do Rio de Janeiro (UERJ)
Rio de Janeiro, RJ, Brasil*

†*Av. Horácio Macedo, 354 - Cidade Universitária - 21941-911
Centro de Pesquisa de Energia Elétrica (CEPEL)
Rio de Janeiro, RJ, Brasil*

Emails: ramon.alves.rj@gmail.com, nadia@eng.uerj.br, ldmm@eng.uerj.br,
ltorres@cepel.br

Abstract— The evaluation of the operational state of power transformers is an essential stage for a maintenance of the electric power supply, becoming necessary in the last years prioritization of assets, due to the scarcity of resources and a difficulty of disconnection. This work presents a new proposal for the classification and prioritization of high power transformers, performing the composition of the Health Index with Swarm Intelligence, aiming to bring an easy-to-use tool with high flexibility and precision.

Keywords— Classification, Prioritization, Power Transformer, Swarm Intelligence.

Resumo— A avaliação do estado operacional de transformadores de potência é um estágio essencial para a manutenção do fornecimento de energia elétrica, tornando necessário nos últimos anos a priorização de ativos, devido à escassez de recursos e à dificuldade de desconexão. Este trabalho apresenta uma nova proposta para a classificação e priorização de transformadores de alta potência, realizando a composição do *Health Index* com Inteligência de Enxame, objetivando trazer uma ferramenta simples, altamente flexível e precisa.

Palavras-chave— Classificação, Priorização, Transformadores de Potência, Inteligência de Enxame.

1 Introdução

Transformadores de potência são os equipamentos instalados em subestações com maior importância, correspondendo a cerca de 60% do capital investido (Jahromi et al., 2009). O setor elétrico brasileiro, de acordo com os relatórios indicadores de desempenho do SIN (Sistema Interligado Nacional) disponibilizados pelo ONS (Operador Nacional do Sistema), nos anos de 2012 e 2015, mostram um aumento ascendente no indicador de perturbações na rede básica, tendo uma redução de 1.57% no ano de 2016, mas, ainda assim, mantendo um número total de 3201 perturbações (ONS, 2017).

A falha de ativos de alta potência pode ser desastrosa e resultar em custos diretos e indiretos para os setores industrial, comercial e residencial (Wang et al., 2002), além de ter um efeito negativo sobre a vida social dos usuários de energia elétrica (Abu-Elanien and Salama, 2010). Dessa maneira, uma interrupção no fornecimento de energia elétrica por vezes sequer pode ter seus prejuízos totalmente mensurados, podendo superar o valor de investimento no ativo. Com isso, fatores relacionados à condição e confiabilidade operacional do ativo, são pontos de extrema importância para o aumento da robustez da rede.

Com o objetivo de verificar o estado operacional de ativos de alta potência, diversos equipamentos, procedimentos e metodologias surgem.

Todavia, com uma grande quantidade de métodos de avaliação do equipamento, por vezes, cai-se em certas contradições entre resultados advindos de diferentes ensaios, não sendo trivial uma composição entre estes, a fim de ser obtida a condição operacional do equipamento. Neste cenário, surgem abordagens, com a utilização de metodologias baseadas no *Health Index*.

O *Health Index* é uma metodologia, a qual busca a composição de diversos ensaios, necessários à verificação da condição operacional do transformador, objetivando ao fim um índice numérico, o qual representará a condição do ativo e permitirá estabelecer uma priorização.

A composição do índice é tradicionalmente dependente de especialistas, os quais atribuem pontuações para os resultados advindos de ensaios elétricos, químicos e físicos do equipamento. Estabelecendo em seguida, para cada fator avaliado, pesos, os quais ponderam os resultados, compondo através de um somatório, um valor numérico que indicará o estado operacional do equipamento, sendo este valor utilizado para o ranqueamento do conjunto de ativos em uma subestação. Entretanto, não se tem um consenso entre autores na composição dos pesos, fator que limita a composição do *Health Index* com uma abordagem abrangente, na qual fatores como a potência de uma família de equipamentos não interfiram de forma preponderante na composição do índice.

Observando a importância de se ter meios de compor diversos ensaios, estabelecer a condição operacional do equipamento e, por conseguinte, estabelecer uma priorização entre um conjunto de ativos, os quais nem sempre compartilham as mesmas características em uma subestação, entende-se como uma oportunidade o desenvolvimento de uma ferramenta com uma abordagem mais genérica.

