

RLC Otimizador – Algoritmo de Metaheurísticas Fundamentadas na Análise Eletromagnética de Circuitos Elétricos

Denis Carlos Lima Costa¹

<https://orcid.org/0000-0003-3207-6934>

RESUMO

Este artigo apresenta o RLC Otimizador (RLCO), uma Metaheurística de otimização estocástica inspirada na fenomenologia Física de circuitos elétricos em corrente alternada (CA). A metodologia proposta mapeia o espaço de busca como um sistema de impedância complexa, em que a função objetivo e suas restrições definem a resistência ativa e as reatâncias do meio. Diferente de algoritmos convencionais, o RLCO utiliza a Lei de Ohm e o Fator de Potência ($\cos\phi$) para governar a dinâmica de movimento dos agentes, interpretando a aptidão (*fitness*) como a magnitude da corrente elétrica em um estado de ressonância série. O algoritmo introduz um mecanismo de Fator Q Adaptativo, que modula a seletividade da busca: uma banda larga inicial para exploração global e uma banda estreita final para o refinamento preciso no ponto de ressonância (ótimo global). Testes realizados em funções de *benchmark* com restrições rígidas de igualdade e desigualdade demonstram que a incorporação de penalidades de impedância (λ, μ) confere robustez ao sistema, permitindo uma convergência estável e evitando mínimos locais. Os resultados validam o RLCO como uma ferramenta eficaz e fisicamente interpretável para problemas complexos das Ciências e das Engenharias.

Palavras-chave

Método de otimização; Ressonância série; Sintonia de frequência; Impedância de busca.

RLC Optimizer – Metaheuristic Algorithm Underpinned on Electromagnetic Analysis of Electrical Circuits

ABSTRACT

This article presents the RLC Optimizer (RLCO), a stochastic optimization metaheuristic inspired by the physical phenomenology of alternating current (AC) electrical circuits. The proposed methodology maps the search space as a complex impedance system, where the objective function and its constraints define the active resistance and reactances of the medium. Unlike conventional algorithms, RLCO uses Ohm's Law and the Power Factor ($\cos\phi$) to govern the movement dynamics of the agents, interpreting (*fitness*) as the magnitude of the electric current in a series resonance state. The algorithm introduces an Adaptive Q Factor mechanism, which modulates the selectivity of the search: an initial wideband for global exploration and a final narrowband for precise refinement at the resonance point (global optimum). Tests performed on benchmark functions with strict equality and inequality constraints demonstrate that the incorporation of impedance penalties (λ, μ) confers robustness to the system, allowing stable convergence and avoiding local minima. The results validate RLCO as an effective and physically interpretable tool for complex problems in Science and Engineering.

Keywords

Optimization method; Series resonance; Frequency tuning; Impedance matching.

Submetido em: 15/03/2026 – Aprovado em: 16/04/2026 – Publicado em: 16/04/2026

¹ Professor-Pesquisador/Doutorado e Pós-Doutorado em Sistemas de Energia. Professor Titular do Instituto Federal de Educação, Ciência e Tecnologia do Pará - IFPA Câmpus Ananindeua. denis.costa@ifpa.edu.br.




1 INTRODUÇÃO

Simultaneamente ao aprimoramento da Ciência e da Tecnologia, existe um intenso nível de esforços dedicados a maximizar o uso racional dos recursos naturais limitados. Os novos avanços científicos revelam a urgente necessidade de considerar maior precisão, melhor desempenho e notável velocidade de construção de sistemas, considerando as condições socioambientais. Dessa forma, é fundamental desenvolver novos métodos de otimização e implementá-los em problemas complexos reais para alcançar cada um dos múltiplos objetivos.

A otimização é um processo de tomada de decisão no qual se busca encontrar os valores mínimo e/ou máximo de uma função. Os algoritmos de otimização são divididos em duas categorias: algoritmos exatos e algoritmos aproximados. Os algoritmos exatos podem encontrar a solução ótima com precisão. No entanto, no caso de problemas de otimização complexos, eles não são suficientemente eficientes e seu tempo computacional aumenta geometricamente de acordo com as dimensões do problema. Sendo assim, considerando as limitações dos métodos exatos e a necessidade de precisão e de velocidade na identificação de respostas adequadas, os algoritmos aproximados, como as Metaheurísticas, são capazes de encontrar soluções congruentes muito próximas da solução ótima em um menor tempo, podendo ser aplicados para resolver problemas complexos (AZIZI *et al.*, 2023).

O prefixo grego *Meta* fundamenta a classificação desses algoritmos como meta-estratégias de otimização, posicionando-os como estruturas de controle generalistas que transcendem as limitações das heurísticas customizadas para problemas específicos. As metáforas utilizadas por pesquisadores no desenvolvimento de novas Metaheurísticas incluem: evolução natural, insetos, gravitação, força eletromagnética, ecossistema, água, plantas, seres humanos, pássaros e animais. A criação de novas Metaheurísticas é extremamente vantajosa para a Ciência, pois elas podem melhorar a precisão e a eficácia do procedimento de otimização para uma série de problemas. Essa motivação direcionou essa pesquisa a fim de propor um algoritmo metaheurístico único, inspirado em conceitos de tecnologias avançadas da Física relacionados às Leis dos circuitos elétricos RLC (Resistor, Indutor, Capacitor), como ilustrado na Figura 1.

Figura 1. Exemplo de Circuito Elétrico RLC.



Fonte: Autor.

O ineditismo do algoritmo RLCO está associado ao fascinante fato de que os circuitos combinam as propriedades de armazenamento de energia (L e C) com a perda de energia (R), criando um sistema que pode oscilar, de forma muito semelhante a um pêndulo.

A otimização é fundamental em muitas aplicações nas ciências e nas engenharias. Obviamente, os objetivos da otimização podem ser diversos — minimizar o consumo de energia, os custos e o impacto ambiental ou maximizar o lucro, a produção, o desempenho, a sustentabilidade e a eficiência. Não é exagero dizer que a otimização está em toda as áreas do conhecimento. Como os recursos são, na maioria das vezes, limitados em aplicações de cenários operacionais, precisa-se encontrar soluções para usar esses valiosos recursos de forma otimizada, sob várias condições e restrições, idealmente de maneira socioambientalmente sustentáveis.

A otimização matemática ou programação é o estudo desses problemas de planejamento e projeto usando ferramentas matemáticas. Como a predominância das aplicações da realidade empírica costuma ser altamente não-linear, elas exigem ferramentas de otimização sofisticadas para serem resolvidas. Atualmente, as simulações computacionais se tornaram uma ferramenta indispensável para resolver esses problemas de otimização com vários algoritmos de busca eficientes.

A otimização de sistemas complexos exige algoritmos que equilibrem de forma eficiente a exploração de vastas regiões do espaço de busca com o refinamento rigoroso de soluções promissoras. O RLC Otimizador (RLCO) propõe uma abordagem baseada na Física, mais especificamente, na análise eletromagnética de circuitos, utilizando a dinâmica de sistemas oscilatórios de segunda ordem como metáfora para a busca estocástica. O algoritmo fundamenta-se no princípio da Ressonância Elétrica, o estado no qual a transferência de energia em um circuito composto por uma resistência (R), um indutor (L) e um capacitor (C) atinge sua magnitude máxima.

Diferente de métodos puramente matemáticos, o RLCO interpreta o espaço de busca como um meio físico dotado de impedância (Z). Em um circuito RLC série, a impedância total é uma função da frequência angular (ω), dada pela Equação (1).

