57º SBPO
SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL
Gramado • RS
DE 5 A 9 DE OUTUBRO DE 2025

OTIMIZAÇÃO DO PLANEJAMENTO DE MANUTENÇÕES EM REDES DE TRANSMISSÃO DE ENERGIA ELÉTRICA

Pedro Henrique Rodrigues Pereira[1]
Programa de Pós-Graduação em Ciência da Computação
Universidade Estadual de Campinas (Unicamp)
Av. Albert Einstein, 1251 – 13083-852 – Campinas, SP, Brasil
pedro.pereira@students.ic.unicamp.br

André L. Maravilha
Departamento de Computação (DECOM-DV)
Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG)
R. Álvares de Azevedo, 400 – 35503-822 – Divinópolis, MG, Brasil
andre.maravilha@cefetmg.br

RESUMO

Este artigo trata do problema de planejamento de manutenções preventivas em redes de transmissão de energia elétrica, conforme proposto pela Réseau de Transport d'Électricité (RTE) no desafio ROADEF/EURO 2020. O planejamento consiste em definir os momentos de início das intervenções, respeitando restrições operacionais e de recursos, com o objetivo de minimizar os riscos decorrentes das incertezas do processo. Tais incertezas são representadas por valores de risco, expressos em unidades monetárias, que refletem a diminuição da confiabilidade do sistema devido à desconexão de trechos da rede durante as manutenções. O trabalho propõe uma estratégia híbrida que constrói uma solução inicial factível por meio da resolução de uma relaxação combinatória do problema e a aprimora com o uso do algoritmo de Evolução Diferencial (DE).

PALAVRAS CHAVE. Planejamento de Manutenções; Programação Inteira Mista; Evolução Diferencial.

EN&OG – PO na Área de Energia, Óleo e Gás, MH – Metaheurísticas

ABSTRACT

This paper considers the maintenance planning problem in electric power transmission networks, as proposed by Réseau de Transport d'Électricité (RTE) in the ROADEF/EURO 2020 challenge. The scheduling task involves determining the start times of maintenance interventions while respecting operational and resource constraints, with the goal of minimizing risks arising from process uncertainties. These uncertainties are represented by risk values, expressed in monetary units, which reflect the reduction in system reliability due to the disconnection of parts of the network during maintenance. The paper proposes a hybrid strategy that builds an initial feasible solution by solving a combinatorial relaxation of the problem and then refines it using the Differential Evolution (DE) algorithm.

KEYWORDS. Maintenance Planning; Mixed-Integer Programming; Differential Evolution.

EEN&OG – OR in Energy, Oil and Gas, MH – Metaheuristics

[1]Trabalho desenvolvido por Pedro Henrique Rodrigues Pereira enquanto aluno do curso de Bacharelado em Engenharia de Computação no CEFET-MG (Campus Divinópolis), sob orientação do Prof. André L. Maravilha (coautor).

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

1. Introdução

O consumo global de energia elétrica teve um aumento significativo, com uma previsão de atingir aproximadamente 30.700 terawatts-hora até 2026, em comparação com níveis inferiores registrados nas décadas passadas [International Energy Agency, 2024]. Parte desse aumento pode ser explicado pela explosão demográfica, crescimento econômico e avanços tecnológicos, como a expansão dos centros de processamento de dados e o crescente uso da inteligência artificial. Garantir uma entrega eficiente da energia elétrica pelas redes de transmissão e distribuição é uma das responsabilidades das operadoras de redes elétricas. Para isso, um plano de manutenções preventivas é essencial para manter um funcionamento adequado desse tipo de sistema.

Embora algumas manutenções possam ser realizadas em linhas vivas, onde a rede permanece energizada, há situações em que o desligamento de parte da rede é inevitável. Esses desligamentos, embora planejados, podem sobrecarregar outras partes da rede, impactando a confiabilidade do sistema de transmissão. Esse impacto na confiabilidade do sistema pode ser medido em termos de valores de risco [Lam, 2022]. Dessa forma, as intervenções de manutenção preventiva são operações críticas, exigindo um planejamento cuidadoso dessas operações na rede.

Este trabalho aborda a otimização do planejamento de manutenções preventivas em redes de transmissão de energia elétrica, mais especificamente, o problema proposto para o *ROADEF/EURO Challenge 2020*[2]. Esse problema foi apresentado pela *Réseau de Transport d'Électricité* (RTE), entidade responsável pela operação do maior sistema de transmissão de alta tensão da Europa, com quase 100.000 km de extensão.

No contexto do ROADEF/EURO Challenge 2020, a RTE apresenta uma abordagem de planejamento de manutenções preventivas em suas redes de transmissão dividida em três etapas sequenciais. Inicialmente, os valores de risco são calculados através de simulações de diferentes cenários futuros. Em seguida, esses valores são utilizados em uma abordagem de otimização para encontrar um plano de manutenções eficiente. Por fim, uma terceira etapa valida o planejamento [Ruiz et al., 2020]. O foco deste trabalho, assim como no ROADEF/EURO Challenge 2020, está na segunda etapa dessa abordagem: dado um conjunto de cenários futuros já simulados e com seus respectivos valores de risco, o objetivo é elaborar um planejamento que minimize o risco esperado, respeitando todas as restrições operacionais e de recursos.

As seções seguintes deste artigo estão organizadas da seguinte forma: Na Seção 2 são discutidos os trabalhos relacionados ao planejamento de manutenções. Em seguida, na Seção 3, o problema é descrito de forma detalhada e formulado como um problema de programação linear inteira mista (MIP, do inglês *mixed integer programming problem*). A Seção 4 apresenta a estratégia de otimização proposta para a resolução do problema. Nas Seções 5 e 6 são descritos e discutidos, respectivamente, o planejamento experimental e os resultados obtidos. Por fim, na Seção 7 são feitas as conclusões.