O objetivo deste trabalho é contribuir não só com uma nova abordagem do problema de classificação e ranqueamento dos ativos de alta potência, mas também da exploração de técnicas de inteligência de enxame como *PSO (Particle Swarm Intelligence)* e *EHO (Elephant Herding Optimization)* aplicado a *Health Index*. Observando que esta área da inteligência computacional sofreu intenso desenvolvimento e exploração nos últimos 20 anos com algoritmos de inspiração biológica.

Nas próximas seções serão abordados os principais algoritmos utilizados neste projeto para o desenvolvimento da solução e comparação de desempenho; as características avaliadas para composição do índice; o método proposto para o problema de priorização e ranqueamento; os resultados alcançados, conclusões e agradecimentos.

2 Algoritmos

Para resolver os mais diversos problemas de engenharia, os sistemas baseados em inteligência computacional têm sido amplamente aplicados nos últimos anos, seja em *software* e - ou *hardware*. Nesta seção, estão presentes os principais algoritmos utilizados neste trabalho, sendo os algoritmos baseados em inteligência de enxame utilizados para proposta de um novo método e os algoritmos tradicionais utilizados para comparação do desempenho alcançado. Os algoritmos implementados terão descritos seus parâmetros, podendo ser apreciados na íntegra nas referências originais contidas em cada uma das subseções abaixo.

2.1 Otimização por Enxame de Partículas

O algoritmo de otimização por enxame de partículas é um método desenvolvido por Kennedy e Eberhart em 1995 (Kennedy and Eberhart, 1995), usado para resolução de problemas np-hard, onde nenhuma solução adequada é encontrada com métodos tradicionais, não sendo necessárias grandes especificações do problema.

Neste algoritmo, cada partícula do enxame representa uma possível solução para o problema, sendo a estratégia de movimentação das partículas em um espaço de busca n-dimensional, baseada no comportamento social de um bando de pássaros e cardume de peixes. Fazendo a seleção da melhor solução através de uma função de aptidão, que deve ser modelada para cada problema, de modo

que a partícula que apresenta uma boa solução para o problema físico receba uma boa avaliação no algoritmo. Cada partícula é então influenciada pelo processo de aprendizagem cognitivo e social em cada iteração, direcionando assim as partículas para regiões promissoras até que um critério de parada seja alcançado como o número máximo de iterações ou um determinado valor de aptidão para a solução ótima local.

Como parâmetros para este algoritmo foram definidos os seguintes valores: termo de inércia (ω)=1; termo cognitivo (φ_1)=1,5; termo social (φ_2)=2; velocidade máxima de exploração=0,5; posição máxima da partícula=1; posição mínima da partícula=0; número de indivíduos=10, 20, 50 e 100; e número máximo de iterações=100 e 1000.

2.2 Otimização por Manada de Elefantes

O método de otimização por manada de elefantes é um método recente de inteligência de enxame apresentado no ano de 2015 (Wang et al., 2015). O algoritmo tem sua proposta focada na busca de soluções ótimo globais em espaços de busca n-dimensional, com sua implementação inspirada no comportamento social de elefantes asiáticos e africanos.

Na natureza, os elefantes da manada se movem sob a orientação da matriarca e os elefantes machos que entram na fase adulta abandonam o grupo. Para representar esse comportamento artificialmente, dois operadores principais são propostos no algoritmo: um operador de agregação, responsável pela atualização da posição de cada indivíduo da manada; e um operador de separação, responsável pela substituição da pior solução dos elefantes artificiais por uma nova solução. Sendo que, na manada artificial, a melhor solução em cada geração representa a matriarca e a pior solução o elefante macho adulto.

A matriarca, tem sua movimentação ao redor do centro da manada, não se afastando abruptamente do grupo. Ocorrendo a avaliação da aptidão das soluções dadas por cada indivíduo, sendo atualizado após o processo de movimentação a matriarca e o elefante macho adulto artificial a cada geração. Finalmente, após um número máximo de gerações o algoritmo apresentará as matriarcas artificiais de cada clã, na qual a mais apta será a solução global para o problema.

Para este algoritmo foram definidos os seguintes parâmetros: número de clãs=número de matriarcas=1; fator de escala (α)=0,9; fator beta (β)=0,3; número de elefantes=10, 20, 50 e 100; e número máximo de gerações=100 e 1000.