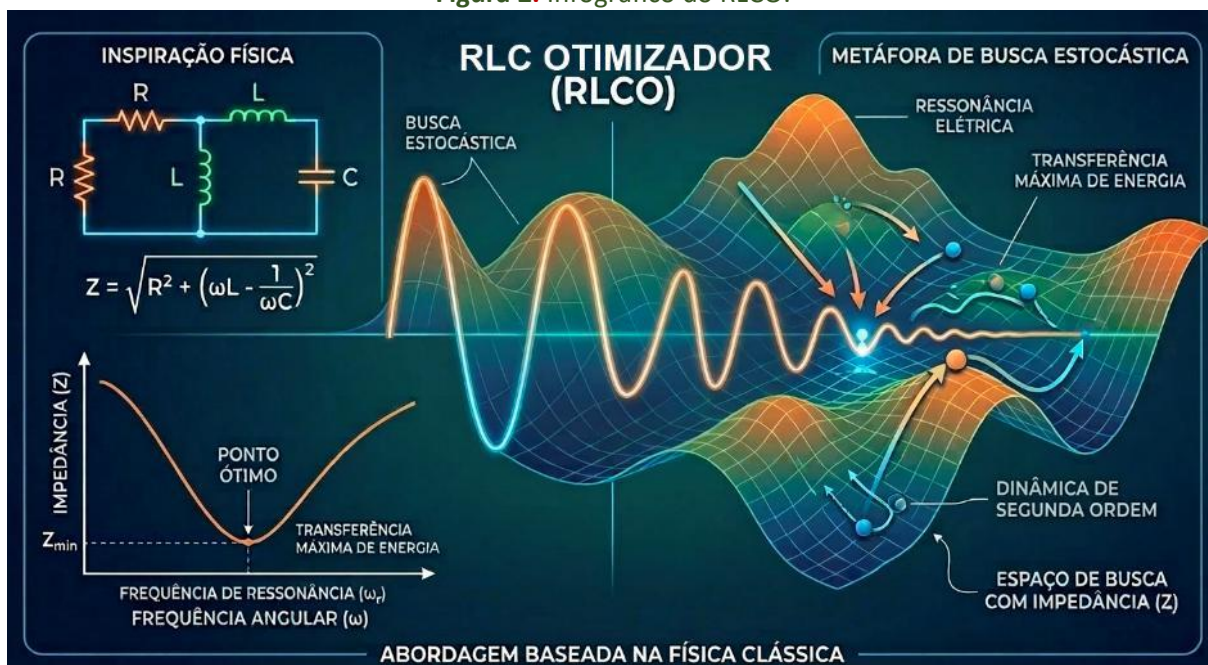
$$Z = \sqrt{R^2 + \left(\omega L - \frac{1}{\omega C}\right)^2} \quad (1)$$

Em que o termo $(\omega L - 1/\omega C)$ representa a reatância total do sistema (X), sendo a Parte Imaginária e (R) a resistência, sendo a Parte Real (ALEXANDER; SADIKU, 2013). O objetivo primordial do otimizador é encontrar a frequência de ressonância (ω_0), ponto exato onde as reatâncias indutiva e capacitiva se anulam, minimizando a impedância e, conseqüentemente, maximizando a corrente elétrica (I), que no RLCO é mapeada como aptidão (*fitness*) do agente.

A inovação deste método de otimização consiste na manipulação do Fator Q (Fator de Qualidade) de forma adaptativa.

Em Sistemas de Energia Elétrica, o Fator Q descreve o amortecimento do circuito: um Q elevado indica uma ressonância estreita e seletiva, enquanto um Q baixo resulta em uma resposta de banda larga. No RLCO, essa característica é utilizada como um mecanismo de controle dinâmico: i) Fase Inicial (Q Baixo) \rightarrow O sistema apresenta alta "resistência de busca", permitindo que os agentes oscilem amplamente pelo domínio, evitando a convergência prematura em mínimos locais. ii) Fase de Convergência (Q Alto) \rightarrow O sistema torna-se criticamente sintonizado, restringindo os agentes em direção ao ponto de máxima energia, o mínimo global da função objetivo. A Figura 2 ilustra a idealização do processo usado na implementação do RLCO.

Figura 2. Infográfico do RLCO.



Fonte: Autor.

Ao incorporar restrições de igualdade e desigualdade diretamente no cálculo da "impedância virtual" por meio de funções de penalidade, o RLCO transforma problemas de otimização restrita em uma busca por equilíbrio dinâmico, oferecendo uma ferramenta intuitiva e matematicamente fundamentada para cientistas e engenheiros. Partindo dos princípios da eletrodinâmica clássica para a linguagem da otimização matemática, o objetivo é demonstrar que o movimento dos agentes não é aleatório, mas governado por leis físicas que buscam o equilíbrio energético (o ótimo global). A base do algoritmo RLCO consiste na interpretação do espaço de busca como um circuito elétrico complexo das leis fundamentais da eletricidade e redefinidas para o processo de busca estocástica.

A Lei de Ohm ($V = Z.I$) estabelece a correlação fundamental entre tensão, impedância e corrente (HALLIDAY; RESNICK, 2016).

Transpondo tal princípio para o domínio da otimização, essa relação é redefinida para quantificar a “velocidade” ou o “passo” de um agente: V (Tensão) \rightarrow representa a "pressão de busca" ou a energia total injetada no sistema para evitar a estagnação; Z (Impedância) \rightarrow é a função de custo total, incluindo penalidades. Quanto pior a solução, maior a "resistência" do meio; I (Corrente) \rightarrow representa a Aptidão (*Fitness*). No RLCO, uma corrente elevada significa que o agente encontrou um caminho de baixa resistência, permitindo passos mais determinantes e assertivos em direção ao ótimo.

As Leis de Kirchhoff (HALLIDAY; RESNICK, 2016) fornecem a estrutura para lidar com problemas multivariáveis e restrições rígidas: i) Lei de Kirchhoff das Correntes \rightarrow aplicada à otimização multiagente, ela sugere que a soma das influências em um nó de decisão deve ser equilibrada. Isso fundamenta a atualização da posição onde a influência do "Melhor Global" e a "Inércia do Agente" se somam vetorialmente. ii) Lei de Kirchhoff das Tensões \rightarrow em um circuito fechado (um ciclo de iteração), a soma das quedas de potencial (erros) deve ser minimizada. Se um agente viola uma restrição, ele adiciona uma "queda de tensão" fictícia (penalidade) tão alta que o potencial disponível para o movimento é drasticamente reduzido.

O diferencial do RLCO, em relação aos demais métodos baseados em Física, é a inclusão das Reatâncias (X_L e X_C). Elas introduzem a dimensão temporal e a frequência na busca: Reatância Indutiva ($X_L = \omega.L$) \rightarrow atua como uma massa inercial. Ela impede mudanças desarmônicas de direção, suavizando a trajetória do agente e permitindo que ele atravesse pequenos picos de erro (ruído) sem perder o impulso. Reatância Capacitiva ($X_C = 1/\omega.C$) \rightarrow atua como um efeito de “mola” ou elasticidade. Em baixas frequências (regiões inexploradas), ela domina o sistema, forçando o agente a se deslocar para longe e explorar novas fronteiras. A Figura 3 simula o comportamento de convergência do RLCO em um espaço de busca.

Figura 3. Caracterização da Dimensão temporal e Energia de busca no RLCO.



Fonte: Autor.

