

# Estudo da Capacidade do Modelo de Histerese $L^2P$ em Emular o Modelo de Preisach

Moisés A. P. Borges\* Agêu A. dos Santos\*\*  
 Rennan S. de Araujo\*\* Felipe S. O. Costa\*\*  
 Wanys A. A. Rocha\*\*\* Omar A. C. Vilcanqui\*\*\*  
 Luiz A. L. de Almeida\*\*\*\*

\* Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal do ABC, SP, (e-mail: moises.borges@ufabc.edu.br).

\*\* Programa de Pós Graduação em Engenharia da Informação, Universidade Federal do ABC, SP, (e-mails: ageu.alves@ufabc.edu.br, rennan.araujo@ufabc.edu.br, oiwa.costa@ufabc.edu.br, wanys.rocha@docente.unip.br).

\*\*\* Centro de Ciências exatas e tecnológicas, Universidade Federal do ACRE, AC, (e-mail: omarchu@ufac.br).

\*\*\*\* Centro de Engenharia, Modelagem e ciências Sociais Aplicadas, Universidade Federal do ABC, SP, (e-mail: luiz.almeida@ufabc.edu.br).

**Abstract:** The Preisach model has been widely used for decades in the most diverse phenomena of hysteresis. However, both the implementation and estimation of parameters of this model are intricate and laborious. The purpose of this article is to study the ability of the Limiting Loop Proximity ( $L^2P$ ) model to properly emulate the Preisach hysteresis model. The  $L^2P$  model is an easy-to-implement and parameter-estimation alternative. Synthetic data are obtained from the Preisach model for a typical magnetic hysteresis. The objective is to estimate the parameters of the  $L^2P$  model, so that its hysteresis representation is as close as possible to the synthetic data of the Preisach model. To estimate the parameters, the *PSO* (Particle Swarm Optimization) method was chosen. Results of hysteresis curves are presented and the degree of similarity of both models is discussed.

**Resumo:** O modelo de *Preisach* já é amplamente utilizado há décadas nos mais diversos fenômenos de histerese. Todavia, tanto a implementação quanto a estimação de parâmetros deste modelo são intrincadas e trabalhosas. O propósito deste artigo é estudar a capacidade do modelo de proximidade ao laço principal (*Limiting Loop Proximity*) em emular apropriadamente o modelo de histerese de *Preisach*. O modelo  $L^2P$  é uma alternativa de fácil implementação e obtenção de parâmetros. Os dados sintéticos são obtidos a partir do modelo de *Preisach* para uma histerese magnética típica. O objetivo é estimar os parâmetros do modelo  $L^2P$ , de modo que se aproxime ao máximo dos dados sintéticos do modelo de *Preisach*. Para estimar os parâmetros foi escolhido o método *PSO* (*Particle Swarm Optimization*). Resultados das curvas de histerese são apresentados e o grau de similaridade de ambos os modelos é discutido.

*Keywords:* PSO;  $L^2P$  model; Preisach model; Hysteresis; Algorithm.

*Palavras-chave:* PSO; Modelo  $L^2P$ ; Modelo de Preisach; Histerese; Algoritmo.

## 1. INTRODUÇÃO

Descrever modelos computacionais que auxiliem na implementação de sistemas práticos é um objetivo encontrado com frequência em diversas pesquisas. No âmbito teórico, um primeiro passo para real aplicação prática é a utilização de dados sintéticos, por possuir proximidade com a metodologia experimental (Borges et al., 2019). Esta abordagem favorece o esclarecimento sobre muitas das incertezas em um estágio preliminar da pesquisa à medida em que avanços adicionais são obtidos. Desta forma, a simulação computacional é um passo importante para promover a

validação e o entendimento dos resultados (Ojeda et al., 2018).

Para a área de magnetização, a inserção de metodologias teóricas promoveu a implementação prática em diversas aplicações conhecidas no respectivo âmbito físico (Barradas-Berglind et al., 2019). Com isso, o estudo fenomenológico da histerese foi facilitado, principalmente devido à modelagem física e matemática proporcionada no início do século XX, fazendo uma abordagem de aproximação de valores para gerar a curva de histerese para os materiais ferromagnéticos (Stentjes et al., 2016).

A consolidação do modelo de histerese de Preisach (1935) possibilitou uma diversidade de pesquisas que relacionam o modelo à prática cotidiana, como os de Janičić et al. (2014) e os mais recentes de Chayratsami and Plett (2018) e Zhu et al. (2019) que trabalham baseados neste modelo para solucionar problemas distintos.

Com o avanço tecnológico, surgiram adaptações importantes na estrutura do modelo (processamento paralelo) com o intuito de melhorar o desempenho computacional. Consequentemente as simulações foram sendo valorizadas, dadas as dificuldades que atualmente são sanadas em custo de processamento. Em um proposta mais recente, de Almeida et al. (2003) constroem uma nova concepção de modelo que reduz a demanda de processamento e facilita a obtenção dos parâmetros.

O custo computacional reduzido auxiliou o desenvolvimento de rotinas mais elaboradas e sensíveis à modelagem da curva de histerese. Modelos que antes apresentavam problemas – devido aos elevados custos computacionais e a demanda de tempo – podem ser melhorados por meio de modificações na obtenção de parâmetros para geração de curvas de histereses próximas às dos modelos clássicos que as originaram (Tao et al., 2020).

O desenvolvimento de técnicas baseadas em algoritmos bio-inspirados possibilita uma nova forma de aproximação entre modelos computacionais distintos (Sibaliya, 2019). Desta forma, a estimação dos parâmetros do modelo  $L^2P$  utiliza o algoritmo *PSO* - *Particle Swarm Optimization*, que se baseia no comportamento social das abelhas para obter o menor erro médio quadrático entre os dados “experimentais” de Preisach e o modelo  $L^2P$  (Eberhart and Kennedy, 1995). A escolha do *PSO* é decorrente da estimação de parâmetros ser equivalente a um problema de otimização com vários mínimos locais, o que dificulta o uso de otimização convexa, como confirmado em Duan et al. (2017).