2.3 Algoritmos Genéticos

Algoritmos genéticos consistem em uma técnica de otimização, inspirada no princípio darwiniano de seleção natural e reprodução genética,

apresentado em 1975 por John Henry Holland (Holland, 1975).

De acordo com a teoria darwiniana, o princípio da seleção privilegia os indivíduos mais aptos, portanto, com maior probabilidade de reprodução. Os códigos genéticos constituem a identidade de cada indivíduo representado nos cromossomos. Esses princípios são usados em algoritmos genéticos, os quais buscam a melhor solução para um determinado problema, através da evolução de populações de soluções codificadas através de cromossomos artificiais.

O cromossomo artificial é uma estrutura de dados que representa o indivíduo como uma das possíveis soluções do espaço de busca do problema. Esses cromossomos são então submetidos a um processo evolutivo que envolve a avaliação da aptidão, seleção, cruzamento e mutação de cada indivíduo. Após várias gerações de evolução, a população deve conter o mesmo número de indivíduos, mas com a presença dos mais aptos.

Para este algoritmo foram definidos os seguintes parâmetros: taxa de cruzamento=0,8; taxa de mutação=0,3; número de indivíduos=10, 20, 50 e 100; e número máximo de gerações=100 e 1000. O método roleta foi utilizado como método de seleção de indivíduos e a representação dos cromossomos artificiais foi definida como real.

2.4 Redes Neurais Artificiais

O primeiro modelo de neurônio artificial foi proposto por Warren McCulloch e Walter Pitts em 1943 (McCulloch and Pitts, 1943). Sendo o neurônio artificial a unidade de processamento fundamental para a operação de uma rede neural, que traz benefícios como: a possibilidade de trabalhar com modelos não-lineares; mapeamento de entrada-saída; adaptabilidade; resposta a evidências; tolerância a falhas; possibilidade de implementação de *VLSI* (*very-large-scale-integration*); uniformidade de análise e projeto; e analogia neurológica (Haykin, 1994).

Redes neurais artificiais, são modelos de inteligência computacional fechados do tipo "caixa preta", reconhecidos pela capacidade de generalizar e extrair padrões complexos, tendo o cérebro humano como inspiração natural. Usando redes de neurônios artificiais, para extração do conhecimento através de um treinamento com padrões conhecidos, onde após sua execução é possível inserir padrões semelhantes ou mesmo desconhecidos, inferindo à rede uma resposta, como no processo de aprendizagem de um ser humano.

2.5 Sistema de Inferência Fuzzy

O conceito de Sistema de Inferência Fuzzy foi introduzido por Lotfi Zadeh em 1965 (Zadeh, 1965), com a formalização dos princípios de conjuntos com graus de pertinência estabelecidos por Jan

Lukasiewicz em 1920, associados aos conceitos de lógica aristotélica clássica.

Sistemas de Inferência Fuzzy permitem a transformação de sinais de entrada precisos em conjuntos de entradas *fuzzy*, guiados por variáveis linguísticas, nos quais graus de pertinência são atribuídos. Através de um processo de inferência com um conjunto de regras bem definido, é estabelecida uma relação de causa e efeito entre as variáveis linguísticas de entrada e saída. Composto por um processo de defuzzificação, um valor de saída preciso.

3 Características Avaliadas

O método proposto neste artigo é alcançado utilizando dados reais de 48 transformadores. Esses dados estão disponíveis em uma base de dados pública, a qual além das características avaliadas neste trabalho, possuem um ranqueamento realizado por especialistas. O conteúdo destes trabalhos estão disponíveis em periódicos e anais de conferência (Abu-Elanien et al., 2012)-(Cerón et al., 2015)-(Chacón-Troya et al., 2017).

Para a caracterização dos transformadores, são utilizados seis ensaios de análise de qualidade do óleo isolante apresentados por: teor de concentração de umidade, acidez, tensão de ruptura, fator de dissipação, grau de concentração de gases combustíveis dissolvidos em óleo e análise do teor de 2-furfuraldeído.