2. Trabalhos Relacionados

O planejamento de manutenções preventivas em redes de transmissão de energia elétrica desempenha um papel fundamental na garantia da confiabilidade do sistema. Esse processo envolve a consideração de fatores críticos, tais como a incerteza na geração de energia, restrições operacionais e a minimização de riscos de falhas. Crognier et al. [2021] destacam os desafios emergentes no planejamento de manutenção no cenário de transição energética, caracterizado pela crescente integração de fontes renováveis. Os autores argumentam que as abordagens tradicionais se tornam inadequadas diante das novas incertezas e restrições impostas pela geração renovável. Além disso,

[2] https://roadef.org/challenge/2020/en/index.php

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

os autores evidenciam que a maioria dos estudos existentes concentra-se no planejamento de manutenção de unidades geradoras, negligenciando, em grande parte, as particularidades das redes de transmissão e os impactos da transição energética.

Nesse sentido, Crognier et al. [2021] propõem uma metodologia que integra a incerteza operacional ao planejamento de manutenções preventivas em redes de transmissão de energia elétrica, proporcionando uma estratégia robusta e adaptável a diferentes cenários futuros, assegurando a viabilidade das práticas de manutenção a longo prazo. Esse trabalho é fundamental para esta discussão, pois ele descreve a metodologia empregada pela RTE (*Réseau de Transport d'Électricité*) e define o problema central abordado na ROADEF/EURO Challenge 2020, estabelecendo as diretrizes para o planejamento robusto de manutenções em redes de transmissão sob incertezas a partir da minimização do risco, caracterizado pela combinação do risco médio e do excesso de risco esperado nos cenários críticos. Esse excesso é dado por uma função quantil (ou Valor em Risco, VaR).

Para a resolução desse problema, Vasquez et al. [2023] propõem uma heurística híbrida baseada na penalização de cenários. Nessa estratégia, é resolvida uma relaxação combinatória do problema, inicialmente ignorando o excesso esperado e, iterativamente, penalizando os valores de risco, aproximando o valor do problema relaxado do problema original de forma progressiva. Além disso, é empregado uma busca local ao final de cada iteração para refinar as soluções geradas. Essa estratégia se mostrou bastante eficiente, garantindo o primeiro lugar no ROADEF/EURO Challenge 2020 aos autores.

No trabalho de Parreño et al. [2023] também é utilizada uma estratégia iterativa para aproximação do problema original a partir de uma relaxação que, inicialmente, ignora o excesso esperado de forma explícita na formulação. No entanto, ao invés de utilizar uma busca local a cada iteração, Parreño et al. [2023] mantém um conjunto das soluções geradas e, uma a uma, tenta melhorá-las com uma busca local baseada no *Variable Neighborhood Descent* (VND), explorando múltiplos movimentos de vizinhança. Por fim, as melhores soluções obtidas após o VND são submetidas a uma busca por *Path Relinking*. Essa estratégia garantiu aos autores o terceiro lugar na ROADEF/EURO Challenge 2020.

Lam [2022]; Gu et al. [2023] investigam diferentes problemas de otimização combinatória sob incerteza, dentre eles, o problema abordado na ROADEF/EURO Challenge 2020. Os autores apresentam uma formulação de programação linear inteira mista para o problema, dois métodos heurísticos que utilizam uma abordagem de confiança para lidar uma função objetivo baseada em quantil e, também, uma heurística baseada no *Iterated Local Search* (ILS) com perturbações autoadaptativas. Dentre estas estratégia, o ILS obteve um melhor desempenho, garantindo-lhe a segunda colocação na ROADEF/EURO Challenge 2020.

Woller et al. [2023] utilizam uma heurística baseada no *Adaptive Large Neighborhood Search* (ALNS) para a otimização do planejamento de manutenções, propondo operadores de destruição e reparo específicos ao problema. Para lidar com eventuais soluções infactíveis ao longo da busca realizada pelo ALNS, os autores adotaram uma estratégia de penalização de soluções inviáveis. Essa abordagem mostrou-se eficaz ao explorar o espaço de soluções, evitando a convergência prematura. O artigo também analisa a introdução de uma busca local, contribuindo significativamente para o desempenho geral da estratégia proposta.

A presença de uma função quantil para definição do excesso de risco esperado na função objetivo resulta em um problema não convexo. Apesar disso, é possível obter formulações MIP, ao custo do aumento significativo do número de variáveis (inclusive binárias) e restrições, e com convergência lenta [Beldiceanu, 2001]. Por isso, estratégias heurísticas são frequentemente adotadas, como pode ser observado nos trabalhos discutidos acima. Apesar disso, Gouvine [2023] explora a geração de desigualdades válidas para lidar com a dificuldade introduzida pela função quantil. O

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

autor propõe uma família de cortes e a utiliza na resolução do nó raiz de um *branch-and-cut* (nesse caso, o CPLEX), o que melhorou significativamente os limites e reduziu o tempo de solução.

Cattaruzza et al. [2024] também propõem o uso de cortes para obter formulações mais fortes, melhorando os limites gerados a partir da relaxação linear. Além disso, os autores utilizam um método de direção alternada sobreposto (OADM, do inglês *Overlapping Alternating Direction Method*) e um algoritmo de agrupamento adaptativo de cenários (ASCA, do inglês *Adaptive Scenario Clustering Approach*). Assim como a estratégia adotada por Vasquez et al. [2023], os autores integram abordagens exatas e heurísticas de forma mais colaborativa.