A utilização do enxame de partículas *PSO*, não impede que outros algoritmos de otimização ou diferentes técnicas possam ser desenvolvidas para este estudo. A finalidade não é comparar algoritmos de otimização e sim obter respostas visando emular o modelo de *Preisach* por meio do modelo  $L^2P$ , e com este propósito é utilizado o *PSO* como ferramenta.

O estudo e escolha do *PSO* nesta contribuição dentre outras técnicas de *Soft computing* existentes, ocorreu devido a algumas vantagens, como as citadas no trabalho de Solihin et al. (2010). Por exemplo, o *PSO* exige somente algumas poucas linhas de código para implementar o algoritmo. Vantagens adicionais, são que esta técnica de busca não usa a informação do gradiente, mas os valores da função objetivo, o que faz dele um algoritmo fácil de usar. E dependendo do *fitness* ele é computacionalmente barato, sabendo-se que as exigências de velocidade de memória e *CPU* são muito baixas.

Não exige uma forte hipótese inicial, a qual está presente em métodos determinísticos tais como linearidade, diferenciabilidade, convexidade ou a não existência de restrições com o objetivo de resolver o problema de forma eficiente. E finalmente a solução pouco depende das condições iniciais das partículas, o que pode ser uma grande vantagem no

projeto de problemas de engenharia baseados em abordagens de otimização.

Este trabalho propõe o desenvolvimento comparativo de curvas de histerese com o auxílio do algoritmo *PSO* para emular o modelo de Preisach usando o modelo  $L^2P$  e a observação das características das curvas de histerese geradas por meio de gráficos de histerese. Desta forma, uma avaliação do comportamento dos modelos será realizada.

O trabalho de Sousa et al. (2018) apresenta de maneira significativa a aplicação de *PSO* para a obtenção de curvas de histerese dentro do próprio modelo  $L^2P$  (de Almeida et al., 2003). A proposta mostra que há uma possibilidade de, com um determinado número de iterações, surgirem resultados de alta significância usando apenas o *PSO* para emular a solução representada em curva de histerese.

Este artigo apresenta um novo método para obtenção de dados para futuras previsões precisas de dispositivos eletromagnéticos de baixa frequência. Com esta abordagem o método realizado em Hussain and Lowther (2018), por exemplo, teria menor custo computacional. A comparação realizada com MEF (métodos de elementos finitos) em Hussain and Lowther (2018) não se faria necessária uma vez que o modelo  $L^2P$  com um número baixo de parâmetros como apresentado em Almeida et al. (2003) pode alcançar resultados próximos de maneira a satisfazer as necessidades exigidas nestas análises.

## 2. CONCEPÇÃO DO MODELO DE *PREISACH*

Para realizar estudos sobre o fenômeno da histerese, foram formulados vários modelos de histerese. Um dos modelos mais utilizados é o de Preisach (1935) em que é realizada por meio de variáveis físicas uma construção da curva de histerese em materiais ferromagnéticos.

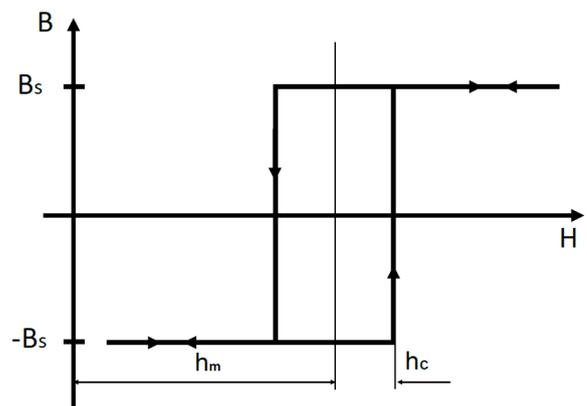


Figura 1. Característica de dipolo elementar proposto por *Preisach*, também chamado de hysteron

Analisando uma amostra de material ferromagnético Preisach (1935) observou que a magnetização era inerte, isto foi chamado por *Preisach* de *magnetische nachwirkung*, ou efeito colateral magnético, que foi caracterizado devido a saltos descontínuos na magnetização de um ferromagneto durante a varredura do campo magnético aplicado. Assim, para materiais ferromagnéticos, a teoria estabelece que estes são constituídos por pequenos dipolos que, como dito,

apresentam forma retangular e podem ser caracterizados por dois parâmetros,  $h_c$  representado na Figura 1 como a projeção ascendente da curva relacionada ao campo magnético como indicada na flecha e  $h_m$  que é a projeção descendente formando o laço principal que nesta forma tem representação retangular de um 'loop' de histerese, como pode ser visto na Figura 1.

A representação do modelo de *Preisach* pode ser explicada com a apresentação de um conjunto infinito de transdutores como caracterizadores de elementos de histerese (Figura 2). A disposição dos elementos  $G_1, G_2, \dots, G_n$  é representada na Figura 2, em que  $H$  é o campo aplicado representando a entrada do sistema e  $B$  (indução magnética) representa a saída do sistema.

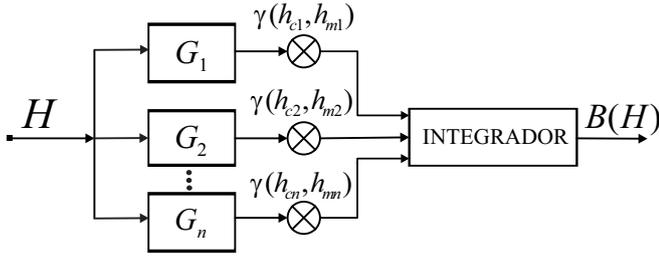


Figura 2. Descrição do modelo de *Preisach*

Os pontos  $(h_{c1}, h_{m1}), (h_{c2}, h_{m2})$  sucessivamente até  $(h_{cn}, h_{mn})$  são os formadores da curva de histerese e todos caracterizam a mesma pela aplicação do integrador. As condições para a inversão da curva são dadas de acordo com informações de posições apresentados na Figura 1, em que para  $H > h_m + h_c$  o valor de  $B(H) = +B_s$  e para  $H < h_m + h_c$  o valor de  $B(H) = -B_s$ , tendo,  $+B_s$  como valor máximo positivo da densidade de fluxo magnético (indução magnética) e  $-B_s$  como valor máximo negativo da densidade de fluxo magnético (indução magnética).

