https://eventos.utfpr.edu.br//sicite/sicite2020

Análise de dados MHD com programação evolutiva

MHD data analysis with evolutionary programming

Bruno da Silva Braziel
brunobraziel@alunos.utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

Cassio Henrique dos Santos Amador
cassioamador@utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

RESUMO

Frente à pluralidade de métodos e análise em investigações envolvendo a física dos plasmas, o auxílio de recursos tecnológicos se torna uma etapa importante na resolução de problemas matemáticos. A Otimização por Enxame de Partículas (PSO), classificado como computação evolucionária, é um algoritmo capaz de eleger a solução matemática mais satisfatória de acordo com iterações em cima dos melhores valores considerados de um intervalo. Diante disso, esta pesquisa buscou comparar o método PSO com o Curve Fit na busca por valores que supram as frequências envolvidas na fórmula que rege os fenômenos magneto-hidrodinâmicos (MHD). Ao fim do estudo, foi observado que o modelo PSO apresentou mais consistência em sua execução, com oscilações menores nos parâmetros quando comparado ao Curve Fit. Este, por sua vez, resultou em valores decrescentes até se aproximarem aos que foram encontrados pelo PSO.

PALAVRAS-CHAVE: Otimização. Comparação. Plasma. Frequência.

Recebido: 19 ago. 2020.
Aprovado: 01 out. 2020.

Direito autoral: Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

ABSTRACT

In view of the plurality of methods and analysis in investigations involving the phyisics of plasma, the support of technological resources becomes a relevant step in mathematical problems' solutions. Particle Swarm Optimization (PSO), classified as an evolutionary computation, is an algorithm capable of electing the most satisfactory mathematic solution according to iterations over the best values considered on an interval. Therefore, this research aimed in comparing PSO method with Curve Fit optimizer to find the values able to supply the frequencies involved in the formula that rules the magnetohydrodynamic

phenomena (MHD). At the end of the study, it was observed that the PSO model showed more consistency in its execution, with low variations when compared to Curve Fit. This, in turn, resulted in decreasing values until they approached the ones found by PSO.

KEYWORDS: Optimization. Comparison. Plasma. Frequency.

INTRODUÇÃO

Considerado o quarto estado da matéria, o plasma é composto por íons, elétrons e átomos neutros. A temperatura de suas partículas é de geralmente 104 Kelvin (BITTENCOURT, J. A. 2013). Para estudo de reações de fusão e produção de energia utilizando plasmas de deutério, por exemplo, é realizado um processo que eleva a temperatura em até 108 Kelvin. Desta forma, a física por trás desta matéria é complexa e incentiva o desenvolvimento de soluções computacionais, tanto para simulações de reações, bem como em problemas matemáticos.

Uma forma de análise de dados que lidam com problemas de otimização é com o apoio de algoritmos genéticos. Eles são classificados como técnicas de programação que possuem características evolutivas. Pode-se dizer que tais algoritmos são iterações de desafios (ou problemas) postos frentes à uma população (sendo este o conjunto de dados). O subconjunto que melhor resolver o problema é eleito para a próxima iteração (TANESE, R.; HOLLAND, J. H.; STOUT, Q. F. 1989). Matematicamente, este método é utilizado para buscar os extremos de funções (WEILE, D. S.; MICHIELSSEN, E. 1997).

A Otimização por Enxame de Partículas (*Particle Swarm Optimization* - PSO) é um exemplo de computação natural, originado de uma tentativa de simulação de um bando de pássaros. Após algum tempo de evolução e correção de parâmetros, o algoritmo foi finalmente reconhecido como um otimizador (EBERHART; YUHUI SHI. 2001).

Este trabalho busca relatar a aplicação do PSO como otimizador para a equação que rege o comportamento da frequência de oscilações causadas por efeitos magneto-hidrodinâmicos (MHD), provindos de um plasma gerado no Tokamak Tore Supra. Partindo de um trabalho já realizado com os mesmos dados, onde foi utilizado algoritmos lineares de busca de soluções, foram encontrados parâmetros para uma equação através de interpolação dos dados no tempo.

Quando comparada a Otimização por Enxame de Partículas com modelos genéticos tradicionais, PSO tem a vantagem de não haver necessidade de discretização. Outros modelos exigem a discretização da soluções possíveis, e corre-se o risco de que a solução ideal esteja entre dois valores da discretização aplicada.