3.1 Concentração de umidade

Durante o processo de fabricação, os transformadores têm como padrão a variação da concentração de umidade no isolamento de 0,5% a 1%, ocorrendo o aumento da concentração de umidade com a degradação do isolamento ou comunicação com a atmosfera (Standard et al., 2013). Os padrões IEC 60814 e ASTM D1533 com o método de titulação de Karl Fisher determinam as metodologias para avaliar o teor de umidade, sendo comumente administrado em ppm (partes por milhão) ou $\mu\text{l/l}$ (Lewand, 2002). A determinação deste teste tem grande importância, uma vez que a concentração de umidade é um dos principais fatores que aceleram o processo de envelhecimento, reduzindo a capacidade dielétrica do isolamento sólido e líquido.

3.2 Acidez

A produção de ácidos no isolamento de transformadores de potência resulta do processo de oxidação, onde os hidrocarbonetos presentes no óleo reagem com o ar dissolvido, gerando ácidos carboxílicos (Erdman, 1988). A concentração de ácidos no transformador é medida por titulação química padronizada pela IEC 62021-1, IEC 62021-2 e ASTM D1534; a medida é dada em mg de

KOH/g (International, 2012). O aumento da concentração de ácido no óleo isolante ocorre com períodos prolongados de sobrecarga, sendo uma indicação do processo de deterioração do isolamento sólido (Wahab et al., 1999) -(Lundgaard et al., 2004).

3.3 Tensão de Ruptura

A tensão de ruptura é uma medida para verificar a capacidade da suportabilidade dielétrica do óleo isolante, apresentando valores significativamente altos quando o óleo está sem a presença de contaminantes, como água e partículas sólidas (Standard et al., 2013). Os testes são realizados de acordo com IEC 60156 e ASTM D1816, verificando a tensão de ruptura da amostra de óleo em ambientes com temperatura controlada de 20 ° a 30 °C, com uma diferença entre os eletrodos de 1mm (Standard et al., 2013). O objetivo do teste é verificar a presença de baixa resistência dielétrica no óleo, o que pode levar ao aumento das descargas parciais, acelerando o processo de envelhecimento do transformador (Abu-Elanien et al., 2012).

3.4 Fator de dissipação ($\tan\delta$)

A verificação do fator de dissipação visa quantificar o nível de energia perdida no transformador durante a operação (Abu-Elanien et al., 2012). O teste é realizado de acordo com a norma IEC 60247, sendo importante verificar a dissipação de energia do óleo isolante, uma vez que se encontra na forma de dissipação de calor, o que acelera o processo de envelhecimento do ativo.

3.5 Análise de Gases Dissolvidos em Óleo Isolante

A determinação da concentração de gases combustíveis é um dos testes mais importantes, responsável por indicar a evolução dos gases, que no processo de operação normal de um transformador já existem, no entanto, com o aumento de sua concentração pode se tornar um indicativo de falha ou envelhecimento do ativo (Abu-Elanien and Salama, 2010). As avaliações podem ser realizadas através de critérios tradicionais, como as relações gasosas de Rogers, Dornenburg, Triângulo de Duval, Critério CEGB, Método Laborelec, entre outros. Estes métodos caracterizam os tipos de falhas dentro dos transformadores pela concentração de gases chave, todavia, utilizando neste trabalho a concentração total dos gases H_2 , CH_4 , C_2H_4 , C_2H_2 e C_2H_6 para determinar a condição operacional (Abu-Elanien et al., 2012).

3.6 Análise de 2-Furfuraldeído

A análise da concentração 2-furfuraldeído visa realizar a avaliação da condição do isolamento sólido do equipamento (Kachler and Hohlein, 2005)-(Pradhan and Ramu, 2004) e (Van Bolhuis et al., 2002)-(Emsley et al., 2000). Esta técnica é responsável por medir a concentração de cadeias de aldeídos no óleo isolante. Por sua vez, a degradação das cadeias de aldeídos, são o resultado do processo de envelhecimento do papel isolante. O aumento da concentração de aldeídos no óleo isolante indica a perda de propriedades mecânicas do papel, gerando uma situação favorável ao aumento de descargas parciais e aceleração do processo de envelhecimento do ativo.

4 Método Proposto

Com base nos ensaios realizados em cada transformador e nos diagnósticos, foi estabelecido um modelo que pode ser tratado em três etapas: pré-processamento dos dados, processo de otimização e validação da solução encontrada.