Os estudos discutidos acima abordam diferentes metodologias e técnicas de otimização, desde programação matemática a algoritmos heurísticos. Estes estudos fornecem a base para o desenvolvimento do presente trabalho, que propõe uma estratégia híbrida, utilizando um modelo de programação linear inteira mista para obter uma solução inicial válida, seguido pelo uso do algoritmo *Differential Evolution* (DE) como técnica de refinamento de solução.

3. Formulação Matemática

A formulação do problema, apresentada a seguir, baseia-se na proposta de Cattaruzza et al. [2024]. Seja $H = \{1, \ldots, T\}$ um horizonte de tempo discreto e finito, onde $T \in \mathbb{Z}_+^*$ denota seu comprimento total. Para cada instante $t \in H$, define-se S_t como o conjunto de cenários simulados. Adicionalmente, sejam I o conjunto de intervenções de manutenção a serem programadas e C o conjunto de recursos disponíveis. O horizonte de tempo para o início de cada intervenção $i \in I$ é representado por $H_i = \{1, \ldots, t^i_{\text{max}}\}$. Os demais parâmetros e variáveis são definidos conforme segue:

Parâmetros:

- $r_{i,t,t',s} \geq 0$ corresponde ao custo associado ao risco no instante $t \in H$, sob o cenário $s \in S_t$, caso a intervenção $i \in I$ seja iniciada em $t' \in H_i$.
- $w_{i,t,t',c}$ indica a quantidade do recurso $c \in C$ demandada no instante $t \in H$ pela intervenção $i \in I$, se esta for iniciada em $t' \in H_i$.
- Os parâmetros $u_{c,t}$ e $l_{c,t}$ representam, respectivamente, os limites superior e inferior do recurso $c \in C$ disponíveis ou requeridos no instante $t \in H$.
- $\Delta_{i,t'}$ denota a duração da intervenção $i \in I$ quando iniciada no instante $t' \in H_i$.
- O conjunto $E = \{(i, j, t)\} \subset I \times I \times H$ define as restrições de exclusão, em que uma tripla (i, j, t) indica que as intervenções i e j não podem ocorrer de forma simultânea no instante t.
- $\alpha \in [0, 1]$ representa o peso atribuído ao risco médio na função objetivo. Dessa forma, o excesso esperado terá um peso de $(1 - \alpha)$ na função objetivo.
- $\tau \in [0, 1]$ é nível do quantil definido para para o cálculo do excesso de risco. Com isso, para cada instante $t \in H$ são definidos valores $q_t = \lceil \tau \times |S_t| \rceil$.

Variáveis de Decisão:

- $x_{i,t'} \in \{0, 1\}$, uma variável binária que assume o valor 1 se a intervenção $i \in I$ iniciar no instante $t' \in H_i$, e 0 (zero) caso contrário.

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

- $y_{t,s} \in \{0,1\}$, uma variável binária que assume o valor 1 se o cenário $s \in S_t$ estiver entre os q_t cenários de menor risco no instante t, e 0 (zero) caso contrário.
- $z_t \geq 0$, uma variável contínua que representa, no instante $t \in H$, o maior valor de risco entre os q_t cenários de menor risco ($y_{t,s} = 1$).
- $\eta_t \geq 0$, uma variável contínua que quantifica o excesso de risco esperado no instante $t \in H$.

A partir dessas definições, o problema de planejamento de manutenção em redes de transmissão de energia elétrica pode ser formulado como um problema de programação linear inteira mista (MIP) da forma:

$$\text{Minimizar} \quad \alpha \sum_{t\in H} \sum_{s\in S_t} \sum_{i\in I} \sum_{t'\in H_i} \frac{r_{i,t,t',s}}{T|S_t|} x_{i,t'} + \frac{1-\alpha}{T} \sum_{t\in H} \eta_t \tag{1}$$

$$\text{s.a.:} \quad \sum_{t'\in H_i} x_{i,t'} = 1 \qquad \forall i \in I \tag{2}$$

$$\sum_{i\in I} \sum_{t'\in H_i} w_{i,t,t',c} x_{i,t'} \leq u_{c,t} \qquad \forall c \in C;\, t \in H \tag{3}$$

$$\sum_{i\in I} \sum_{t'\in H_i} w_{i,t,t',c} x_{i,t'} \geq l_{c,t} \qquad \forall c \in C;\, t \in H \tag{4}$$

$$\sum_{\substack{t'\in H_i:\\ t'\leq t;\\ t\leq t'+\Delta_{i,t'}-1}} x_{i,t'} + \sum_{\substack{t'\in H_j:\\ t'\leq t;\\ t\leq t'+\Delta_{j,t'}-1}} x_{j,t'} \leq 1 \qquad \forall (i,j,t) \in E \tag{5}$$

$$\sum_{s\in S_t} y_{t,s} \geq q_t \tag{6}$$

$$z_t \geq \sum_{i\in I} \sum_{t'\in H_i} r_{i,t,t',s} x_{i,t'} - M_{t,s}\,(1 - y_{t,s}) \qquad \forall s \in S_t \tag{7}$$

$$\eta_t \geq z_t - \frac{1}{|S_t|} \sum_{s\in S_t} \sum_{i\in I} \sum_{t'\in H_i} r_{i,t,t',s} x_{i,t'} \qquad \forall s \in S_t \tag{8}$$

$$x_{i,t'} \in \{0,1\} \qquad \forall i \in I; t' \in H_i \tag{9}$$

$$y_{t,s} \in \{0,1\} \qquad \forall s \in S_t \tag{10}$$

$$z_t \geq 0 \qquad \forall t \in H \tag{11}$$

$$\eta_t \geq 0 \qquad \forall t \in H \tag{12}$$

A função objetivo (1) minimiza o custo ponderado do risco do planejamento, composto por dois termos: (i) média dos riscos ao longo do horizonte e (ii) a média dos excessos esperados.