METODOLOGIA

De acordo com o estudo realizado por Amador et al. (2017), os fenômenos MHD estudados exibem uma frequência que obedece a seguinte fórmula:

$$f=\sqrt{f_{BAE}{}^2+\left(m\left|1-\frac{1}{q_{min}}\right|f_A\right)^2}+m\left(f_{Tor}+f_{dia}\right) \quad (1)$$

Que pode ser parametrizada da seguinte forma:

$$f=\sqrt{f_0{}^2+\left(m f_1\right)^2}+m f_2 \quad (2)$$

A equação acima apresenta a frequência observada em alguns diagnósticos, quando ocorre o fenômeno chamado de dente-de-serra, onde f_0 diz respeito aos modos mais fortes do fenômeno MHD, f_1 é a frequência caracterizada pelas cascatas de Alfvén (outro fenômeno MHD), provindas de íons causados pela produção adicional de calor na Tokamak e por fim, f_2 é a soma das frequências resultantes da rotação toroidal e diamagnética. m é um parâmetro que indica o número do modo, ou seja, quantas vezes as frequências estão sendo repetidas. Esta função é não linear, portanto obter os parâmetros f_0, f_1 e f_2 não pode ser feito com métodos lineares de busca.

Tratamento dos Dados: A Figura 1, motivo deste estudo, apresenta os pontos resultantes das frequências observadas. Cada sequência temporal equivale a um valor de m diferente, porém os demais parâmetros são iguais para todas as curvas. Como cada curva está medida em tempos diferentes, os dados foram interpolados com base numa sequência temporal de 50 pontos. Caso a sequência temporal termine antes ou depois desses pontos interpolados, aquela curva é desconsiderada naquele intervalo. A interpolação é necessária para poder se ajustar à equação com todos os pontos disponíveis naquele tempo.

Figura 1 – Pontos obtidos através do projeto de Amador et al (2017, p. 016010).

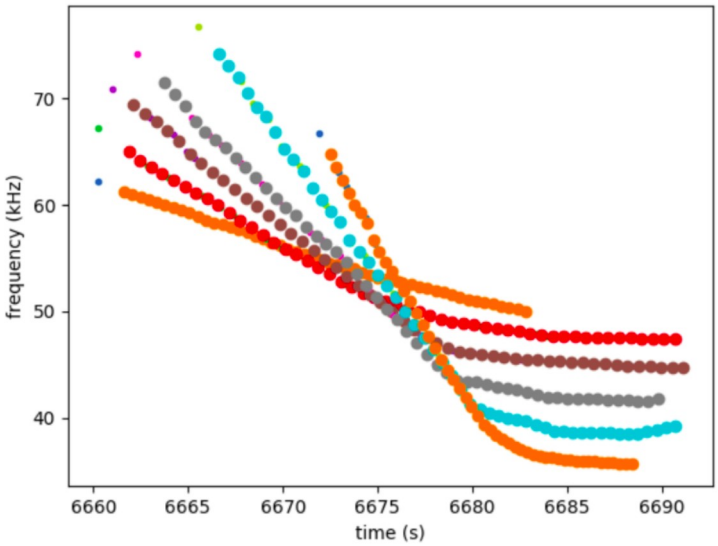

Fonte: Autoria própria

O valor de 50 foi escolhido, uma vez que utilizando menos que este, correria o risco de perder informações e, extrapolando tal quantia, seriam criados valores que não existem. Seu resultado foi disposto em uma matrix *MxN*, sendo *M* a quantidade de valores para frequência e *N* os valores para o tempo. Onde não havia dados, foi colocado *NaN*, facilitando a aplicação dos algoritmos por utilizar arrays de *numpy*, biblioteca utilizada para operações matemáticas.

Como primeiro passo nesta pesquisa, foi utilizada a função *Curve Fit* da biblioteca *Scipy*. O segundo passo foi utilizar o algoritmo de Enxame de Partículas com o mesmo propósito. Em ambos os casos, o chi quadrado foi utilizado como avaliador da eficiência do algoritmo. Os dados para esta pesquisa são parte do projeto "Investigação de Fenômenos de Plasma de Tokamak com Ferramentas de Aprendizado de Máquina e Programação Evolutiva" (AMADOR, C. et al. 2017).

Curve Fit: Também classificada como mínimos quadrados não lineares (EBERHART; YUHUI SHI. 2001), este método toma como parâmetros a função a ser otimizada, os vetores de dados e, no caso desta pesquisa, também foram passados os limites de valores. Ela retorna dois parâmetros, sendo o primeiro os valores otimizados e o segundo a covariância do resultado, podendo ser utilizada para obter o desvio padrão.