A otimização é concluída quando o sistema atinge a Ressonância Série. Matematicamente, isso ocorre quando as Reatâncias se anulam ($X_L \cong X_C$), resultando em, $Z_{min} = R \Rightarrow I_{max} = V/R$. Neste estado, o ângulo de fase (φ) é zero e o Fator de Potência ($\cos\varphi$) é unitário. Isso significa que toda a "energia de busca" do algoritmo está sendo convertida em trabalho útil de convergência, eliminando oscilações desnecessárias e focando inteiramente no refinamento da solução encontrada.

2 REVISÃO DE LITERATURA

A heurística é uma estratégia, por tentativa e erro, capaz de gerar soluções verossímeis para um problema complexo em um período plausível. O propósito principal é descobrir um conjunto de soluções estáveis em um tempo aceitável. Não há uma garantia provável de que as melhores soluções possam ser obtidas. A ideia é ter um algoritmo eficiente, que funcione, na maioria das vezes, e que seja capaz de proporcionar soluções de boa qualidade. Entre as soluções de qualidade encontradas, espera-se que algumas sejam ótimas, embora não haja garantia de tal otimalidade (YANG, 2020).

Can e Alatas (2015) indicam que os métodos de otimização, especialmente os metaheurísticos que utilizam o poder da natureza, imitam processos físicos e destacam o Algoritmo de Otimização *Big Bang Big Crunch*, baseado na evolução do universo e o Algoritmo de Busca Gravitacional, baseado na lei da gravidade, que foram propostos e aplicados na resolução de problemas complexos.

Yang (2020) indica que os dois principais componentes de um algoritmo metaheurístico são: a intensificação e a diversificação, ou exploração e exploração. Diversificação significa gerar soluções diversas para explorar o espaço de busca em escala global. Intensificação significa focar a busca em uma região local, explorando a informação de que, uma boa solução atual é encontrada nessa região. Isso é combinado com a seleção das melhores soluções. A seleção da melhor solução assegura que as soluções converjam para a otimalidade, enquanto a diversificação, por meio da aleatorização, evita que as soluções fiquem aprisionadas em ótimos locais e, ao mesmo tempo, aumenta a diversidade das soluções. A melhor combinação desses dois componentes principais, frequentemente, certifica que a otimalidade global seja alcançável.

Chattopadhyay *et al.* (2022) discutem sobre os algoritmos metaheurísticos mais amplamente utilizados, baseados na Física não-linear e os categorizam em seis domínios de acordo com o ramo da Física do qual se inspiraram. Os modelos incluem propostas enfatizando como cada algoritmo imita os processos físicos não-lineares para encontrar a solução ideal, como mecânica clássica, termodinâmica, eletromagnetismo, entre outros.

Kaveh *et al.* (2022) apresentam a formulação matemática do Efeito Doppler (ED) para desenvolver um novo otimizador metaheurístico baseado em princípios físicos. No algoritmo proposto, as velocidades dos observadores, que atuam como agentes de busca do algoritmo, são atualizadas com base na equação do ED.

Para Agushaka *et al.* (2023), os algoritmos metaheurísticos podem ser classificados como: baseados em população e baseados em trajetória. O Algoritmo Genético (*Genetic Algorithm*) é um exemplo de modelo baseado em população, uma vez que usa um conjunto de *strings*; da mesma forma ocorre com a Otimização por Enxame de Partículas (*Particle Swarm Optimization*), o Algoritmo do Vaga-Lume (*Firefly Algorithm*) e a Busca do Cuco (*Cuckoo Search*), pois esses algoritmos metaheurísticos utilizam múltiplos agentes ou partículas. Por outro lado, o Recozimento Simulado (*Simulated Annealing*) usa um único agente ou solução que se move pelo espaço de projeto ou espaço de busca de forma segmentada. Um movimento ou solução melhor é sempre aceito, enquanto um movimento não tão bom pode ser aceito com uma certa probabilidade. Os passos ou movimentos traçam uma trajetória no espaço de busca, com uma probabilidade não-nula de que essa trajetória possa alcançar o ótimo global (BOYD; VANDENBERGHE, 2004).

Como destacado por Azizi *et al.* (2023), existem vários algoritmos de otimização fundamentados na Física: O algoritmo *Big Bang Big Crunch*, inspirado nas teorias da evolução do universo; o algoritmo proeminente da otimização da Solubilidade de Gases de Henry, que imita o comportamento regido pela lei de Henry; o Busca de Orbitais Atômicos é outro algoritmo no qual os princípios fundamentais da Física são usados como fonte de inspiração.

Os algoritmos metaheurísticos baseados em princípios físicos são técnicas de otimização inspiradas que oferecem soluções robustas e flexíveis para problemas complexos, não-lineares e de alta dimensionalidade. Uma das grandes vantagens desses algoritmos refere-se a conseguir explorar os melhores caminhos, com consumo energético ótimo, evitando obstáculos pertencentes à própria “topografia” da função objetivo. A fim de aprimorar o processo de otimização, Azizi *et al.* (2023) propõem o *Energy Valley Optimizer* (EVO), algoritmo metaheurístico inspirado em princípios avançados da Física relacionados à estabilidade e aos diferentes modos de decaimento de partículas.

Sharieh *et al.* (2025) examinam o desempenho algoritmos metaheurísticos baseados em Física - Algoritmo Semelhante ao Eletromagnetismo, Algoritmo de Busca Fluida, Algoritmo de busca Gravitacional – e destaca que esses modelos demonstram excelente desempenho na resolução de problemas de otimização com restrições em diversas áreas.

Razavi-Termeh *et al.* (2025) apresentam uma pesquisa cujo objetivo é investigar a eficácia da utilização de algoritmos metaheurísticos baseados em princípios físicos, em combinação com modelos de aprendizado de máquina em conjunto, para o mapeamento da suscetibilidade a deslizamentos de terra. O estudo demonstrou o potencial dessa abordagem para melhorar significativamente a precisão dos mapas de suscetibilidade.

Saad *et al.* (2026) apresentam o Otimizador de Transformada de Fourier, uma estrutura Metaheurística que incorpora a análise no domínio da frequência por meio da Transformada Discreta de Fourier. O método proposto permite atualizações da solução impulsionadas por transformações baseadas em frequência, visando alcançar um equilíbrio mais eficaz entre exploração e exploração.

3 METODOLOGIA

O funcionamento do RLC Otimizador (RLCO) baseia-se na busca pelo estado de impedância mínima. Para um problema de otimização, $n - dimensional$, cada agente i é tratado como um circuito RLC independente, operando em uma frequência angular ω_i , que representa a solução candidata. O algoritmo foi implementado em Linguagem de Computação Científica OCTAVE (EATON *et al.*, 2024) podendo ser executado, também, em Linguagem MATLAB de Computação Científica (MATHWORKS, 2025).

3.1 O Espaço de Busca como Impedância (Z)

A função objetivo $f(x)$ que se deseja minimizar é mapeada como a Resistência Ativa (R) do sistema. No entanto, para incluir a dinâmica de movimento, define-se a Impedância Complexa (Z) total de cada agente, conforme indica a Equação (2).

$$Z_i = \sqrt{R_i^2 + (X_{L,i} - X_{C,i})^2} \quad (2)$$

Em que as reatâncias são definidas em função da posição atual do agente (ω_i):

- ✦ $X_{L,i}$ a Reatância Indutiva \rightarrow representa a inércia do agente, $X_{L,i} = \omega_i \cdot L$;
- ✦ $X_{C,i}$ a Reatância Capacitiva \rightarrow representa a capacidade de exploração, $X_{C,i} = \frac{1}{\omega_i \cdot C}$.