Os dados de entrada foram separados de forma randomica em dois grupos: dados para processo de otimização dos pesos do *Health Index* e dados para validação. Realizando em uma primeira etapa o pré-processamento dos dados, no qual a normalização das características é realizada com base no desvio padrão dos resultados de cada ensaio. Não utilizando métodos de seleção de características neste trabalho, pela capacidade dos algoritmos utilizados buscarem o conjunto pesos ótimos (w) para ponderar a pontuação (*Score-S*) obtida com os diagnósticos de cada característica (i), minimizando inclusive os valores de ponderação de características menos significativas para composição do índice, realizando a ponderação até o número máximo de características disponíveis(n).

Após o pré-processamento, as técnicas de inteligência computacional são implementadas, sendo a proposta deste trabalho a utilização de técnicas baseadas em inteligência de enxame (Otimização por Enxame de Partículas e Otimização por Manada de Elefantes) e para comparação Algoritmos Genéticos, o qual foi viável ser implementado. Buscando com essas técnicas, o conjunto de pesos ótimos utilizados na Eq. 1 para a composição do *Health Index*.

$$HI = \frac{\sum_{i=1}^n S_i w_i}{\sum_{i=1}^n w_i} \quad (1)$$

Cada indivíduo presente nos algoritmos de otimização apresentará um vetor de pesos para a composição do *Health Index*, estas soluções serão aplicadas em um conjunto de ativos conhecidos, cada solução apresentando um valor de aptidão de acordo com a aproximação com a priorização

estabelecida pelos especialistas dos trabalhos, dos quais utilizou-se o conjunto de dados como referência. Com a solução alcançada, o processo de validação será realizado com parte dos transformadores não utilizados no processo de otimização.

No processo de construção do *Health Index*, os ativos foram classificados em três classes de criticidade: bons, medianos e ruins. Estabelecendo após análise dos trabalhos utilizados como referência, intervalos para valores pós-composição, onde ativos ruins são equipamentos que apresentam índice variando de 0,75-1; equipamentos com condição operacional mediana entre 0,45-0,75; e ativos com bons entre 0-0,45.

O processo de otimização foi realizado com número máximo limitado de 100 iterações em uma primeira etapa (caso 1 - c1) e 1000 iterações em uma segunda (caso 2 - c2), visando verificar, com o aumento do número de iterações, o comportamento dos algoritmos, bem como a possibilidade de obter melhores resultados com maior tempo para o processo de busca de uma solução.

Os respectivos experimentos foram repetidos para cada algoritmo 500 vezes, variando o número de indivíduos (NI) em: 10, 20, 50 e 100. Neste processo, foi realizada uma variação da quantidade de dados, verificando se com um conjunto de dados menor uma boa solução era alcançada no processo de busca. Estabelecendo como relações de dados para o processo de otimização e posterior validação as razões: 26-22 (54,2%-45,8%) e 30-18 (62,5%-37,5%) transformadores; observando estas relações serem interessantes pelo tamanho do conjunto de dados utilizado apresentando resultados expressivos.

Ao fim do processo de otimização e validação da solução, verificando todas as etapas inseridas acima, os pesos ideais são encontrados.

5 Resultados

Após a proposta do método inicial, foi realizada uma comparação entre as técnicas, a fim de ter uma visão geral de quais das técnicas implementadas se mostrava mais eficiente em termos de acurácia, tempo de convergência, tamanho da população e relação de dados necessária para convergir para uma solução adequada.

A comparação de modelos baseados em redes neurais (Abu-Elanien et al., 2011) e sistema de inferência fuzzy (Abu-Elanien et al., 2012) com o modelo proposto neste trabalho, ocorreu apenas sob acurácia por estes não apresentarem os subsídios necessários à reprodução dos resultados.

Os resultados das implementações são apresentados abaixo em duas sequências. A primeira é realizada com a divisão do banco de dados com 54,2% dos transformadores para otimização e 45,8% para validação, trazendo diferentes configurações quanto ao números de indivíduos(NI) e

número máximo de iterações(c1 e c2), para os três algoritmos implementados: PSO, EHO e GA. Os valores apresentados são médios tanto para acurácia como para o tempo de convergência, apresentando os respectivos valores de desvio padrão.




Figura 1: Acurácia média (%), usando 54,2% dos dados para otimização e 45,8% para validação com número máximo de 100 iterações.




Figura 2: Acurácia média (%), usando 54,2% dos dados para otimização e 45,8% para validação com número máximo de 1000 iterações.

Tabela 1: Acurácia média (%), usando 54,2% dos dados para otimização e 45,8% para validação.