Particle Swarm Optimization: Desenvolvido em 1995, a Otimização por Enxame de Partículas é um algoritmo pertencente à classe de algoritmos genéticos com características evolucionárias (COMMUNITY, T. S. 2020). Sua conduta orgânica

se dá com base em estudos em neurociências, psicologia cognitiva, etologia social e ciências comportamentais (TILL STENSITZKI, M. et al. 2020). O PSO usa as maneiras com que os animais se reúnem para exemplificar partículas homogêneas que percorrem as possibilidades de um caso específico. A Figura 2 exemplifica o uso do PSO na otimização de uma função trigonométrica.

Figura 2 – Exemplo de utilização da função *Curve Fit* na otimização de um senóide.

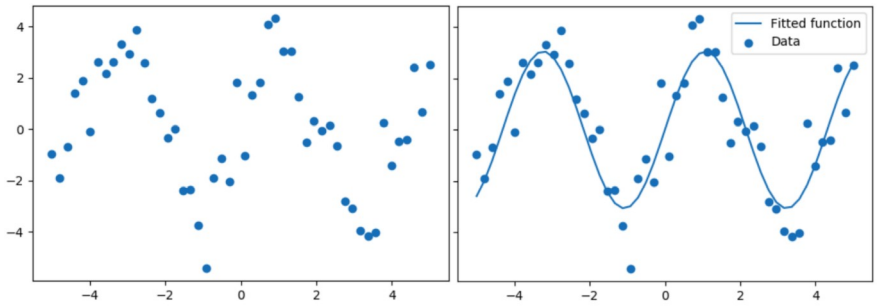

Fonte: EMMANUELLE GOUILLART, G. et al. 2020.

Diante disso, esta pesquisa tomou como base o pseudo algoritmo da Figura 3 para encontrar os melhores valores para a Eq. 2 de acordo com os valores interpolados. Ao final do código, foi retornado os extremos da fórmula, bem como um valor que representa a eficiência da técnica para cada iteração.

Figura 3 – Pseudo código de Otimização por Enxame de Partículas.

PARA *cada partícula i* **FAÇA**
  PARA *cada dimensão d* **FAÇA**
    Inicializar a posição x_{id} aleatoriamente dentro do intervalo possível
    Inicializar a posição v_{id} aleatoriamente dentro do intervalo possível
  FIM
FIM
Iteração $k = 1$
REPITA
  PARA *cada partícula i* **FAÇA**
    Calcular o valor *fitness*
    SE *o valor fitness for melhor que o histórico de* $p_{best_{id}}$ **ENTÃO**
      Associar o atual valor *fitness* ao $p_{best_{id}}$
    FIM
  FIM
  Escolha a partícula que possui o melhor valor *fitness* como g_{best_d}
  PARA *cada partícula i* **FAÇA**
    PARA *cada dimensão d* **FAÇA**
      Calcular a velocidade de acordo com a equação
      $v_{id}(k+1) = wv_{id}(k) + c_1 rand_1(p_{id} - x_{id}) + c_2 rand_2(p_{gd} - x_{id})$
      Atualizar a posição da partícula de acordo com a equação
      $x_{id}(k+1) = x_{id}(k) + v_{id}(k+1)$
    FIM
  FIM
  $k = k + 1$
ATÉ *máximo de iterações ou critério de mínimos erros não ser atingido*;

Fonte: Al Hwaitat, Ahmad. 2017.

RESULTADOS E DISCUSSÕES

Utilizando os dados interpolados, foram obtidos os seguintes valores para os parâmetros da equação quando trabalhando com o *Curve Fit*, de acordo com a Figura 4. Vale ressaltar que o terceiro parâmetro da fórmula f_2 foi fixado em 2,5 GHz, como feito no artigo original, para poder comparar os resultados.

Figura 4 – Resultados utilizando *Curve Fit*.