Tratando de representar  $(h_c, h_m)$  em forma de uma função de ponderação, de modo que possa ser escrito como  $\gamma(h_c, h_m)$ , representando uma função de peso, em que, para uma mesma excitação  $H$ , a resposta  $B(H)$  é a soma ponderada das respostas dos transdutores individuais. É possível ver abaixo na Equação (1), na qual a formação de diversos pontos vão adicionar características de histerese

$$B(H) = \iint \gamma(h_c, h_m) H(t) d_{h_c} d_{h_m}, \quad (1)$$

em que,  $\gamma(h_c, h_m)$  é uma função de ponderação;  $B(H)$  é uma função relativa ao campo magnético  $H$ ;  $d_{h_c}$  é a variação da coercitividade apresentada pelo laço do dipolo e  $d_{h_m}$  é a variação correspondente ao campo magnético criado no local do dipolo pelos dipolos vizinhos. Onde, a formação de diversos pontos vão adicionar características de histerese, podendo também serem caracterizados na forma da seguinte Equação (2)

$$f(t) = \sum_{j=1}^N \sum_{i=1}^N \mu(h_{c_j}, h_{m_i}) \gamma_{h_{c_j}, h_{m_i}} [B(H)], \quad (2)$$

em que,  $\mu(h_{c_j}, h_{m_i})$  é o valor da função densidade de *Preisach*. Essa ponderação distribuída descreve a contribuição relativa de cada um dos  $N$  *hysterons* do modelo. Mantendo

as características para a formação de laços de histerese, é apresentado na Equação (3) condições de contorno para representação da função que altera os pontos de formação dos 'loops' intrínsecos do modelo.

$$M(H) = \begin{cases} -1, & H(t) \leq h_m \\ 1, & H(t) \geq h_c \\ \text{mantendo,} & h_c \leq u(t) \leq h_m \end{cases} \quad (3)$$

Sendo,  $M(H)$  a magnetização gerada em relação às variações dos valores  $h_c$  e  $h_m$ . Desta forma a Equação (3) oferece condições para a representação da curva de histerese gerada pelo modelo clássico de *Preisach*, desenvolvida por meio do nexa da magnetização em relação a valores de campo e posteriormente fazendo-se uma correlação entre a indução magnética  $B(H)$  e a magnetização  $M(H)$ .

### 3. CONCEPÇÃO DO MODELO $L^2P$

O modelo desenvolvido por de Almeida et al. (2003) tem como referência o laço maior de histerese confinando em seu interior todos os laços menores. A caracterização matemática parte da observação da Figura 3.

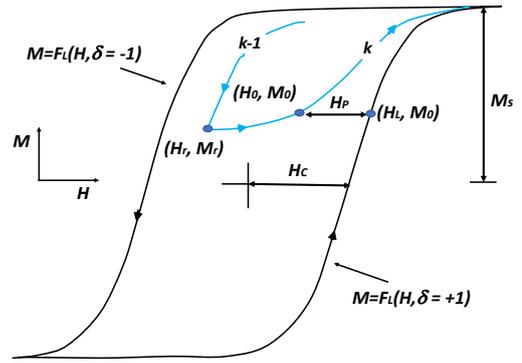


Figura 3. Concepção do modelo  $L^2P$

Sabendo que, na característica experimental de histerese  $M \times H$ , existe uma determinada largura que separa as curvas crescentes e decrescentes principais. Logo, a magnetização  $M$  satura quando alcança valores elevados tanto negativos quanto positivos de  $H$ . Desta maneira, todas as curvas de histerese ficam confinadas ao laço limite, que por sua vez é a combinação das curvas crescentes e decrescentes principais (Leal et al., 2006).

Considerando a histerese como independente da taxa de excitação temporal do sinal, de maneira que o laço principal seja considerado invariante com qualquer que seja o campo aplicado. Com isto representa-se o laço principal pela função  $F_l(H, \delta)$  que é resultante das combinações das curvas  $F_l(H, \delta) = +1$  e  $F_l(H, \delta) = -1$ , observando a Figura 3, através de configurações geométricas, obtém-se a estrutura do modelo proposto por de Almeida et al. (2003). De acordo com a Equação (4),

$$M(H) = \frac{2M_s}{\pi} \arctan \left( \frac{H_p + H - \delta H_c}{h_0} \right) \quad (4)$$

em que,  $M$  é a magnetização da histerese estática;  $M_s$  é a magnetização de saturação;  $H_c$  é o campo coercitivo;

$h_0$  é uma constante dependente do material;  $\delta = \text{sgn}(H)$  onde  $\text{sgn}()$  representa a função sinal com valor  $+1$  para valores positivos do argumento e  $-1$  para valores negativos do argumento. Na mesma sequência com observações da Figura 3, nota-se  $H_L$  como um ponto intrínseco do modelo correspondente à  $M_0$ ; tendo,  $H_p = H_L - H$  correspondente ao campo de proximidade o qual expressa a distância qualquer de um ponto  $(H, M)$  na trajetória  $k$  em um laço menor usando como referência o laço principal  $(H_L, M)$ .

$$H_p = H_{pr}P(x) \quad (5)$$

$$H_{pr} = h_0 \tan\left(\frac{\pi M_r}{2M_s}\right) + \delta H_c - H_r \quad (6)$$