A Corrente Elétrica (I) é o mecanismo de passo. A corrente do sistema é a magnitude do deslocamento do agente ao melhor ponto conhecido ($bestPos$). Como exibido por Alexander e Sadiku (2013), a Lei de Ohm generalizada para circuitos AC (*Alternating Current* ou Corrente Alternada) está representada na Equação (3):

$$I_i = \frac{V_{fonte}}{Z_i} \quad (3)$$

Dessa forma, quando o agente está longe do ótimo (alta impedância), a corrente I é baixa, gerando passos cautelosos. Quando o agente se aproxima da ressonância ($X_L \cong X_C$), a corrente atinge seu pico, acelerando a convergência.

3.2 O Ângulo de fase (φ) e Direcionalidade

O deslocamento não é apenas uma questão de magnitude, mas de direção. O ângulo de fase do circuito indica se o agente está operando em uma região predominantemente indutiva ou capacitiva, representada na Equação (4).

$$\varphi_i = \arctan\left(\frac{X_{L,i} - X_{C,i}}{R_i}\right) \quad (4)$$

3.3 Equação de Atualização e Movimento

A nova posição do agente (ω no tempo $t + 1$) é calculada integrando a magnitude da corrente e o fator de potência ($\cos\varphi$), conforme indica a Equação (5).

$$\omega_i(t + 1) = \omega_i(t) + [I_i \cdot \cos\varphi_i \cdot (\omega_{best} - \omega_i(t)) \cdot Q(t)] \quad (5)$$

Sendo, ω_{best} a melhor solução global até o momento; $Q(t)$ o Fator Adaptativo que decresce conforme o tempo de simulação aumenta, amortecendo as oscilações finais para garantir estabilidades no ponto ótimo.

3.4 Tratamento de Restrições via Penalidades de Impedância

As restrições de igualdade ($h(x) = 0$) e de desigualdade ($g(x) \leq 0$) são incorporadas diretamente na Resistência (R), como mostra a Equação (6).

$$R_{total} = f(x) + \sum \lambda \cdot |h(x)| + \sum \mu \cdot \max(0, g(x)) \quad (6)$$

Essa abordagem garante que zonas proibidas do espaço de buscas atuem como isolantes de altíssima impedância, repelindo os agentes de volta para a região viável. A Figura 4 destaca como o Fator Q descreve o amortecimento do circuito.

Figura 4. Influência do Fator Q na otimização.



Fonte: Autor.

Na formulação matemática do RLC Otimizador (RLCO), o λ desempenha o papel de um Fator de Penalidade Estática às restrições de igualdade. Em analogia com circuitos elétricos, interpreta-se o λ da seguinte forma:

- i. Função Técnica (Otimização) \rightarrow O λ é um multiplicador de grande magnitude (10^6 ou maior). Ele serve para converter uma violação de restrição em uma "resistência" virtual de extrema magnitude. Se a condição de igualdade $h(x) = 0$ não for atendida, o termo $\lambda \cdot |h(x)|$ adiciona um valor massivo à resistência R . Isso faz com que a impedância Z tenda ao infinito, reduzindo a "corrente" (aptidão) daquela solução para quase zero

$$\left(\lim_{x \rightarrow \text{conflito}} Z(x) = \infty \Rightarrow I(x) \approx 0 \right).$$

- ii. Analogia Física (O Circuito) → Considere que o λ representa a Resistividade do Isolante. Quando um agente tenta sair da trajetória determinada pela restrição de igualdade, é como se ele estivesse tentando passar corrente através de um material altamente isolante (como borracha ou cerâmica). O sistema "força" o agente a permanecer onde a resistência é baixa, ou seja, exatamente sobre a linha em que $h(x) = 0$.
- iii. Diferença entre λ e μ → a) o λ está associado a Igualdades ($h(x) = 0$). Como uma igualdade é estritamente rígida (qualquer desvio de zero é computado como erro), o parâmetro λ impõe uma penalização severa. b) o μ está associado a Desigualdades ($g(x) \leq 0$). Ele só "ativa" a resistência extra se o agente ultrapassar a fronteira proibida.

O RLCO apresenta uma estratégia de otimização superior na sua formulação, uma vez que emprega três mecanismos como hiperparâmetros de regularização: 1) Direcionalidade Física → O uso de $\cos\phi$ (Fator de Potência) substitui os coeficientes arbitrários de outros algoritmos. Ele faz com que o agente saiba se precisa "adiantar" ou "atrasar" sua busca em relação ao ponto de ressonância. 2) Sintonia Adaptativa → O Fator Q controla a largura da banda de busca. No início, a banda é larga (permite erros e exploração); no fim, a banda é estreita (exige precisão absoluta). 3) Tratamento de Restrições → Ao somar as penalidades diretamente na resistência (R), o algoritmo trata violações como materiais isolantes que impedem a passagem da corrente, forçando os agentes a convergirem apenas para as regiões permitidas.

3.5 O Algoritmo passo a passo

O fluxo de execução do RLCO é dividido em três fases principais: Inicialização, Ciclo de Ressonância (busca) e Refinamento de Banda.

1ª fase → Procedimento de Inicialização: Nesta fase, o algoritmo define o "ambiente elétrico". Cada agente i recebe uma posição inicial aleatória ω_i dentro dos limites $[\omega_{min}, \omega_{max}]$, que representa sua frequência angular de operação. As velocidades iniciais (correntes de deslocamento) são zeradas, simulando um sistema em repouso antes da aplicação da tensão de excitação V_{fonte} .

2ª fase → Ciclo de Ressonância (*Loop* principal): Para cada iteração t , o algoritmo executa os seguintes subpassos para cada agente:

- i) Cálculo da Resistência Ativa (R) → A função objetivo $f(x)$ é avaliada. Caso exista violação de restrições, as penalidades λ (igualdade) e μ (desigualdade) são somadas, elevando a resistência e simulando um material isolante, como indica a Equação (7).

$$R_{total} = f(x) + Penalidades + R_{base} \quad (7)$$

- ii) Determinação das Reatâncias e Impedâncias (Z) → O algoritmo calcula a oposição imaginária da “distância” que a frequência atual, como mostra a Equação (8).

$$Z = \sqrt{R_{total}^2 + (X_L - X_C)^2} \quad (8)$$

3ª fase → Refinamento de Banda (Fator Q Adaptativo): Diferente de algoritmos com parâmetros fixos, o RLCO utiliza um Fator Q dinâmico. Esse fator autoajustável é adaptativo da seguinte maneira:

- ✦ Baixa Seletividade (Início): O algoritmo aceita uma banda larga de frequências, permitindo que os agentes explorem o espaço globalmente.
- ✦ Alta Seletividade (Final): A curva de ressonância se estreita drasticamente. Apenas soluções muito próximas do ótimo geram "corrente" suficiente para movimento, resultando em um ajuste fino de alta precisão.

A Figura 5 representa o pseudocódigo lógico do algoritmo de otimização RLCO.


Figura 5. RLCO passo a passo.



Fonte: Autor.

A Figura 6 exibe a performance do algoritmo RLCO com a execução do mecanismo, Fator Q Adaptativo, modulando a seletividade da busca: uma banda larga inicial para exploração global e uma banda estreita final para o refinamento preciso no ponto de ressonância (ótimo global).