NI	PSO		EHO		GA	
	c1(%)	c2(%)	c1(%)	c2(%)	c1(%)	c2(%)
10	89.87	91.61	99.19	100	74.11	86.21
20	92.58	93.44	99.82	100	78.23	93.19
50	92.78	93.43	99.98	100	82.81	94.55
100	93.45	93.15	99.95	100	86.31	94.79

Tabela 2: Desvio padrão(σ) dos valores encontrados para acurácia média, usando 54,2% dos dados para otimização e 45,8% para validação.

NI	PSO		EHO		GA	
	c1(%)	c2(%)	c1(%)	c2(%)	c1(%)	c2(%)
10	8.79	7.44	3.03	0.00	10.49	11.47
20	6.66	4.97	1.37	0.00	10.08	6.44
50	5.01	4.21	0.29	0.00	10.18	4.04
100	4.30	4.17	0.45	0.00	10.37	3.60




Figura 3: Tempo de convergência médio (s), usando 54,2% dos dados para otimização e 45,8% para validação com número máximo de 100 iterações.




Figura 4: Tempo de convergência médio (s), usando 54,2% dos dados para otimização e 45,8% para validação com número máximo de 1000 iterações.

Tabela 3: Tempo de convergência médio (s), usando 54,2% dos dados para otimização e 45,8% para validação.

NI	PSO		EHO		GA	
	c1(s)	c2(s)	c1(s)	c2(s)	c1(s)	c2(s)
10	1.21	13.11	0.68	0.59	2.12	13.24
20	2.48	24.65	1.64	0.92	3.96	21.92
50	5.94	59.50	3.68	1.97	6.91	98.99
100	11.78	187.69	3.81	4.84	16.59	176.10

Tabela 4: Desvio padrão(σ) do tempo de convergência médio (s), usando 54,2% dos dados para otimização e 45,8% para validação.

NI	PSO		EHO		GA	
	c1(s)	c2(s)	c1(s)	c2(s)	c1(s)	c2(s)
10	0.27	4.87	0.42	0.58	0.17	3.93
20	0.84	9.24	0.86	0.67	0.24	12.85
50	1.73	26.41	1.79	0.92	0.79	26.96
100	4.54	65.13	1.81	2.29	2.20	82.99

De modo a verificar a obtenção de melhores resultados, foi aumentado para 62,5% a quantidade de dados presente no processo de otimização, repetindo a metodologia aplicada na etapa anterior, podendo os resultados serem observados abaixo.




Figura 5: Acurácia média (%), usando 62,5% dos dados para otimização e 37,5% para validação com número máximo de 100 iterações.




Figura 6: Acurácia média (%), usando 62,5% dos dados para otimização e 37,5% para validação com número máximo de 1000 iterações.

Tabela 5: Acurácia média (%), usando 62,5% dos dados para otimização e 37,5% para validação.

NI	PSO		EHO		GA	
	c1(%)	c2(%)	c1(%)	c2(%)	c1(%)	c2(%)
10	89.72	92.08	98.74	100.00	70.67	85.67
20	92.74	94.71	99.28	100.00	76.32	93.72
50	93.94	94.34	99.98	100.00	82.37	96.37
100	94.78	94.84	99.97	100.00	84.59	96.80

Tabela 6: Desvio padrão(σ) da acurácia média (%), usando 62,5% dos dados para otimização e 37,5% para validação.

NI	PSO		EHO		GA	
	c1(%)	c2(%)	c1(%)	c2(%)	c1(%)	c2(%)
10	11.07	9.55	4.08	0.00	10.68	12.82
20	8.17	6.10	3.17	0.00	11.48	8.61
50	7.32	6.13	0.35	0.00	11.66	4.11
100	6.12	4.90	0.43	0.00	11.85	3.93




Figura 7: Tempo de convergência médio(s), usando 62,5% dos dados para otimização e 37,5% para validação com número máximo de 100 iterações.




Figura 8: Tempo de convergência médio(s), usando 62,5% dos dados para otimização e 37,5% para validação com número máximo de 1000 iterações.

Tabela 7: Tempo de convergência médio(s), usando 62,5% dos dados para otimização e 37,5% para validação.