Sabendo-se que,  $H_r$  é o valor do campo magnético no campo de reversão;  $M_r$  é o valor da magnetização no ponto de reversão e  $P(x)$  é uma função arbitrária monotonicamente decrescente, a qual caracteriza a Equação (7). Com o início em deduções nas quais é possível determinar através de experimentos uma dependência funcional de  $H_p$ , como representado pela Equação (5), sendo  $H_{pr}$  o campo de proximidade no ponto de reversão, que é a distância entre o ponto do laço principal e o ponto de reversão. O laço principal tem o mesmo valor de magnetização  $M$  do ponto final de reversão e pertence a curva em que  $\delta$  tem seu valor dado pela Equação (6).

$$x = \frac{H - H_r}{H_{pr}} \quad (7)$$

Desta forma, qualquer trajetória dentro do laço é praticamente independente do ponto de reversão  $(H_r, M_r)$  mostrado na Figura 3. Esta característica é denominada de proximidade ao laço principal. Com isto, a dependência funcional pode ser descrita para retratar qualquer material magnético. A clareza desta definição dá-se devido ao valor máximo da função de proximidade estar entre 0 e 1.

$$H_p = H_{pr}P\left(\frac{H - H_r}{H_{pr}}\right) \quad (8)$$

Aplicando um ponto inicial na Equação (8),  $P(0) = 1$ , para o primeiro valor apresentado na Equação (5), tendo o valor mínimo como nulo, observa-se que esta função mostra a aproximação de uma trajetória qualquer ao laço principal. Neste modelo, de Almeida et al. (2003) fala que a função de proximidade está diretamente ligada ao material magnético, dependendo deste, necessitando portanto de uma escolha criteriosa para o ajuste adequado de  $H_p$  em relação com  $H$ .

$$P_x = \begin{cases} 1 - \text{sen}(\delta x), & \text{se } \delta x < \frac{\pi}{2} \\ 0, & \text{se } \delta x > \frac{\pi}{2} \end{cases} \quad (9)$$

No caso de materiais magnéticos de tipo suave, de Almeida et al. (2003) propõe que a função proximal seja dada pela Equação (9), em que  $\delta$  representa uma constante arbitrária com a característica de determinar a aderência dos laços menores em relação ao laço principal.

Utilizando das Equações (4) e (9), é possível obter a modelagem estática de materiais magnéticos suaves com a utilização de apenas quatro parâmetros:  $M_s$ ,  $H_c$ ,  $h_0$  e  $\delta$ .

$$M(H) = \frac{2M_s}{\pi} \arctan\left(\frac{H_{pr}P\left(\frac{H-H_r}{H_{pr}}\right) + H - \delta H}{h_0}\right) \quad (10)$$

A Equação (10) é fundamental para geração do algoritmo e na implementação da função deste trabalho. Em relação à mudanças na implementação serão destacados apenas o campo aplicado à curva e a alteração dos valores de parâmetros. Os valores de  $M_s$ ,  $H_c$  e  $H_r$  serão a resposta apresentada pelo algoritmo  $L^2P$  em relação ao campo aplicado por meio da curva de magnetização.

#### 4. METODOLOGIA ORIENTADA À OBTENÇÃO DE RESULTADOS

O desenvolvimento desta pesquisa visando a preparação dos modelos, com o intuito de efetuar a aquisição de dados, é representado na Figura 4. A metodologia consiste na aplicação de um sinal representativo do campo magnético. Em seguida ocorre a geração dos parâmetros de Preisach (1935), os quais são obtidos utilizando as Equações (1), (2) e (3) que, em uma relação de magnetização por campo aplicado, geram a curva de histerese do modelo.

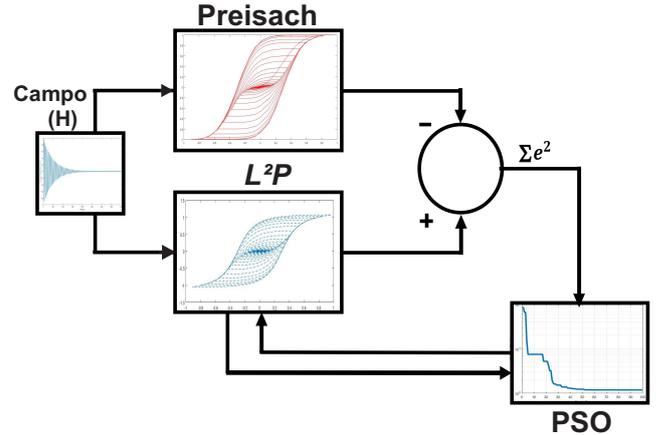


Figura 4. Diagrama representativo

A ilustração apresentada na Figura 4 apresenta a representação da ideia elaborada para alcançar a resposta aproximada do modelo  $L^2P$  a partir do modelo de Preisach. Iniciando com uma entrada  $H$ , como mostra a Figura 5, com valores idênticos para os dois modelos, são geradas as condições para representar a curva de histerese de acordo com a otimização gerada pelo PSO. Esta otimização procura os parâmetros do modelo  $L^2P$ , usando o somatório do erro para alcançar os valores no qual é realizada a busca.

O algoritmo bio-inspirado PSO e o modelo  $L^2P$  trocam informações entre si com o objetivo de caracterizar os quatro parâmetros, os quais podem ser relacionados diretamente com as Equações (9) e (10). Estes quatro parâmetros são desconhecidos no momento da geração da curva de histerese pelo algoritmo PSO (o qual utiliza os dados obtidos por meio modelo de Preisach simulado com auxílio das Equações (2) e (3)). Deste modo os valores dos parâmetros

do modelo  $L^2P$  são encontrados a partir do  $PSO$ , o qual envia informações para a realização da busca por meio de suas partículas.