Figura 6. Fator Q em operação.



Fonte: Autor.

Testes realizados em funções de *benchmark* com restrições rígidas de igualdade e desigualdade demonstram que a incorporação de penalidades de impedância (λ , μ) confere robustez ao sistema, permitindo uma convergência estável e evitando mínimos locais. Os resultados validam o RLCO como uma ferramenta eficaz e fisicamente interpretável para problemas complexos da ciência e da engenharia.

4 RESULTADOS

Para aferir a eficácia e validar o desempenho do RLC Otimizador (RLCO), o algoritmo foi submetido a um protocolo de testes utilizando quatro funções de referência (*benchmarks*) amplamente consolidadas na literatura de otimização: *Sphere*, *Rastrigin*, *Rosenbrock* e *Ackley*. Essas funções permitem avaliar a robustez dos algoritmos em diversos gradientes de complexidade, abrangendo desde superfícies convexas unimodais até paisagens de busca altamente não-lineares, caracterizadas por uma densa distribuição de mínimos locais. As definições algébricas para o caso geral de n – dimensões estão representadas nas Equações (9), (10), (11) e (12).

4.1 Função Sphere

Esta função constitui o modelo analítico elementar para a avaliação da taxa de convergência algorítmica. Devido às suas propriedades de continuidade, convexidade e unimodalidade, ela atua como um controle fundamental para aferir a eficiência computacional. Seu mínimo global é dado por $f(x) = 0$ em $x = (0, \dots, 0)$. O Gráfico 1a ilustra a topologia da Função *Sphere*, evidenciando sua geometria unimodal e a suavidade de seu gradiente em direção ao mínimo global, para $n = 2$ no intervalo $[x, y] = (-5: 5, -5: 5)$. O Gráfico 1b exibe o valor da função objetivo sendo minimizado: quanto menor o *fitness*, "mais apto" é o agente.

$$f(x) = \sum_{i=1}^n x_i^2 \quad (9)$$

Valores otimizados via RLCO: $x = 0,0002, y = -0,0036, f(x, y) = 1,33 \cdot 10^{-5}$.

Gráfico 1a - Comportamento da Função *Sphere*.


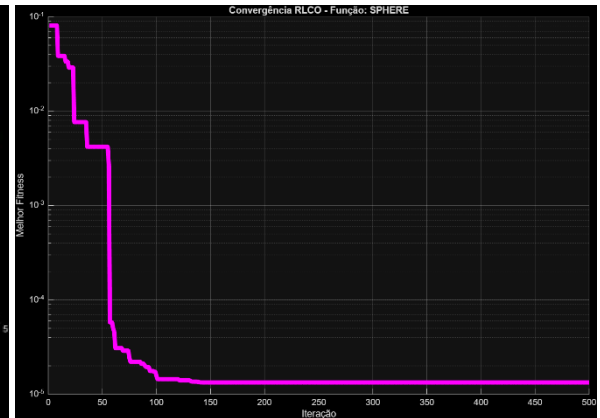


Gráfico 1b - Otimização da Função *fitness* (9).



Fonte: Autor.

4.2 Função Rastrigin

Baseada na função *Sphere*, porém, com o acréscimo de uma modulação de cosseno para criar várias irregularidades. Devido à sua natureza altamente multimodal, esta função apresenta uma superfície de custo complexa, induzindo algoritmos de busca local à convergência prematura em mínimos locais (subótimos). Seu mínimo global é dado por $f(x) = 0$ em $x = (0, \dots, 0)$. O perfil topográfico da Função *Rastrigin* é detalhado no Gráfico 2a, destacando-se pela presença de múltiplos mínimos locais e pela natureza não-convexa de seu domínio de busca, para $n = 2$ no intervalo $[x, y] = (-5: 5, -5: 5)$.

O Gráfico 2b mostra o valor da função objetivo sendo minimizado: quanto menor o *fitness*, "mais apto" é o agente.

$$f(x) = 10n + \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i)] \quad (10)$$

Valores otimizados via RLCO: $x = 0,0014, y = 0,0011, f(x, y) = 6,38. 10^{-4}$.

Gráfico 2a -Topografia da Função Rastrigin.





Gráfico 2b - Otimização da Função *fitness* (10).



Fonte: Autor.

4.3 Função Rosenbrock

Também conhecida como "Vale de Rosenbrock" ou "Função Banana". Seu mínimo global está no interior de um vale estreito e curvado. A localização da topografia do vale é obtida com relativa facilidade. Contudo, a estabilização do gradiente no ponto de mínimo exato é o principal desafio à eficiência do algoritmo. Seu mínimo global é dado por $f(x) = 0$ em $x = (1, \dots, 1)$. O perfil de convergência da Função *Rosenbrock* é ilustrado no Gráfico 3a, destacando a superfície de custo não-convexa que dificulta a progressão do gradiente em direção ao ponto de ótimo, para $n = 2$ no intervalo $[x, y] = (-2: 2, -1: 3)$. O seu característico vale parabólico exige alta precisão algorítmica à convergência do mínimo global. O Gráfico 3b destaca o valor da função objetivo sendo minimizado: quanto menor o *fitness*, "mais apto" é o agente.

$$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (1 - x_i)^2] \quad (11)$$

Valores otimizados via RLCO: $x = 0,9813, y = 0,9628, f(x, y) = 3,51. 10^{-4}$.

Gráfico 3a - Perfil da Função *Rosenbrock*.


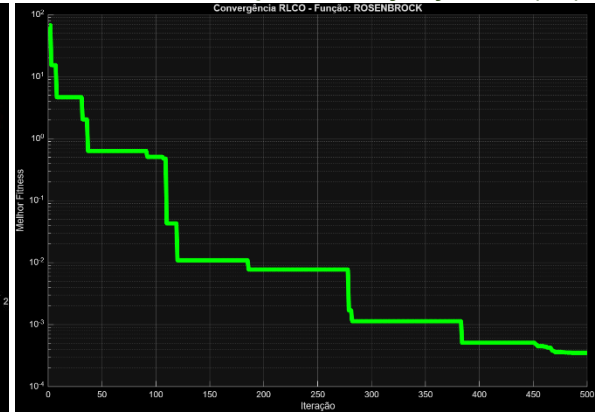


Gráfico 3b - Otimização da Função *fitness* (11).



Fonte: Autor.

4.4 Função Ackley

Esta função é caracterizada por uma superfície quase plana em suas extremidades, mas com um poço profundo e estreito no centro. Algoritmos de busca baseados estritamente em gradientes locais são suscetíveis à estagnação em mínimos locais ou pontos de sela, falhando em explorar a topologia global da função. Seu mínimo global é dado por $f(x) = 0$ em $x = (0, \dots, 0)$. O Gráfico 4a mostra topologia multimodal da Função *Ackley*, com pequenas oscilações nas bordas, transitando para uma singularidade central profunda, para $n = 2$ no intervalo $[x, y] = (-5: 5, -5: 5)$. O Gráfico 4b destaca o valor da função objetivo sendo minimizado: quanto menor o *fitness*, "mais apto" é o agente.

$$f(x) = -20 \exp\left(0,2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e \quad (12)$$

Valores otimizados via RLCO: $x = 0,0055, y = -0,0010, f(x, y) = 1,68 \cdot 10^{-2}$.

Gráfico 4a - Topologia da Função *Ackley*.