As restrições (2)–(5) asseguram as condições necessárias para um planejamento viável. Analisando cada uma separadamente, temos: as restrições (2) garantem que cada intervenção de manutenção tenha o tempo de início definido; as restrições (3) e (4) garantem que o total de recursos utilizado em cada instante esteja dentro dos limites superior e inferior, respectivamente; e as restrições (5) garantem que duas intervenções não sejam realizadas simultaneamente caso isso esteja determinado no conjunto de exclusões E.

As restrições (6)–(8) determinam os excessos esperados η_t para cada instante ao longo do horizonte de tempo. As restrições (6) e (7) calculam o valor do τ-quantil para cada instante, enquanto as restrições (8) asseguram que o valor de η_t seja pelo menos igual ao excesso esperado

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

para o respectivo instante t. A constante $M_{t,s}$ na Eq. (7), é um valor suficientemente grande e pode ser determinado como:

$$M_{t,s} = \sum_{i \in I} \max_{t \in H_i} \{r_i, t, t', s\} \tag{13}$$

Por fim, as restrições (9)–(12) definem o domínio das variáveis do modelo.

4. Metodologia

Para resolver o problema de planejamento de manutenção em redes de transmissão de energia elétrica, foi adotada uma abordagem similar à estratégia utilizada em [Parreño et al., 2023], no qual é resolvida uma relaxação combinatória do problema, desconsiderando o excesso esperado da formulação, seguido pelo uso de uma busca heurística considerando o problema completo.

4.1. Etapa 1 - Solução Inicial

Considerando a formulação matemática, Eqs. (1)–(12), apresentada para o problema, pode-se observar que as restrições (6)–(8) são necessárias apenas para o cálculo dos custos associados ao excesso de risco esperado. Ao desconsiderar as restrições (6)–(8), removendo as variáveis definidas (10)–(12), e reescrevendo a função objetivo como:

$$\text{Minimizar} \quad \alpha \sum_{t \in H} \sum_{s \in S_t} \sum_{i \in I} \sum_{t' \in H_i} \frac{r_{i,t,t',s}}{T|S_t|} x_{i,t'} \tag{14}$$

temos uma relaxação combinatória do problema original, na qual uma solução para essa relaxação é uma solução factível para o problema original, uma vez que as restrições de instante de início, recursos e exclusão são todas atendidas.

Dessa forma, a primeira etapa da estratégia proposta consiste em resolver essa relação combinatória, formada pelas Eqs. (14), (2)–(5), (9). Apesar dessa relaxação fornecer uma solução viável, ela não é necessariamente a solução ótima. No entanto, os casos em que o valor de excesso esperado associado à solução ótima da relaxação combinatória for zero, então, essa solução é ótima para o problema original.

4.2. Etapa 2 - Refinamento com o Algoritmo de Evolução Diferencial

O algoritmo de Evolução Diferencial (DE, do inglês *Differential Evolution*) é uma metaheurística originalmente proposta para a otimização de funções de variáveis contínuas [Storn e Price, 1997]. Apesar de sua simplicidade, o DE é muito eficiente: com poucos parâmetros de controle e operações aritméticas básicas, ele é capaz de convergir para regiões promissoras do espaço de busca e, em diversas classes de problemas, atingir até mesmo a solução ótima [Storn e Price, 1997]. Devido a essas características, o DE tem sido amplamente utilizado para a resolução de problemas de otimização em outros domínios, incluindo aqueles com variáveis discretas [Price et al., 2005; Onwubolu e Davendra, 2006; Prado et al., 2010].

O DE inicia o processo de otimização gerando aleatoriamente um conjunto de n_p soluções candidatas, cada uma representada como um vetor em $\mathbb{R}^n$. A cada iteração, o algoritmo explora o espaço de busca criando novos vetores através de operações de mutação e recombinação. Neste trabalho é adotada a seguinte notação: $\mathbf{x}_i^g$ corresponde à i-ésima solução candidata na iteração g, onde $i \in \{1, \ldots, n_p\}$. Cada componente $x_{i,j}^g$ representa o valor da j-ésima variável de decisão associada à solução $\mathbf{x}_i^g$. A estrutura básica do DE está descrita no Algoritmo 1.

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

Algoritmo 1: Algoritmo de Evolução Diferencial (DE)

1 Inicializa o conjunto de soluções $\{\mathbf{x}_1^0, \mathbf{x}_2^0, \ldots, \mathbf{x}_{n_p}^0\}$;
2 $g \leftarrow 0$;
3 **enquanto** *critério de parada não é satisfeito* **faça**
4 **para todo** $i \in \{1, 2, \ldots, n_p\}$ **faça**
5 Criar vetor de mutação $\mathbf{v}_i^g$; `// mutação: Seção 4.2.1`
6 Criar $\mathbf{u}_i^g$ a partir de $\mathbf{x}_i^g$ e $\mathbf{v}_i^g$; `// recombinação: Seção 4.2.2`
7 **se** $f(\mathbf{u}_i^g) \leq f(\mathbf{x}_i^g)$ **então**
8 $\mathbf{x}_i^{g+1} \leftarrow \mathbf{u}_i^g$;
9 **senão**
10 $\mathbf{x}_i^{g+1} \leftarrow \mathbf{x}_i^g$;
11 **fim**
12 **fim**
13 $g \leftarrow g + 1$;
14 **fim**
15 **retorna** $\arg\min_i f(\mathbf{x}_i^g)$;