Uma vez encontrados, os parâmetros retornam para a meta-heurística  $PSO$  para confirmação, na forma de comparação entre as curvas de histerese dos modelos de *Preisach* e  $L^2P$ , computados pela diferença que neste caso pretende-se que seja próxima de zero. Isto é possível dado que o algoritmo  $PSO$  é versátil para este tipo de desenvolvimento. Deste modo, a Figura 4 representa a forma como foi concebido o diagrama, visando representar a utilização do  $PSO$  nos modelos de *Preisach* e  $L^2P$ . Sendo que o modelo de *Preisach* constitui a “entrada de dados” para o  $PSO$  que por sua vez troca informações com o modelo  $L^2P$  com vistas à geração dos parâmetros do mesmo e também da obtenção final da curva de histerese, a qual aspira-se que possua similaridade em relação à curva que foi desenvolvida pelo modelo de *Preisach*.

A otimização baseada na meta-heurística  $PSO$  gera condições para a representação do modelo  $L^2P$ . Com a proposição realizada é observado que como resultado final pode ser realizada uma comparação que indica se os números de iterações e a população foram objetivas na otimização para a aproximação.

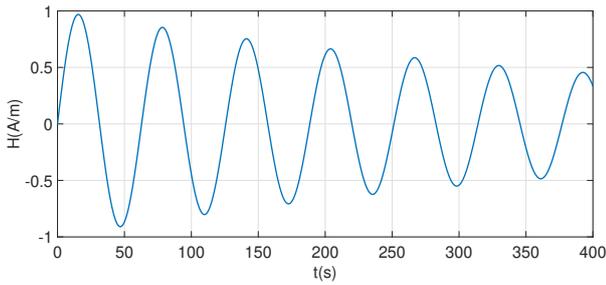


Figura 5. Campo aplicado para geração da curva de Histerese

Com o campo aplicado, mostrado na Figura 5, é realizada a implementação em forma de simulação da curva de histerese por meio do modelo de *Preisach* como é apresentado na Figura 6.

A representação do modelo de *Preisach* é considerada como uma segunda etapa no desenvolvimento desta abordagem, a primeira foi a escolha de um campo para a verificação dos possíveis laços do modelo (Figura 5). Mudanças na representação por meio de valores de pontos de amostragem, podem ser realizadas e o incremento de pontos acima de 100 começa a representar os laços menores (*minors loops*) do modelo (apresentado em forma de resultado nas Figuras 8 e 10). Uma terceira etapa é a utilização do algoritmo  $PSO$  com o intuito de buscar os parâmetros do modelo  $L^2P$  e uma quarta e última etapa é a caracterização da curva de histerese pelos modelos e sua comparação (como apresentado em forma de resultado na Figura 10).

A obtenção da curva de histerese do modelo de *Preisach* (Figura 6) antes da implementação da técnica de otimização é apresentada como parâmetro para a busca realizada pelo  $PSO$  de regiões propícias para a obtenção do laço principal de histerese e dos laços menores. Isto tudo devido

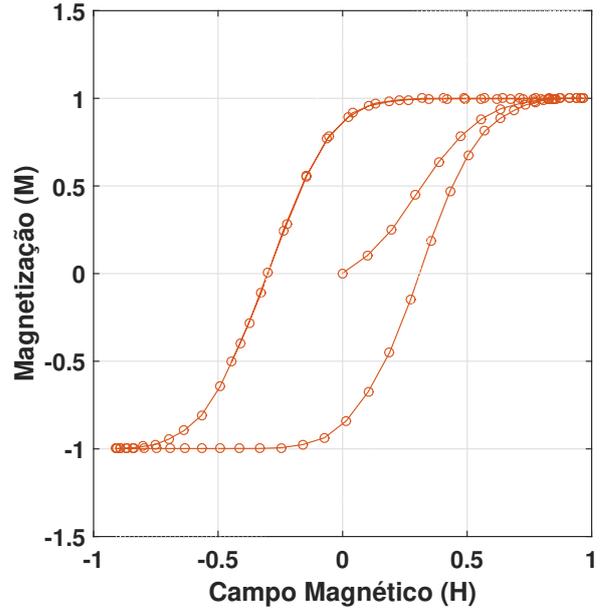


Figura 6. Curva de histerese simulada com modelo de *Preisach* com um valor de 100 pontos para a amostragem

a inserção do campo que apresenta natureza senoidal decrescente em forma de um afundamento de tensão, o qual é falha típica de sistemas de potência quando da ocorrência de faltas em linhas de transmissão. Estes problemas têm se tornado comuns devido à alta inserção de equipamentos eletrônicos em indústrias e são conhecidos como afundamentos momentâneos de tensão (AMT). As suas causas estão associadas de forma direta as faltas nos sistemas elétricos, o que provoca uma parada rápida no sistema, não danificando no entanto o equipamento na maioria das vezes. Porém prejudica o processo em andamento gerando custos relacionados a perdas de qualidade e tempo de retomada do processo envolvido (Cebrian et al., 2005). A caracterização do fenômeno no caso é específica e de forma diferente da apresentada, mas semelhanças em núcleos de transformadores são existentes em uma forma mais abrupta. A simulação realizada com o modelo tenta deixar suave a geração da curva de histerese, pois a preocupação não são perdas e sim identificar por meio do  $PSO$  pontos de convergência que aproximem os modelos.

## 5. ESTIMATIVA DE MODELO USANDO $PSO$

A estimação de parâmetros é dada pela função representativa do modelo em acomodação, a função de geração do modelo de *Preisach* que em sua concepção é totalmente uma função Gaussiana de composição irreversível. A formulação é apresentada de forma que com o algoritmo seja representada uma minimização, que gere por estimação do modelo o alcance do mesmo resultado para o modelo  $L^2P$  ou um erro minimizado de tal forma que ambos sejam próximos o suficiente.