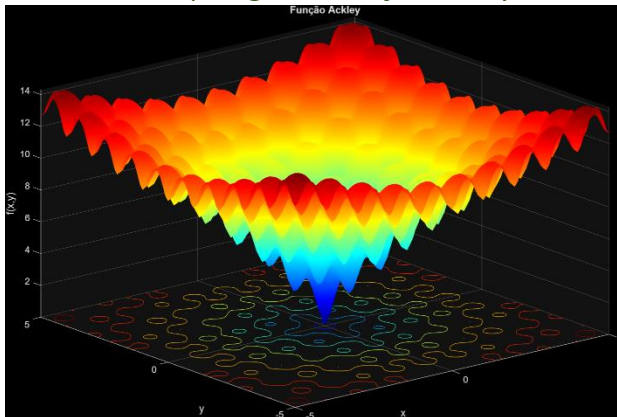



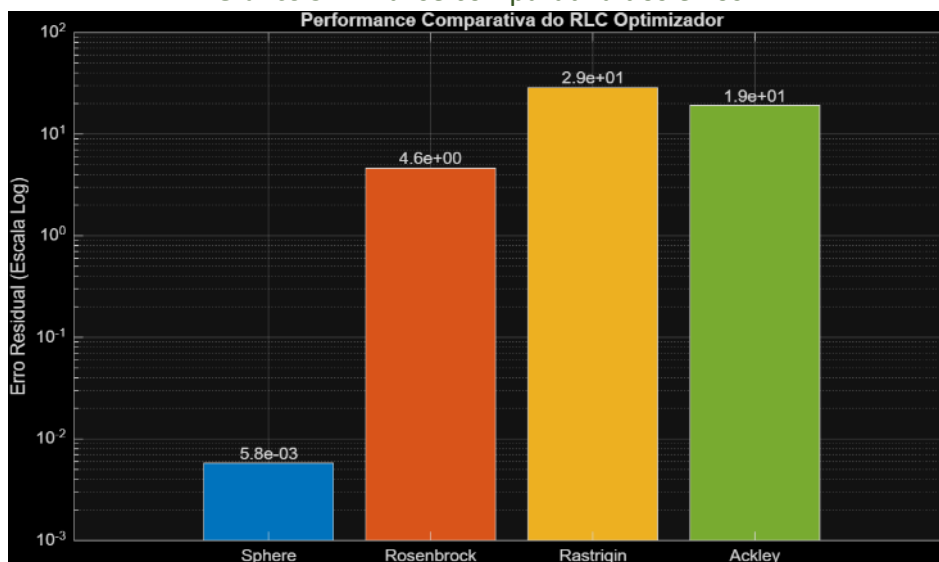
Gráfico 4b - Otimização da Função *fitness* (12).



Fonte: Autor.

O Gráfico 5 exibe um histograma com os erros finais, comparando e avaliando a precisão do algoritmo RLCO em diferentes modelos matemáticos, referente às quatro funções de *benchmark* aplicadas, *Sphere*, *Rosenbrock*, *Rastrigin* e *Ackley*.

Gráfico 5 – Análise comparativa dos erros.



Fonte: Autor.

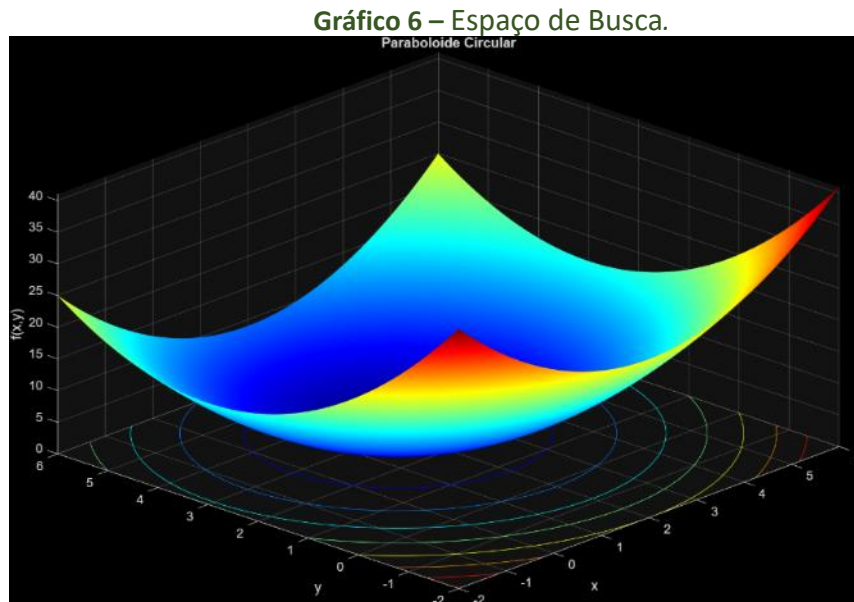
- ✦ Para a Função *Sphere* (azul), espera-se o menor erro. Dada a natureza estritamente convexa e a suavidade da superfície, o ponto de convergência apresenta estabilidade assintótica, permitindo que o sistema atinja a boa precisão sem a interferência de ruídos numéricos ou instabilidades de gradiente
- ✦ Para a Função *Rosenbrock* (laranja), o erro costuma ser maior que 10^{-1} . O algoritmo RLCO requer um número elevado de iterações para percorrer o vale parabólico de baixa curvatura, onde a atenuada variação da impedância (gradiente reduzido) resulta em uma progressão assintótica lenta em direção ao ponto de ótimo.
- ✦ Para a Função *Rastrigin* (amarela), a magnitude reduzida do erro evidencia que a perturbação térmica atuou como um mecanismo de desestabilização de estados subótimos, impedindo a estagnação prematura em regiões de mínimo local e conduzindo o sistema ao estado de energia mínima.
- ✦ Para a Função *Ackley* (verde), o desempenho do RLCO nesta função é superior devido à isotropia da região periférica, onde a impedância constante evita desvios erráticos. A transição para a singularidade central gera um gradiente de potencial elevado — analogamente a um pico de corrente — que acelera a convergência dos agentes em direção ao mínimo global.

4.5 Função Paraboloide Circular

Para testes com restrições de igualdade e de desigualdade, no RLCO, utilizou-se a Função do Paraboloide Circular, representada pela Equação (13). Na análise matemática de otimização, essa função é classificada como uma estritamente convexa e unimodal, o que significa que possui um único ponto crítico que é, obrigatoriamente, o seu mínimo global, cujos valores são: $x = 2$; $y = 3$, $f(x, y) = 0$.

$$f(x, y) = x^2 + y^2 - 4x - 6y + 13 \quad (13)$$

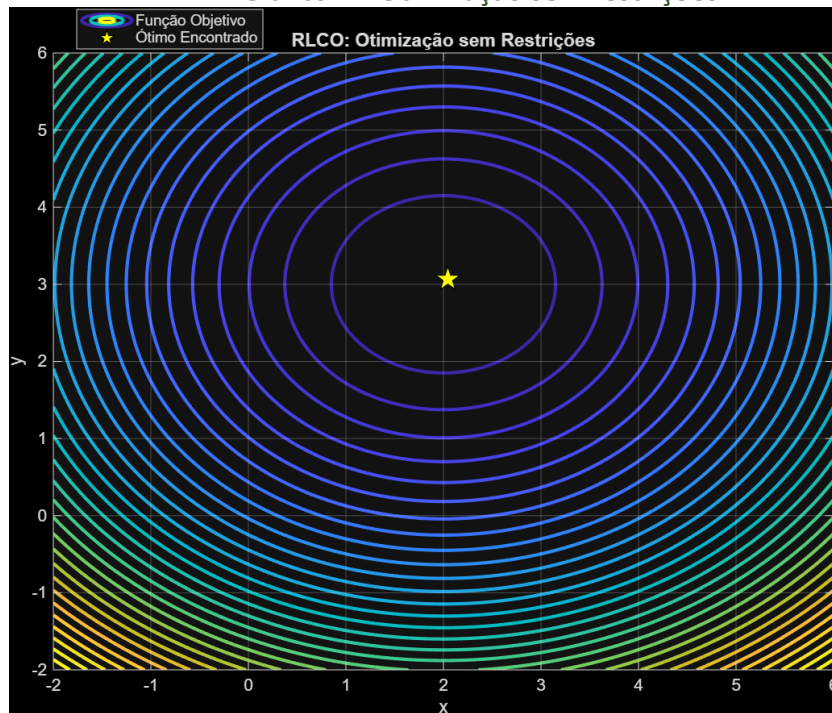
O Gráfico 6 mostra o comportamento da Equação (13), considerando que ela é a função objetivo a ser otimizada, com e sem restrições.