Para o problema de planejamento de manutenção abordado neste trabalho, cada solução candidata foi representada por um vetor $\mathbf{x} \in \mathbb{Z}_+^n$, onde $n = |I|$ corresponde ao número total de intervenções. Cada componente x_j do vetor determina o instante de início da intervenção $j \in I$. Na criação do conjunto de soluções (linha 1), cada posição $x_{i,j}^0$ do vetor $\mathbf{x}_i^0$ é inicializada com valores inteiros aleatórios uniformemente distribuídos no intervalo $[1, t_{\max}^j]$. Ao final deste processo, as soluções são avaliadas e aquela de pior qualidade é substituída pela solução viável obtida na Etapa 1 (Seção 4.1).

O DE proposto neste trabalho permite a manutenção de soluções que violam as restrições Eq. (3)–(5). Para lidar com soluções inviáveis, o resultado da avaliação $f(\cdot)$ de uma solução (linhas 7 e 15 do Algoritmo 1) é uma tupla $f_{c1}, f_{c2}, f_{\text{obj}}$ onde: f_{c1} contabiliza o número de restrições de recursos e exclusões violadas (Eq. (3)–(5)); f_{c2} é a soma dos excessos e déficits relacionados às restrições de recursos violadas (Eq. (3)–(4)); e f_{obj} corresponde ao valor da função objetivo original (Eq. (1)). Neste sentido, é adotada uma comparação lexicográfica entre as soluções, seguindo uma ordem de prioridade onde primeiro minimiza-se as violações às restrições do problema para, então, considerar o valor da função objetivo.

Diversas abordagens para as operações de mutação (linha 5) e recombinação (linha 6) para o DE são encontradas na literatura [Opara e Arabas, 2018; Campelo e Botelho, 2016]. Após uma análise preliminar, optou-se pelo uso das variantes *DE/best/1* e *DE/rand/1* para a etapa de mutação, combinadas com o cruzamento exponencial para a etapa de recombinação. A descrição das operações de mutação e recombinação utilizadas no presente trabalho são apresentadas, respectivamente, nas subseções 4.2.1 e 4.2.2 abaixo.

4.2.1. Mutação

As variantes *DE/best/1* e *DE/rand/1* foram empregadas para a geração dos vetores de mutação $\mathbf{v}_i^g$ (linha 5 do Algoritmo1), conforme a Eq. (15):

$$\mathbf{v}_i^g \leftarrow \mathbf{x}_{\text{b}}^g + F \cdot (\mathbf{x}_{r_1}^g - \mathbf{x}_{r_2}^g) \tag{15}$$

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

onde, $\mathbf{x}_b^g$ representa a melhor solução corrente (para *DE/best/1*) ou uma solução aleatória (para *DE/rand/1*), enquanto $\mathbf{x}_{r_1}^g$ e $\mathbf{x}_{r_2}^g$ correspondem a soluções distintas selecionadas aleatoriamente, com $r_1 \neq r_2 \neq i$. O parâmetro $F \in (0;\ 2]$ representa o fator de escala, controlando a intensidade da perturbação aplicada pela diferença entre as soluções.

A estratégia *DE/best/1* promove uma busca nas proximidades da melhor solução corrente, característica relevante considerando o objetivo de refinamento da solução inicial obtida na Etapa 1. Contudo, para minimizar o risco de convergência prematura, implementou-se um mecanismo de alternância com *DE/rand/1*, que introduz maior diversidade na exploração do espaço de busca. A seleção entre as estratégias é determinada aleatoriamente a cada iteração, com probabilidade p_{best} de se escolher a estratégia *DE/best/1*.

Durante a criação do vetor mutante $\mathbf{v}_i^g$ (Eq. (15)), os valores gerados podem apresentar componentes fracionárias ou extrapolarem os limites estabelecidos para o início das intervenções. Portanto, na criação de $\mathbf{v}_i^g$, cada elemento $v_{i,j}^g$ é submetido a duas operações sequenciais: primeiro, um arredondamento para o inteiro mais próximo e, em seguida, um ajuste para assegurar que o valor resultante permaneça dentro do intervalo $[1, t_{\text{max}}^j]$, onde t_{max}^j representa o instante máximo permitido para o início da j-ésima intervenção.

4.2.2. Recombinação

Na etapa de recombinação (linha 6 do Algoritmo 1), o vetor de teste $\mathbf{u}_i^g$ é construído da seleção de componentes do vetor mutante $\mathbf{v}_i^g$ e da solução alvo $\mathbf{x}_i^g$. Neste trabalho, foi adotada a recombinação exponencial por apresentar um desempenho superior em comparação com outras abordagens tradicionais de DE [Campelo e Botelho, 2016], a qual é descrita na Eq. (16):

$$u_{i,j}^g = \begin{cases} v_{i,j}^g & \text{se } k_{i,2} \leq n \text{ e } k_{i,1} \leq j \leq k_{i,2} \\ v_{i,j}^g & \text{se } k_{i,2} > n \text{ e } (j \geq k_{i,1} \text{ ou } j \leq k_{i,2} \bmod n) \\ x_{i,j}^g & \text{caso contrário} \end{cases} \tag{16}$$

em que $k_{i,1} \in [1, n]$ é um conjunto de índices selecionados aleatoriamente e $k_{i,2} = k_{i,1} + d_i$, com $d_i \in [1, n]$ sendo um conjunto de valores amostrados de uma distribuição exponencial:

$$P(d_i = x) = \frac{\rho^{x-1} - \rho^x}{\sum_{y=1}^{n} (\rho^{y-1} - \rho^y)} \tag{17}$$

onde o parâmetro $\rho \in (0, 1)$ controla a forma desta distribuição, influenciando diretamente o valor de d_i, que determina o número de componentes copiados de $\mathbf{v}_i^g$. À medida ρ aumenta, o número de componentes do vetor de teste $\mathbf{u}_i^g$ que são copiados do vetor de mutação $\mathbf{v}_i^g$ tende a aumentar.