O  $PSO$  foi simulado com base nos trabalhos de Eberhart and Kennedy (1995), Ojeda et al. (2018) e nas Equações (11) e (12), que apresentam como características um vetor representante da posição  $x_i = [x_i^1, x_i^2, \dots, x_i^n]$  e um vetor correspondente de velocidade  $v_i = [v_i^1, v_i^2, \dots, v_i^n]$  em que a

posição apresenta o ponto ótimo da solução do problema em dada velocidade. Ambos os vetores na ativação do problema são inicializados de forma aleatória para a predição com base no comportamento semelhante ao das abelhas. A solução será feita por todas as partículas de forma a convergir em valores de parâmetros.

$$x_k^i = x_k^i + v_k^i \quad (11)$$

$$v_k^i + 1 = w.v_k^i + c_1.r_1.(p^i - x_k^i) + c_2.r_2.(p_k^s - x_k^i) \quad (12)$$

Em que,  $x_k^i + 1$  e  $v_k^i + 1$  representam posição e velocidade, respectivamente, de cada partícula na interação  $k + 1$ , sendo  $v_k^i$  a atual velocidade da partícula  $i$ , tendo  $p^i$  como melhor posição da partícula  $i$ , sendo  $p_k^s$  sua melhor posição global e  $w$  sua inércia e sua capacidade buscar dentro do espaço de solução. Para esta aplicação foi realizada uma otimização utilizando-se 50 partículas e 100 iterações (parâmetros com melhores resultados obtidos após várias simulações) e valores conhecidos do modelo  $L^2P$  são apresentados na Tabela 1.

A busca realizada apresentada na tabela 1 é referente aos valores de parâmetros  $M_s$ ,  $H_c$  e  $H_r$  e seus correspondentes no modelo de *Preisach*. Os valores do modelo  $L^2P$  foram alcançados pelo algoritmo *PSO* quando o mesmo emula o modelo de *Preisach*. Os valores apresentados podem ser encaixados em material do tipo ferrite 3C91 e 3C94 que constituem elementos para criação de indutores, transformadores e elementos variados do sistema elétrico. O campo aplicado (Figura 5) não é um sinal que mantém a mesma amplitude e decai ao longo do tempo, induzindo uma variação na formação de laços menores, o que neste trabalho é importante para dar diferença no comportamento de ambos os modelos, sendo esta diferença o objetivo central deste artigo. Em um caso de apenas verificação de histerese do material para situações típicas (o que não corresponde com a ideia deste trabalho) um sinal senoidal de mesma amplitude e sem variações abruptas de frequência é mais indicado.

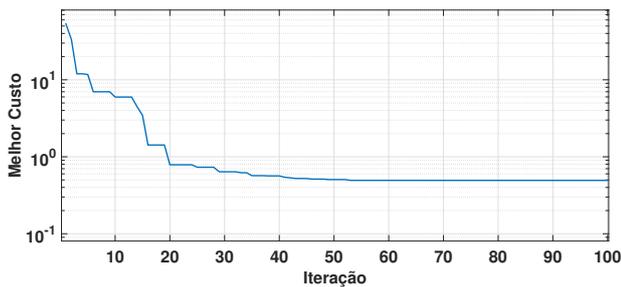


Figura 7. Curva de minimização do *PSO*

A resposta obtida pela otimização é apresentada na Figura 8, na qual após ser realizada a minimização, se obteve um resultado em que o modelo  $L^2P$  alcança uma convergência em relação ao modelo de *Preisach* gerando a resposta buscada em níveis de comportamento. A Figura apresenta 400 pontos referente à entrada  $H$  que é o campo gerado para verificação do comportamento de modelo de histerese e representa uma quantidade média de laços internos

quando comparado com os outros resultados obtidos que serão apresentados na Figuras 9 e 10.

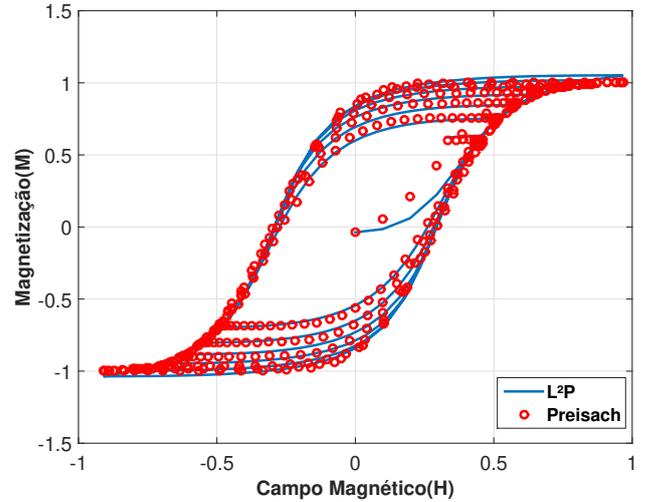


Figura 8. Aproximação de modelos pelo *PSO* com utilização de 400 pontos para amostragem

Para aumentar em dados as comparações, primeiro foi reduzido o número de pontos do modelo, como observado na Figura 9, para minimizar os laços menores e garantir melhor observação do modelo  $L^2P$ . Este modelo é representado pela computação bio-inspirada em função do modelo de *Preisach* associado a representação do laço principal da curva de histerese.