Fonte: Autor.

O Gráfico 7 mostra o resultado da otimização, sem restrições, da função objetivo, representada pela Equação (13). Os valores ótimos encontrados, pelo RLCO, são: $x = 2,0036$; $y = 2,9561$; $f(x, y) = 0,0019$.

Gráfico 7 – Otimização sem restrições.

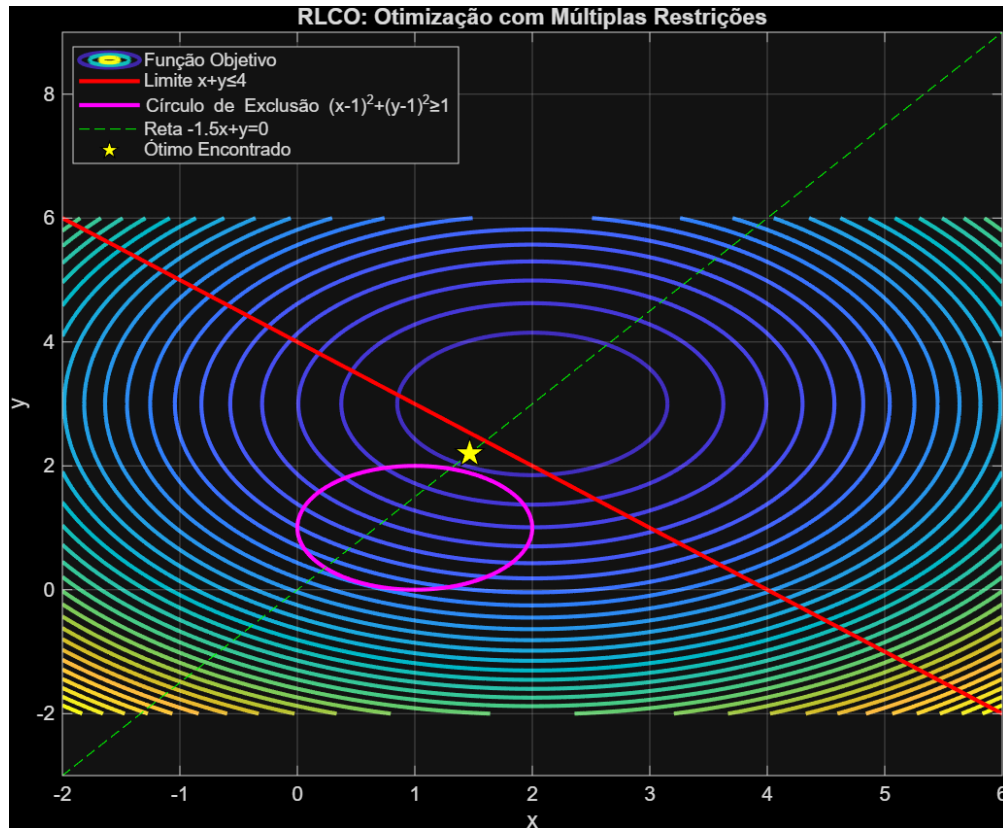


O Gráfico 8 mostra o resultado da otimização, com restrições, da função objetivo, representada pela Equação (13). As penalidades aplicadas estão exibidas no Sistema de Equações (14).

$$\begin{aligned} \min f(x, y) &= x^2 + y^2 - 4x - 6y + 13 && (14) \\ \text{Sujeito a} & \\ x + y &\leq 4 && (\text{Restrição de desigualdade}) \\ -1,5x + y &= 0 && (\text{Restrição de igualdade}) \\ (x - 1)^2 + (y - 1)^2 &\geq 1 && (\text{Restrição não-linear}) \end{aligned}$$

Os valores ótimos encontrados, pelo RLCO, considerando as restrições operacionais são: $x = 1,4664$; $y = 2,2043$; $f(x, y) = 22,8455$.

Gráfico 8 – Otimização com restrições.



Fonte: Autor.

Agentes com um *fitness* alto encontram maior resistência elétrica, movendo-se com menos eficiência, enquanto o agente com o "Melhor Fitness" define o referencial de condutividade para o grupo. Nas funções, *benchmarks*, testadas, o "Melhor Fitness" indica a proximidade do valor real do mínimo global. Os gráficos com as funções *fitness* (em escala logarítmica no eixo *y*) mostram a evolução desse valor ao longo do tempo. Os decaimentos das linhas indicam que o algoritmo RLCO está "aprendendo" ou "refinando" a solução. Os Platôs (linhas retas horizontais), indicam que o algoritmo RLCO está estagnado em um valor da função *fitness* e não consegue encontrar uma solução melhor, pois, pode estar preso em um mínimo local.

5 DISCUSSÃO

Os resultados obtidos mediante as simulações no RLCO permitem uma análise detalhada da dinâmica de busca e da capacidade de sintonização do algoritmo. A interpretação foca em dois pilares: a eficiência da convergência e a precisão da navegação no espaço de busca restrito.

5.1. Análise da Curva de Convergência (Impedância vs. Iterações)

O gráfico de convergência, produzido em escala semilogarítmica, para a Impedância (Z), revela o comportamento do sistema ao longo do tempo. No início da simulação, observa-se uma queda acentuada nos valores de Z . Fisicamente, isso representa os agentes saindo de regiões de "alta resistência" (soluções ruins ou zonas proibidas) e entrando no canal de baixa impedância em direção à ressonância.

- ✦ Estabilidade: A ausência de grandes oscilações nas iterações finais indica que o Fator Q Adaptativo cumpriu seu papel, estreitando a banda de busca e permitindo que os agentes "sintonizassem" o ótimo sem ultrapassá-lo (*overshooting*).
- ✦ Velocidade: A rapidez com que o $\log Z$ estabiliza demonstra que a Lei de Ohm aplicada ao passo de busca é eficiente em acelerar os agentes quando estão distantes do alvo e desacelerá-los conforme a fase (φ) se aproxima de zero.

5.2. Interpretação da Superfície de Contorno e Restrições

Os gráficos com curvas de nível oferecem uma visão do campo de potenciais onde os osciladores operam.