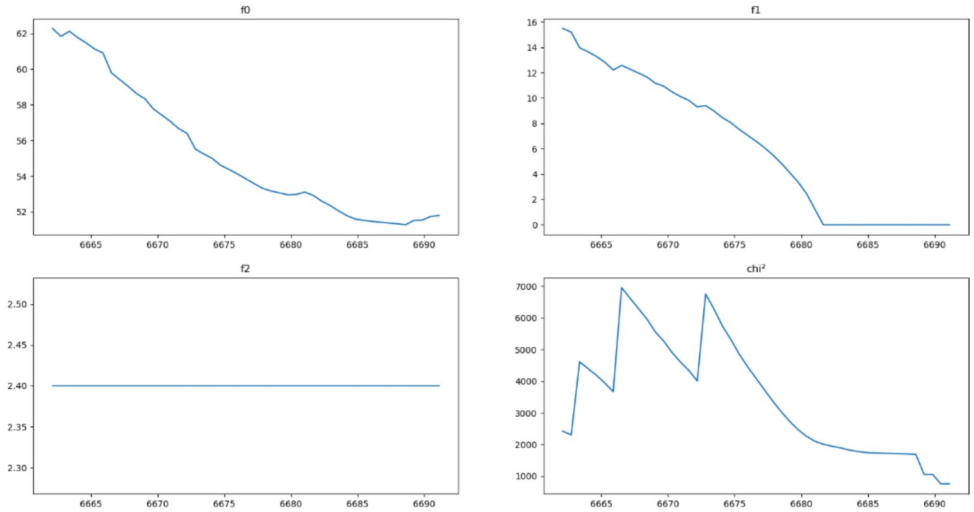

Fonte: Autoria própria.

Quando trabalhando com PSO, utilizando 500 iterações, foram obtidos os valores apresentados na Figura 5.

Figura 5 – Resultados utilizando *Particle Swarm Optimization*.

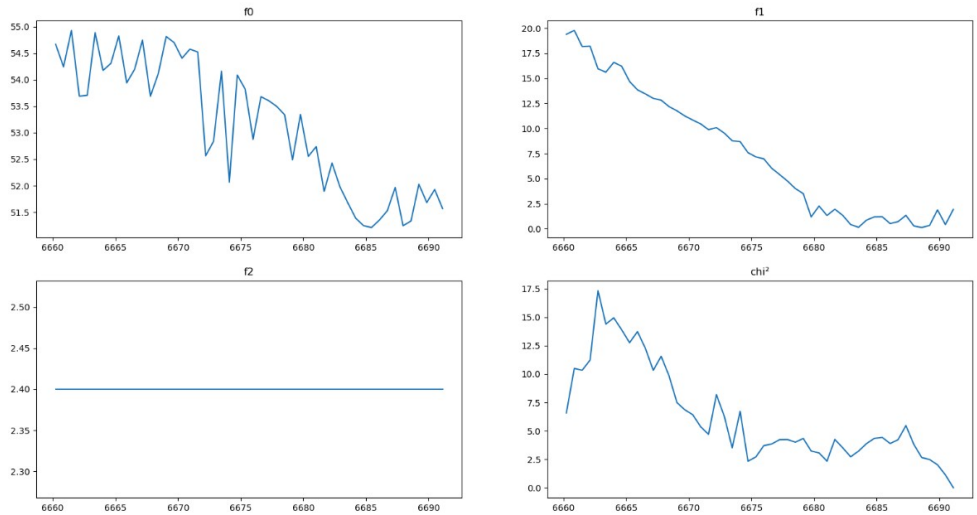

Fonte: Autoria própria.

Comparando ambos métodos, têm-se os gráficos da Figura 6. A variável f_0 teve um comportamento mais constante no modelo PSO do que no *Curve Fit*, sendo que por volta dos 6675 microssegundos ambos modelos mantiveram uma similaridade de valores. A variável f_1, por sua vez, obteve praticamente o mesmo comportamento em ambos cenários, levemente variando a partir dos 6680 segundos.

Figura 6 – Comparativo entre *Curve Fit* (em laranja) e PSO (em azul).