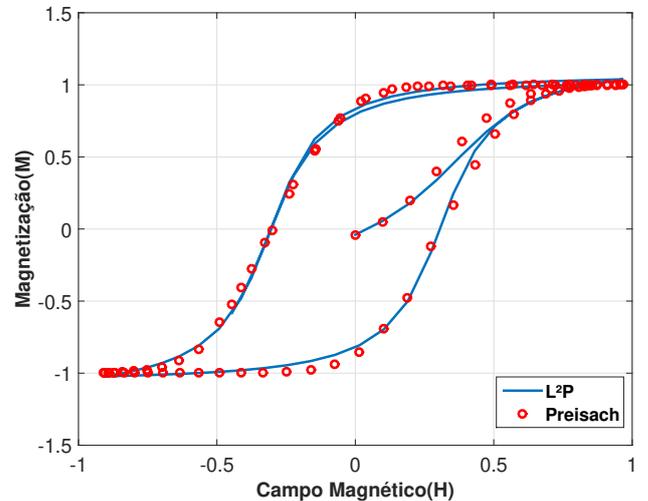


Figura 9. Comparação dos modelos com redução do tamanho do campo  $H$  de 400 para 100 pontos

A avaliação de laços menores de histerese requer um aumento do número de pontos do vetor  $H$  que corresponde à entrada. Para isso, foi realizada uma simulação com 600 pontos para observação conforme pode ser visto na Figura 10.

A observação de acordo com a representação Gaussiana normal do modelo de *Preisach* evidencia que a tendência do mesmo é sua componente de estimação ser totalmente irreversível. Naturalmente, a estimação via *PSO* de tal

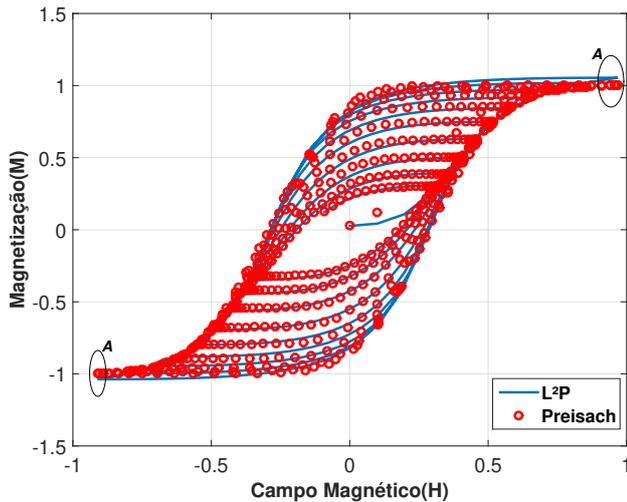


Figura 10. Comparação dos modelos com campo H de 600 pontos. Onde as elipses A representam as pequenas diferenças devido ao fato de que o modelo  $L^2P$  apresenta um pouco de componente reversível

Tabela 1. Valores obtidos em simulação.

| PARÂMETROS | $L^2P$  |         | PREISACH |         |
|------------|---------|---------|----------|---------|
|            | H       | M       | H        | M       |
| Hc         | 0,2938  | 0       | 0,2953   | 0       |
| -Hc        | -0,2830 | 0       | -0,3016  | 0       |
| Mr         | 0       | 0,8402  | 0        | 0,8507  |
| -Mr        | 0       | -0,8192 | 0        | -0,8317 |
| Ms         | 0,9585  | 1,0550  | 0,9681   | 1,000   |
| -Ms        | -0,9102 | -1,0380 | -0,9102  | -0,9990 |

modelo por meio do modelo  $L^2P$  fica apenas aproximada, devido ao fato do modelo apresentar uma natureza que compõe em baixa porcentagem uma componente reversível.

As diferenças apresentadas com a representação via  $PSO$  que realiza modificações dos parâmetros do modelo  $L^2P$  para emular o modelo de *Preisach* são pequenas como é apresentado. Isto indica que ambos podem trabalhar para evidenciar curvas de histerese em materiais com boa aceitação do modelo de *Preisach* que é mais consolidado que o modelo  $L^2P$  e também abre a possibilidade de ambos trabalharem em conjunto em aplicações que precisem utilizar métodos de elementos finitos para comprovar se os valores mostrados pelo modelo são realmente satisfatórios.

O cálculo baseado na estimação do erro de um modelo em função de outro modelo é apresentado apenas pelo cálculo do erro quadrático. Assim a função pode aproximar as curvas a ponto de que os laços menores possam ser quase idênticos ao original. Desta forma, nota-se a componente reversível do modelo  $L^2P$  persistindo em gerar o desnível quando aplicado o cálculo que possibilita a resposta observada na Figura 10. Observam-se também as diferenças de parâmetros do modelo  $L^2P$  relacionado aos mesmos pontos do modelo de *Preisach*, os quais são apresentados na Tabela 1 de acordo com a aproximação gerada por meio do  $PSO$ .

Os pontos escolhidos na Tabela 1 são  $H_c$  que representa o campo coercitivo,  $M_r$  que representa a magnetização

remanescente e  $M_s$  representando a magnetização de saturação. Ambos têm seus dois sentidos indicados e são encontrados na literatura para qualquer curva de histerese. Os parâmetros obtidos pelo  $PSO$  são os mesmos apresentados como valores do modelo  $L^2P$ .

## 6. CONCLUSÃO

A modelagem computacional é uma ferramenta prévia à prática efetiva. Análises e métodos são desenvolvidos para melhorar a escolha de componentes, materiais e aplicação. Desta forma, é possível promover a economia de recursos importantes utilizados nos mais variados projetos. No âmbito de sistemas elétricos, modelos de histerese têm atuação na previsão de perdas relacionadas a materiais ferromagnéticos.

A proposta deste trabalho é justamente a aproximação das curvas de histerese dos modelos  $L^2P$  e *Preisach* por meio da técnica de otimização  $PSO$ , cuja finalidade é obter resultados que proporcionam maior proximidade, no que diz respeito à aquisição de dados em ambas as modelagens. Os conceitos foram simplificados, tendo isto em vista, a representação de uma multiplicação senoidal com uma exponencial decrescente como indicação de campo, foi calculada com o número de 100 iterações e um valor representativo de 50, referente à população. Com este panorama, é provável concluir que o mesmo resultado ocorra nos casos de afundamento de tensão em linhas de transmissão. Estes afundamentos podem danificar elementos constitutivos dos sistemas elétricos ou minimamente interromper um processo industrial por meio de AMT gerando custos relacionados a retomada de processo e passíveis danos relacionados à qualidade do processo que está sendo realizado.