- ✦ Navegação Restrita: A linha tracejada que representa os modelos de restrição de igualdade, $h(x) = 0$, atua como um condutor de baixa resistência. É possível observar que o ponto de "Ressonância" (marcado pela estrela no gráfico) encontra-se exatamente sobre esta linha. Isso prova que as Penalidades de Impedância (λ) transformaram o restante do espaço em um isolante perfeito, forçando a convergência para a zona viável.
- ✦ Ponto de Ressonância: O sucesso do RLCO é confirmado quando o agente atinge as coordenadas calculadas. A proximidade entre o valor obtido e o valor teórico esperado para o mínimo da função paraboloide sob restrição comprova a precisão da metáfora RLC.

5.3. Discussão sobre os Parâmetros RLC

Durante os testes, observou-se que a Indutância (L) agiu efetivamente como um amortecedor de ruído numérico. Problemas com muitas oscilações locais foram suavizados pela "inércia indutiva", enquanto a Capacitância (C) garantiu que, mesmo em áreas planas do gráfico, os agentes mantivessem uma "tensão de busca" mínima para explorar o domínio.

Diferente de um modelo de otimização tradicional, em que os parâmetros são puramente matemáticos, a discussão, neste artigo, produz uma orientação mais científica: ajustar o RLCO é, na prática, projetar um filtro passa-faixa em que a frequência central é a solução do problema proposto.

6 CONCLUSÃO

O presente trabalho apresentou o desenvolvimento e a implementação do algoritmo RLC Otimizador (RLCO), uma metaheurística baseada na Física que utiliza a dinâmica de circuitos de corrente alternada para a busca de soluções ótimas em espaços complexos. A originalidade da abordagem reside na substituição dos operadores estocásticos convencionais pela mecânica de sintonia de frequência, em que a aptidão da solução é governada pela magnitude da corrente elétrica e pela fase do sistema.

Os resultados obtidos demonstram que a metáfora da Impedância (Z) como métrica de custo, aliada ao tratamento de restrições via Penalidades de Resistência (λ, μ), permite uma navegação fluida pelo espaço de busca, repelindo os agentes de zonas inviáveis através de barreiras de alta resistividade virtual. A introdução do Fator Q Adaptativo mostrou-se fundamental para o equilíbrio entre exploração e exploração: no início do processo, a baixa seletividade (banda larga) permitiu uma varredura global eficiente, enquanto a transição para um Q elevado (banda estreita) garantiu uma convergência precisa e estável no ponto de ressonância (ótimo global).

Comparado a algoritmos tradicionais, o RLCO destaca-se pela sua interpretabilidade física, oferecendo aos cientistas e engenheiros uma ferramenta na qual, os parâmetros de controle (L, C, R) possuem significados técnicos diretos. A convergência observada, nas simulações com as funções *benchmark* e nos testes com o parabolóide circular restrito, legitima a robustez do modelo em lidar com superfícies de erro multimodais e restrições rígidas de igualdade e desigualdade, lineares e não-lineares.

Além das contribuições técnicas, a fundamentação do RLCO estabelece um novo paradigma para a hibridização de princípios eletrodinâmicos com as Heurísticas de Natureza Física.

Ao demonstrar que o ajuste paramétrico preciso de um sistema ressonante equivale matematicamente à busca por estados de energia mínima, este estudo transcende a mera aplicação de uma analogia, validando a eficácia de modelos físicos na superação de limitações computacionais. A estabilidade numérica observada durante as transições de fase do sistema sugere que o algoritmo possui potencial para ser embarcado em sistemas de tempo real, no qual a previsibilidade do comportamento da “corrente de busca” é primordial. Dessa forma, esse trabalho extrapola a concepção de uma nova abordagem metaheurística, recomendando uma reavaliação de como Leis Clássicas da Física podem ser reconfiguradas para solucionar os desafios contemporâneos da otimização global.

Para pesquisas futuras, sugere-se a exploração do RLCO em problemas de alta dimensionalidade e a implementação de uma versão de ressonância paralela, que poderia oferecer vantagens em topologias de busca com múltiplos mínimos locais profundos. Em síntese, o RLCO consolida-se como uma alternativa promissora e matematicamente fundamentada para a otimização de sistemas complexos das Ciências e das Engenharias.

REFERÊNCIAS

ALEXANDER, C. K.; SADIKU, M. N. O. Fundamentos de Circuitos Elétricos. 5. ed. Porto Alegre: AMGH, 2013.

AZIZI M.; AICKELIN U.; KHORSHIDI H.; BAGHALZADEH, Shishehgarkhaneh M. Energy valley optimizer: a novel metaheuristic algorithm for global and engineering optimization. 2023.

BIRBIL, S.; FANG, S. C. "An Electromagnetism-like Mechanism for Global Optimization". Journal of Global Optimization, v. 25, n. 3, p. 263-282, 2003.

BOYD, S.; VANDENBERGHE, L. Convex Optimization. Cambridge University Press, 2004.

CAN, U.; ALATAS, B. Physics-Based Metaheuristic Algorithms for Global Optimization. Am. J. Inf. Sci. Comput. Eng. 2015.

CHATTOPADHYAY, Soumitri; MARIK, Aritra; PRAMANIK, Rishav. A Brief Overview of Physics-inspired Metaheuristic Optimization Techniques. Artificial Intelligence; Neural and Evolutionary Computing. 2022.

DORF, R. C.; SVOBODA, J. A. Introduction to Electric Circuits. 9. ed. Wiley. 2013.

EATON, J. W.; BATEMAN, D.; HAUBERG, S.; WEHBRING, R. *GNU Octave version 9.1.0 manual: a high-level interactive language for numerical computations*. CreateSpace Independent Publishing Platform. 2024.

HAYT, W. H.; KEMMERLY, J. E.; DURBIN, S. M. Análise de Circuitos em Engenharia. 8. ed. McGraw-Hill, 2012.

HALLIDAY, David; RESNICK, Robert. Fundamentos de Física, volume 3: Eletromagnetismo. Jearl Walker – 10ª. ed. - Rio de Janeiro: LTC. ISBN 978-85-216-3208-5. 2016.

KAVEH, Ali; HOSSEINI, Seyed M.; ZAERREZA, Ataollah. A Physics-based Metaheuristic Algorithm Based on Doppler Effect Phenomenon and Mean Euclidian Distance Threshold. Periodica Polytechnica Civil Engineering, [S. l.], v. 66, n. 3, p. 820–842. 2022.

KENNEDY, J.; EBERHART, R. "Particle Swarm Optimization". In: Proceedings of ICNN'95 - International Conference on Neural Networks, v. 4, p. 1942-1948. 1995.

MATHWORKS, Inc. MATLAB. Natick, Massachusetts: The MathWorks Inc., 2025.

RAZAVI-TERMEH, Seyed V.; SADEGHI-NIARAKI, Abolghasem; NAQVI, Rizwan A.; CHOI, Soo-Mi. Investigating the efficacy of physics-based metaheuristic algorithms in combination with explainable ensemble machine-learning models for landslide susceptibility mapping. Springer Nature. 2025.

SAAD, Mohammed R.; EMAM, Marwa M.; HOSNEY, Mosa E.; SAMEE, Nagwan A.; ALKANHEL, Reem I.; HOUSSEIN, Essam H. Fourier Transform Optimizer: A novel physics-inspired metaheuristic algorithm for optimization problems. Knowledge-Based Systems (Elsevier). 2026.

SHARIEH, Ahmad; MOSLEH, Heba; KABEER, Tasneem. Physics-Based Metaheuristic Optimization Algorithms for Pathfinding. Algorithms. 2025.

YANG, X. S. Nature-Inspired Optimization Algorithms. 2. ed. Elsevier. 2020.