NI	PSO		EHO		GA	
	c1(s)	c2(s)	c1(s)	c2(s)	c1(s)	c2(s)
10	1.20	9.61	1.09	1.12	1.55	13.11
20	3.01	16.81	1.04	1.83	2.88	31.15
50	4.78	41.78	2.01	3.90	6.88	38.93
100	14.24	86.21	7.26	4.15	13.45	69.38

Tabela 8: Desvio padrão(σ) do tempo de convergência médio(s), usando 62,5% dos dados para otimização e 37,5% para validação.

NI	PSO		EHO		GA	
	c1(s)	c2(s)	c1(s)	c2(s)	c1(s)	c2(s)
10	0.45	5.92	0.71	1.39	0.15	5.01
20	1.31	11.76	0.65	2.41	0.40	18.04
50	2.48	28.55	1.04	2.45	1.05	28.05
100	8.54	56.24	3.67	5.01	2.09	57.66

Buscando a comparação da metodologia proposta, foi encontrado na literatura trabalhos, os quais realizavam a composição do *Health Index* com abordagens semelhantes a proposta deste trabalho, porém utilizando métodos de inteligência computacional distintos.

O primeiro destes utiliza redes neurais artificiais, atingindo com uma rede MLP (*Multilayer Perceptron*) uma acurácia de 96,55% no ranqueamento de um grupo de ativos conhecidos (Abu-Elanien et al., 2011), não exibindo, todavia, o tempo necessário para treinamento nem disponibilizando os subsídios necessários a sua reprodução.

A segunda referência é baseada em um modelo utilizando sistemas de inferência fuzzy estruturado no máximo-mínimo de Mamdani, com um conjunto de 33 regras e única saída, atingindo uma acurácia de 96,7% (Abu-Elanien et al., 2012).

6 Conclusões

O método proposto apresenta bons resultados em relação aos objetivos deste trabalho e traz como contribuição para a comunidade acadêmica o uso de inteligência de enxame na priorização de ativos de alta potência.

Com os resultados alcançados, observa-se que sistemas baseados em inteligência de enxame apresentam boas soluções para o problema de priorização de ativos de alta potência com alto grau

de acurácia, estabelecendo um conjunto de pesos com a metodologia proposta baseado no comportamento físico do grupo de ativos conhecidos.

Vale ressaltar que o tempo de convergência para resultados com inteligência de enxame se mostrou menor em comparação com outros métodos de otimização utilizados neste trabalho, observando que a implementação com o algoritmo EHO provou ser muito eficiente e adequada para resolver o problema, superando as implementações com PSO e GA, obtendo acurácia média igual a 100 % e tempo de convergência médio inferior a 1s nos melhores resultados encontrados.

Quanto à relação de dados para otimização da solução e validação, verificou-se, que mesmo com uma quantidade inferior de dados para busca dos pesos, algoritmos baseados em inteligência de enxame apresentaram boas soluções para o problema apresentado neste trabalho.

Com o aumento do tamanho da população nos algoritmos, observou-se uma ligeira melhoria nos resultados. Apresentando, todavia, boas soluções mesmo com o número de indivíduos reduzidos, gerando como benefício uma queda no custo computacional e tempo de processamento dos algoritmos.

Com relação ao sistema comparado, verificou-se que sobre o método de otimização tradicional (Algoritmo Genético) o método proposto consegue alcançar melhores valores de acurácia e tempo de convergência.

Observando que o método proposto supera o modelo baseado em sistemas de inferência fuzzy por esse ser composto por cerca de 33 regras, tendo uma alta dependência do especialista, notando que numa possível expansão do número de características avaliadas, um conjunto de regras completamente novo e a associação entre elas deverá ser estudado e definido pelo especialista, acarretando uma dependência e portanto perda de flexibilidade.

No modelo o qual utiliza-se redes neurais artificiais, a estrutura da rede tem um grau de complexidade mais elevado tornando-a um modelo onde se torna de difícil exposição a mecânica de definição da sua estrutura para um conjunto de *stakeholders* envolvidos pouco habituados com técnicas de inteligência computacional. Além do processo de treinamento ser extremamente sensível à quantidade e qualidade do conjunto de dados, convergindo o modelo proposto neste trabalho para uma estrutura simples com um vetor de pesos para ponderação das características avaliadas de simples explicação e exposição.

Agradecimentos

À Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) por fornecer o suporte necessário à publicação deste trabalho.