4.3. Transição Entre as Etapas

A abordagem proposta estrutura-se em duas fases consecutivas de processamento: a Etapa 1 (Seção 4.1) gera uma solução viável inicial através de um modelo MIP, enquanto a Etapa 2 (Seção 4.2) aplica o algoritmo DE para refinamento desta solução.

Embora o modelo MIP da Etapa 1 não incorpore explicitamente a minimização do excesso de risco esperado, sua resolução completa – até a comprovação de otimalidade – pode demandar um tempo computacional considerável. Para contornar esta situação, pode-se limitar o tempo máximo dedicado à execução da Etapa 1, procedendo da seguinte forma:

- Caso a solução ótima seja encontrada antes do limite de tempo estabelecido, o tempo remanescente é direcionado para a Etapa 2, permitindo um processamento mais extenso com o DE.

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

- Por outro lado, caso o tempo máximo da Etapa 1 seja atingido sem que a solução ótima tenha sido identificada, o processo é interrompido e a melhor solução disponível até então é utilizada como entrada para a Etapa 2. Dessa forma, garante-se que o algoritmo avance para a próxima fase, aproveitando os resultados obtidos.

É importante ressaltar que o tempo limite da Etapa 1 pode ser atingido sem que nenhuma solução viável tenha sido identificada. Nesse caso, o algoritmo pode prosseguir para a Etapa 2, porém sem a inclusão desta solução no conjunto inicial de soluções do DE. Com isso, é assegurado a continuidade do processo de otimização mesmo na ausência de uma solução inicial, embora com potencial impacto no tempo necessário para convergência, pois partirá de condições menos favoráveis.

5. Planejamento Experimental

O planejamento experimental seguiu as diretrizes estabelecidas pelo ROADEF/EURO Challenge 2020, com um limite máximo de execução de 15 minutos (900 segundos). Desse total, limitou-se a 5 minutos (300 segundos) a resolução do modelo MIP na Etapa 1 (Seção 4.1), destinando o tempo restante à Etapa 2 (Seção 4.2) para refinamento da solução através do DE.

A implementação foi desenvolvida em C++ (padrão C++17), compilada com g++ (versão 13.3.0). Para a resolução do MIP, utilizou-se o Gurobi Optimizer (versão 12.0.1) [Gurobi Optimization, LLC, 2023]. Considerando a independência entre as iterações do laço interno do DE (linhas 4–12 do Algoritmo 1), foi utilizado processamento paralelo na implementação desta etapa. O código-fonte completo está disponível publicamente em `https://github.com/andremaravilha/Paper-SBPO-2025`.

Os experimentos foram executados em uma máquina virtual com 4 *threads* de processamento, 16 GiB de memória principal e sistema operacional Linux Ubuntu 24.04.2 LTS (64-bit). O máquina física subjacente estava equipada com dois processadores Intel Xeon Silver 4116 (2.10 GHz), 128 GiB de memória principal e operando sob o sistema Xen Hypervisor. Apesar da capacidade de processamento disponível, o Gurobi e o DE foram limitados a utilizar no máximo duas *threads*, e assim, mantendo uma similaridade ao ambiente de hardware adotado na competição, possibilitando uma comparação justa.

5.1. Instâncias de Teste

Para avaliação de desempenho, foram utilizadas as instâncias oficiais da competição[3], que representam diversos cenários operacionais de redes elétricas. A base de testes compreende quatro conjuntos (A, B, C e X), cada um contendo 15 instâncias no formato JSON, com tamanhos totais de 1,24 GiB (A), 9,09 GiB (B), 4,69 GiB (C) e 6,68 GiB (X), respectivamente.

5.2. Protocolo Experimental

Para avaliação do desempenho da estratégia proposta, adotou-se um protocolo experimental dividido em duas etapas. Inicialmente, os conjuntos de instâncias A e B foram utilizados exclusivamente para o ajuste dos parâmetros do DE. Em seguida, o conjunto C foi empregado para a análise comparativa do método proposto.

Cada instância do conjunto C foi resolvida em 10 execuções independentes. Durante essas execuções, foram registrados a solução gerada na Etapa 1, correspondente à relaxação combinatória, quanto a solução obtida após a aplicação do DE na Etapa 2. Essa abordagem permitiu quantificar o ganho relativo proporcionado pelo DE em relação à solução inicial. Por fim, os resultados foram comparados com outras estratégias disponíveis na literatura, assegurando uma avaliação objetiva do desempenho da estratégia proposta em relação ao estado da arte.

[3]Disponíveis em: `https://github.com/rte-france/challenge-roadef-2020/`.

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

5.3. Ajuste de Parâmetros

Os parâmetros do DE foram configurados utilizando o pacote *irace* (versão 3.5) [López-Ibáñez et al., 2016]. A Tabela 1 detalha os intervalos explorados e os valores finais adotados.