Em relação à modelagem é visto que, para a aquisição exigida, os modelos convergem com determinadas diferenças em sua estrutura fundamental de concepção. As diferenças são devido às estruturas que não são alteradas em ambos os modelos. Desta forma, observações mostram que a composição fundamental do modelo de *Preisach* comporta-se de maneira totalmente irreversível, fenômeno este explicitado pelo fato de sua representação Gaussiana ser construída com bases em métodos físicos. Com isso, é possível concluir que o sutil contraste observado é devido a existência de uma parcela reversível na composição do modelo  $L^2P$ .

Em termos de aplicação, o resultado apresentado é compatível para a utilização em outras possíveis análises em redes e sistemas elétricos, sobretudo naqueles que possuam materiais característicos para avaliar curvas de histerese. A proposta deste artigo foi validada, devido à resposta do modelo  $L^2P$  de Almeida et al. (2003) o qual apresenta uma rápida convergência em relação ao modelo clássico de *Preisach* (1935) alcançando resultados tão próximos que chegam a ser quase imperceptíveis as diferenças entre os modelos para a geração de curvas de histerese.

A importância demonstrada neste trabalho é a representação de dois modelos de forma que ambos podem trabalhar em análise conjunta em uma possível aplicação. A resposta obtida mostra que a aproximação entre os modelos pode

gerar uma confiabilidade maior se ambos os modelos forem utilizados em conjunto.

## REFERÊNCIAS

- Barradas-Berglind, J., Wisniewski, R., and Jayawardhana, B. (2019). Model predictive control with fatigue-damage minimization through the dissipativity property of hysteresis operators. *European Journal of Control*. doi: <https://doi.org/10.1016/j.ejcon.2019.11.004>.
- Borges, M.A.P., Vilcanqui, O.A.C., and Almeida, L.A.L. (2019). Amplificador acoplado em modelo de histerese para análise de altas frequências. *Encontro Regional de Matemática Aplicada (IV-ERMAC)*, 28–33.
- Cebrian, J.C., Camilo, L., Kagan, N., Matsuo, N.M., and Arango, H. (2005). Consideration of voltage sags disruption risks in distribution planning studies. In *CIREN 2005 - 18th International Conference and Exhibition on Electricity Distribution*, 1–4.
- Chayratsami, P. and Plett, G.L. (2018). Hysteresis modeling of lithium-silicon half cells using discrete preisach model. In *2018 8th IEEE International Conference on Control System, Computing and Engineering (IC-CSCCE)*, 31–36.
- de Almeida, L.A.L., Deep, G.S., Lima, A.M.N., and Neff, H. (2003). Limiting loop proximity hysteresis model. *IEEE Transactions on Magnetics*, 39(1), 523–528.
- Duan, N., Xu, W., Li, Y., Wang, S., Guo, Y., and Zhu, J. (2017). Comparison of limiting loop model and elemental operator model for magnetic hysteresis of ferromagnetic materials. *IEEE Transactions on Magnetics*, 53(11), 1–4.
- Eberhart, R. and Kennedy, J. (1995). A new optimizer using particle swarm theory. In *MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science*, 39–43.
- Hussain, S. and Lowther, D.A. (2018). An efficient implementation of the classical preisach model. *IEEE Transactions on Magnetics*, 54(3), 1–4.
- Janičić, V., Ilić, V., Pjevalica, N., and Nikolić, M. (2014). An approach to modeling the hysteresis in ferromagnetic by adaptation of preisach model. In *2014 22nd Telecommunications Forum Telfor (TELFOR)*, 761–764.
- Leal, J.F.Z., Neto, G.M.S., and de Almeida, L.A.L. (2006). Modelo de transformador de corrente usando o rdl2p. *CBA*.
- Ojeda, D.R.G., de Almeida, L.A.L., and Vilcanqui, O.A.C.V. (2018). Parameter estimation of nonlinear thermoelectric structures using particle swarm optimization. *Simulation Modelling Practice and Theory*, 81, 1–10. doi: <https://doi.org/10.1016/j.simpat.2017.11.004>.
- Preisach, F. (1935). Über die magnetische nachwirkung. *Zeitschrift für Physik*, 94, 277–302.
- Sibaliija, V.T. (2019). Particle swarm optimisation in designing parameters of manufacturing processes: A review (2008–2018). *Applied Soft Computing*, 84, 105743. doi: <https://doi.org/10.1016/j.asoc.2019.105743>.
- Solihin, M.I., Wahyudi, Legowo, A., and Akmeliawati, R. (2010). Comparison of lqr and pso-based state feedback controller for tracking control of a flexible link manipulator. In *2010 2nd IEEE International Conference on Information Management and Engineering*, 354–358.
- Sousa, L.C., de Almeida, L.A.L., and Capovilla, C.E. (2018). A hysteresis model for power ferrites. In *2018 Simposio Brasileiro de Sistemas Eletricos (SBSE)*, 1–6.
- Steenjtes, S., Petrun, M., Dolinar, D., and Hameyer, K. (2016). Effect of parameter identification procedure of the static hysteresis model on dynamic hysteresis loop shapes. *IEEE Transactions on Magnetics*, 52(5), 1–4.
- Tao, Y.D., Li, H.X., and Zhu, Z.M. (2020). Hysteresis modeling with frequency-separation-based gaussian process and its application to sinusoidal scanning for fast imaging of atomic force microscope. *Sensors and Actuators A: Physical*, 311, 112070. doi: <https://doi.org/10.1016/j.sna.2020.112070>.
- Zhu, L., Wu, W., Xu, X., Guo, Y., Li, W., Lu, K., and Koh, C. (2019). An improved anisotropic vector preisach hysteresis model taking account of rotating magnetic fields. *IEEE Transactions on Magnetics*, 55(6), 1–4.