Referências

- Abu-Elanien, A. E. and Salama, M. (2010). Asset management techniques for transformers, *Electric power systems research* **80**(4): 456–464.
- Abu-Elanien, A. E., Salama, M. and Ibrahim, M. (2011). Determination of transformer health condition using artificial neural networks, *Innovations in Intelligent Systems and Applications (INISTA), 2011 International Symposium on*, IEEE, pp. 1–5.
- Abu-Elanien, A. E., Salama, M. and Ibrahim, M. (2012). Calculation of a health index for oil-immersed transformers rated under 69 kv using fuzzy logic, *IEEE Transactions on Power Delivery* **27**(4): 2029–2036.
- Cerón, A. F., Echeverry, D. F., Aponte, G. and Romero, A. A. (2015). Índice de salud para transformadores de potencia inmersos en aceite mineral con voltajes entre 69kv y 230kv usando lógica difusa, *Información tecnológica* **26**(2): 107–116.
- Chacón-Troya, D. P., Lata, J. P. and Medina, R. D. (2017). Health index assessment for power transformers with thermal upgraded paper up to 230kv, using fuzzy inference. part ii: A sensibility analysis, *Devices, Circuits and Systems (ICCDCS), 2017 International Caribbean Conference on*, IEEE, pp. 109–112.
- Emsley, A., Xiao, X., Heywood, R. and Ali, M. (2000). Degradation of cellulosic insulation in power transformers. part 3: Effects of oxygen and water on ageing in oil, *IEE Proceedings-Science, Measurement and Technology* **147**(3): 115–119.
- Erdman, H. G. (1988). *Electrical insulating oils*, Vol. 998, ASTM International.
- Haykin, S. (1994). *Neural networks: a comprehensive foundation*, Prentice Hall PTR.
- Holland, J. (1975). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*, University of Michigan Press.
- International, A. (2012). *Standard Test Method for Acid and Base Number by Color-indicator Titration*, ASTM International.
- Jahromi, A., Piercy, R., Cress, S., Service, J. and Fan, W. (2009). An approach to power transformer asset management using health index, *IEEE Electrical Insulation Magazine* **25**(2): 20–34.
- Kachler, A. J. and Hohlein, I. (2005). Aging of cellulose at transformer service temperatures. part 1: Influence of type of oil and air on the degree of polymerization of pressboard, dissolved gases, and furanic compounds in oil, *IEEE Electrical Insulation Magazine* **21**(2): 15–21.
- Kennedy, J. and Eberhart, R. (1995). Particle swarm optimization, *Neural Networks, 1995. Proceedings., IEEE International Conference on*, Vol. 4, pp. 1942–1948 vol.4.
- Lewand, L. (2002). Understanding water in transformer systems, *Neta World* pp. 1–4.
- Lundgaard, L. E., Hansen, W., Linhjell, D. and Painter, T. J. (2004). Aging of oil-impregnated paper in power transformers, *IEEE Transactions on power delivery* **19**(1): 230–239.
- McCulloch, W. S. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics* **5**(4): 115–133.
- ONS (2017). Indicadores de desempenho do sin, <http://ons.org.br/>. Acessado em 28-11-2017.
- Pradhan, M. and Ramu, T. (2004). Criteria for estimation of end of life of power and station transformers in service, *Electrical Insulation and Dielectric Phenomena, 2004. CEIDP'04. 2004 Annual Report Conference on*, IEEE, pp. 220–223.
- Standard, I. et al. (2013). Mineral insulating oils in electrical equipment—supervision and maintenance guidance, *BS EN 60422*.
- Van Bolhuis, J., Gulski, E. and Smit, J. (2002). Monitoring and diagnostic of transformer solid insulation, *IEEE Transactions on Power Delivery* **17**(2): 528–536.
- Wahab, M. A., Hamada, M., Zeitoun, A. and Ismail, G. (1999). Novel modeling for the prediction of aged transformer oil characteristics, *Electric Power Systems Research* **51**(1): 61–70.
- Wang, G. G., Deb, S. and d. S. Coelho, L. (2015). Elephant herding optimization, *2015 3rd International Symposium on Computational and Business Intelligence (ISCBI)*, pp. 1–5.
- Wang, M., Vandermaar, A. and Srivastava, K. D. (2002). Review of condition assessment of power transformers in service, *IEEE Electrical Insulation Magazine* **18**(6): 12–25.
- Zadeh, L. (1965). Fuzzy sets, *Information and Control* **8**(3): 338 – 353.