Parâmetro	Descrição	Tipo	Intervalo	Valor Adotado
n_p	Tamanho do conjunto de soluções	inteiro	$[30;\ 50]$	36
p_{best}	Probabilidade de uso do *DE/1/best*	real	$[0;\ 1]$	0,37
F	Fator de escalonamento da mutação	real	$[0,05;\ 2]$	0,16
ρ	Parâmetro da recombinação exponencial	real	$(0;\ 1)$	0,30

Tabela 1: Configuração dos parâmetros do Algoritmo de Evolução Diferencial.

6. Resultados e Discussão

Os resultados obtidos pela estratégia proposta, são apresentados na Tabela 2. A partir desses resultados é possível notar a capacidade do DE em obter melhorias no plano de manutenção a partir da solução inicial gerada através da resolução do MIP.

Tabela 2: Resumo dos resultados obtidos, em cada uma das instâncias, com a estratégia proposta.

				Etapa 2 (Evolução Diferencial)							
	Etapa 1 (Resolução do MIP)			Obj.		Risco Médio		Excesso		Melhoria %	
Inst.	Obj.	Risco Médio	Excesso	Média	Desvio	Média	Desvio	Média	Desvio	Média	Desvio
C_01	11490.05	4008.76	18971.34	9470.60	40.99	4695.56	15.27	14245.64	87.03	17.58	0.36
C_02	3661.25	4395.74	2926.76	3651.87	2.33	4422.74	7.78	2881.00	10.59	0.26	0.06
C_03	39725.52	22405.66	57045.39	39623.22	24.92	22519.33	29.06	56727.11	77.78	0.26	0.06
C_04	44642.75	22152.35	67133.14	40810.51	102.06	25750.61	80.29	55870.41	265.85	8.58	0.23
C_05	4761.81	2071.35	7452.26	4469.11	25.10	2352.17	29.59	6586.05	78.40	6.15	0.53
C_06	8772.11	9168.41	8375.81	8748.59	4.14	9247.14	19.58	8250.04	25.89	0.27	0.05
C_07	8240.24	3484.44	12996.03	7437.35	165.49	3905.01	88.85	10969.70	418.12	9.74	2.01
C_08	11616.71	12795.84	10437.58	11609.26	2.60	12818.40	9.75	10400.12	13.34	0.06	0.02
C_09	6995.42	3854.16	10136.67	6708.68	35.41	4052.61	25.88	9364.75	94.66	4.10	0.51
C_10	51633.03	25846.02	77420.03	51346.12	69.94	26090.84	47.40	76601.41	175.32	0.56	0.14
C_11	6500.10	4612.39	8387.82	6047.35	16.51	5044.95	27.09	7049.75	56.97	6.97	0.25
C_12	13179.90	13832.75	12527.04	13118.70	11.69	14007.14	27.40	12230.26	48.02	0.46	0.09
C_13	46573.84	25460.65	67687.04	46537.92	19.63	25508.26	22.57	67567.59	60.07	0.08	0.04
C_14	28351.64	21392.72	35310.57	28305.60	14.27	21490.62	27.94	35120.59	55.21	0.16	0.05
C_15	43513.27	27827.82	59198.72	43457.45	20.98	27915.96	33.47	58998.94	67.94	0.13	0.05

A primeira etapa, baseada na resolução do MIP, forneceu soluções viáveis para todas as instâncias. Na segunda etapa, o DE demonstrou capacidade de melhorar consistentemente essa solução, com ganhos percentuais variando entre 0,06% (Instância C_08) e 17,58% (Instância C_01). Destaca-se que a instância C_01 apresentou a maior melhoria relativa, enquanto em outras, como C_02, C_03 e C_06, a melhoria foi inferior a 1%. Os baixos desvios padrão associados às 10 execuções do DE (especialmente para a função objetivo) o indica como uma estratégia robusta, com variações pequenas entre diferentes execuções.

A instância C_04 registrou uma melhoria significativa (8,58%), acompanhada por reduções no valor da função objetivo e no excesso de risco, embora com um aumento no risco médio. Esse comportamento evidencia o *trade-off* entre os indicadores de risco (risco médio e excesso), onde o DE priorizou a otimização global em detrimento do critério específico de risco médio, o único considerado durante a primeira etapa da abordagem proposta. Casos semelhantes ocorreram

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

em C_07 e C_11, nos quais a função objetivo foi reduzida em 9,74% e 6,97%. Isso sugere que o DE capaz de explorar regiões do espaço de busca com diferentes compensações entre os objetivos.

A Tabela 3 compara os melhores resultados obtidos pela abordagem proposta (considerando as 10 execuções) com os melhores resultados reportados na competição (ROADEF'2020). A análise revela que, embora a estratégia proposta tenha encontrado soluções viáveis em todas as instâncias, em nenhum caso ela superou os melhores resultados conhecidos, apresentando diferenças percentuais (Dif. %) que variam de -2,94% (C_12) a -39,73% (C_05), onde o valor negativo indica um pior desempenho da estratégia proposta.

Tabela 3: Comparação dos melhores resultados obtidos com a estratégia proposta contra os melhores resultados conhecidos para cada instância.

Instância	ROADEF'2020	Proposta	Dif. %
C_01	8515.90	9422.48	-10.65
C_02	3541.65	3648.17	-3.01
C_03	33511.70	39590.67	-18.14
C_04	37585.73	40572.09	-7.95
C_05	3166.89	4424.94	-39.73
C_06	8396.00	8740.72	-4.11
C_07	6083.27	7278.54	-19.65
C_08	11162.84	11605.94	-3.97
C_09	5586.98	6645.09	-18.94
C_10	43342.49	51255.14	-18.26
C_11	5749.96	6024.08	-4.77
C_12	12721.13	13095.67	-2.94
C_13	42487.99	46501.84	-9.45
C_14	26467.22	28281.74	-6.86
C_15	39758.03	43424.33	-9.22

A instância C_05 destacou-se negativamente, com uma diferença de quase -40%. Uma investigação mais aprofundada dessa instância é necessária para identificar a causa desse resultado.