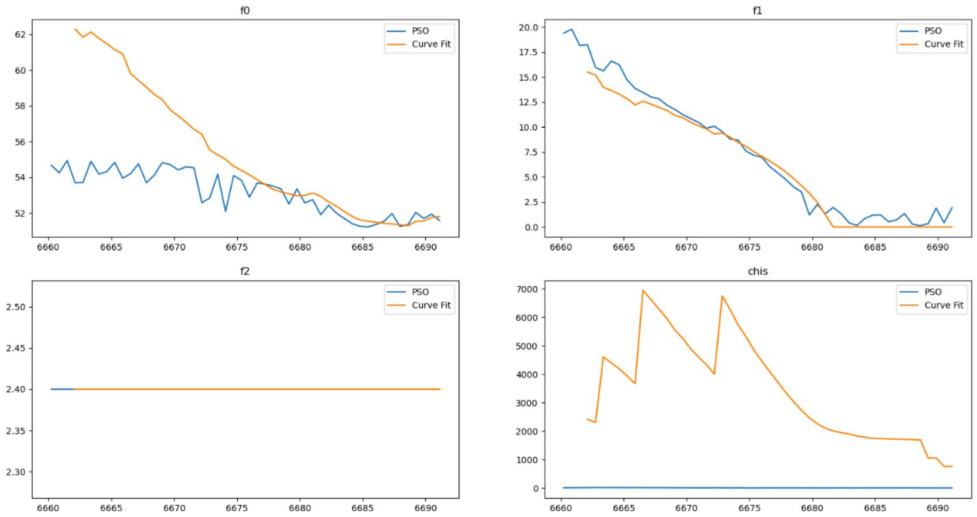

Fonte: Autoria própria.

Por fim, o chi quadrado foi o mais discrepante dos casos, evidenciando que no modelo PSO houve leves mudanças, o que não foi o caso do *Curve Fit*, modelo que apresentou severas variações nos valores dos parâmetros da equação.

CONCLUSÕES

Diante dos resultados apresentados e tomando como base o comparativo entre o modelo *Curve Fit* e PSO, é possível notar que o Enxame de Partículas é um método viável para se encontrar resultados de equações não lineares. Outro ponto a ser levantado é que, utilizando PSO, é possível obter o valor de f_2 (nesta pesquisa tomado como constante), fator que não é possível ser aplicado nos métodos de otimização da biblioteca *Scipy*.

A análise da discrepância entre os chi quadrados e a implementação do parâmetro f_2 são itens considerados como integrantes de trabalhos futuros.

AGRADECIMENTOS

Os autores agradecem à Universidade Tecnológica Federal do Paraná, pela participação no Programa de Voluntariado em Iniciação Científica e Tecnológica do acadêmico Bruno da Silva Braziel.

REFERÊNCIAS

BITTENCOURT, J. A. **Fundamentals of plasma physics**. [S.l.]: Springer Science & Business Media, 2013.

TANESE, R.; HOLLAND, J. H.; STOUT, Q. F. **Distributed Genetic Algorithms for Function Optimization**. 1989. Tese (Doutorado) – Disponível em: https://dl.acm.org/doi/book/10.5555/915973. Acesso em 06 ago. 2020.

WEILE, D. S.; MICHIELSSEN, E. **Genetic algorithm optimization applied to electromagnetics: A review**. IEEE Transactions on Antennas and Propagation, IEEE, v. 45, n. 3, p. 343–353, 1997. Disponível em: https://ieeexplore.ieee.org/abstract/document/558650. Acesso em 06 ago. 2020.

EBERHART; YUHUI SHI. **Particle swarm optimization: developments, applications and resources**. In: PROCEEDINGS of the 2001 Congress on Evolutionary Computation (IEEE Cat. No.01TH8546). [S.l.: s.n.], mai. 2001. v. 1, 81–86 vol. 1. DOI: 10.1109/CEC.2001.934374. Disponível em: https://ieeexplore.ieee.org/abstract/document/934374. Acesso em 06 ago. 2020.

AMADOR, C. et al. **Determination of *q* during sawtooth from inverse evolution of BAEs in Tore Supra**. Nuclear Fusion, IOP Publishing, v. 58, n. 1, p. 016010, nov. 2017. DOI: 10.1088/1741-4326/aa85a9. Disponível em: https://iopscience.iop.org/article/10.1088/1741-4326/aa85a9/meta. Acesso em 06 ago. 2020.

EMMANUELLE GOUILLART, G. et al. **1.6.12.8 Curve Fitting**. Disponível em: https://scipy-lectures.org/intro/scipy/auto_examples/plot_curve_fit.html. Acesso em 06 ago. 2020.

COMMUNITY, T. S. **Scipy Optimize Curve Fit**. Disponível em: https://docs.scipy.org/doc/scipy/reference/generated/scipy.optimize.curve_fit.html. Acesso em 06 ago. 2020.

TILL STENSITZKI, M. et al. **Modeling Data and Curve Fitting**. Disponível em: https://lmfit.github.io/lmfit-py/model.html. Acesso em 06 ago. 2020.

AL HWAITAT, AHMAD, H. A. **Movement Particle Swarm Optimization Algorithm**. Modern Applied Science, v. 12, p. 148, dez. 2017. DOI: 10.5539/mas.v12n1p148. Disponível em: https://www.researchgate.net/publication/322164147_Movement_Particle_Swarm_Optimization_Algorithm. Acesso em 06 ago. 2020.