7. Conclusões

Apesar de não alcançar os melhores resultados reportados na competição, o DE se mostrou capaz de produzir melhorias em relação à solução obtida a partir da resolução do MIP da Etapa 1 da estratégia proposta e apresentando uma variabilidade baixa em relação à solução final produzida.

A despeito de um desempenho inferior, o DE ainda pode ser melhorado, dado que a avaliação da solução é um dos principais processos que consomem o orçamento de tempo disponível para resolução. Uma primeira abordagem que pode ser explorada é a realização de avaliação parcial da função objetivo, já que apenas parte da solução é modificada.

Outro aspecto que pode ser investigado é se está ocorrendo convergência prematura do conjunto de soluções e, dessa forma, estagnando o refinamento pelo DE. Caso isso seja constatado, pode-se explorar estratégias para manter a diversidade do conjunto de soluções, como autoadaptação dos parâmetros p_{best} e ρ, substituição de parte das soluções da população por soluções aleatórias e, também, diferentes operadores de mutação e recombinação.

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

Referências

Beldiceanu, N. (2001). Pruning for the minimum constraint family and for the number of distinct values constraint family. In Walsh, T., editor, *Principles and Practice of Constraint Programming – CP 2001*, International Conference on Principles and Practice of Constraint Programming, p. 211–224, Berlin, Heidelberg. Springer.

Campelo, F. e Botelho, M. (2016). Experimental investigation of recombination operations for differential evolution. In *Proceedings of the Genetic and Evolutionary Computation Conference 2016*, GECCO '16, p. 221–228, New York, NY, USA. Association for Computing Machinery.

Cattaruzza, D., Labbé, M., Petris, M., Roland, M., e Schmidt, M. (2024). Exact and heuristic solution techniques for mixed-integer quantile minimization problems. *INFORMS Journal on Computing*, 36(4):1084–1107.

Crognier, G., Tournebise, P., Ruiz, M., e Panciatici, P. (2021). Grid operation-based outage maintenance planning. *Electric Power Systems Research*, 190:106682.

Gouvine, G. (2023). Mixed-integer programming decomposition for stochastic programming with quantiles. Disponível em: `https://arxiv.org/pdf/2111.01047v2`. Acessado em: 09 de março de 2025.

Gu, H., Lam, H. C., Pham, T. T. T., e Zinder, Y. (2023). Heuristics and meta-heuristic to solve the ROADEF/EURO challenge 2020 maintenance planning problem. *Journal of Heuristics*, 29: 139–175.

Gurobi Optimization, LLC. *Gurobi Optimizer Reference Manual: version 12.0*, 2023. Acessado em: 03 de maio de 2025.

International Energy Agency (2024). Electricity 2024 - analysis and forecast to 2026. Technical report, International Energy Agency. Acessado em: 25 de fevereiro de 2025.

Lam, H. C. T. (2022). *Scheduling with Two Types of Penalties Under Uncertainty and Its Application to Maintenance Planning*. PhD thesis, Faculty of Science, University of Technology Sydney, Sydney.

López-Ibáñez, M., Dubois-Lacoste, J., Pérez Cáceres, L., Birattari, M., e Stützle, T. (2016). The irace package: Iterated racing for automatic algorithm configuration. *Operations Research Perspectives*, 3:43–58.

Onwubolu, G. e Davendra, D. (2006). Scheduling flow shop using differential evolution algorithm. *European Journal of Operational Research*, 171(2):674–692.

Opara, K. e Arabas, J. (2018). Comparison of mutation strategies in Differential Evolution – a probabilistic perspective. *Swarm and Evolutionary Computation*, 39:53–69.

Parreño, F., Parreño-Torres, C., e Alvarez-Valdes, R. (2023). A matheuristic algorithm for the maintenance planning problem at an electricity transmission system operator. *Expert Systems with Applications*, 230:120583.

Prado, R. S., Silva, R. C. P., Guimarães, F. G., e Neto, O. M. (2010). Using differential evolution for combinatorial optimization: a general approach. In *IEEE International Conference on Systems Man and Cybernetics*, p. 11–18.

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br

Price, K. V., Storn, R. M., e Lampinen, J. A. (2005). *The Differential Evolution Algorithm*, chapter 2, p. 37–134. Springer, Berlin, Heidelberg.

Ruiz, M., Tournebise, P., e Panciatici, P. (2020). ROADEF Challenge RTE: Grid operation-based outage maintenance planning. Disponível em: `https://roadef.org/challenge/2020/en/index.php`. Acessado em: 25 de fevereiro de 2025.

Storn, R. e Price, K. (1997). Differential evolution – a simple and efficient heuristic for global optimization over continuous spaces. *Journal of Global Optimization*, 11(4):341–359.

Vasquez, M., Buljubasic, M., e Hanafi, S. (2023). An efficient scenario penalization matheuristic for a stochastic scheduling problem. *Journal of Heuristics*, 29:383–408.

Woller, D., Rada, J., e Kulich, M. (2023). The ALNS metaheuristic for the transmission maintenance scheduling. *Journal of Heuristics*, 29:349–382.

DOI: 10.59254/sbpo-2025-212273
https://proceedings.science/p/212273?lang=pt-br