

Estratégias de Diversificação para Otimização da Programação de Intervenções em Redes Elétricas

Rainer Zanghi¹, Julio Cesar Stacchini de Souza², Milton Brown Do Coutto Filho¹

¹Instituto de Computação

²Departamento de Engenharia Elétrica

Universidade Federal Fluminense

Niterói, RJ, Brasil

E-mails: rzanghi@ic.uff.br, julio@ic.uff.br, mbrown@ic.uff.br

Resumo—A aplicação de Algoritmos Evolutivos em problemas complexos de otimização pode ser considerada uma arte. Durante o processo de busca da solução de um problema, a harmonia entre diversificação e intensificação objetiva atender o compromisso existente entre qualidade e custo computacional. Em problemas complexos e multimodais, a convergência prematura para uma solução ótima local pode impedir a descoberta de soluções melhores. O presente trabalho se ocupa da utilização de técnicas capazes de prevenir/reparar a convergência prematura em Algoritmos Evolutivos. Durante a maior parte do processo evolutivo, busca-se manter elevado o nível de diversificação, respeitando-se porém o binômio qualidade-custo computacional da solução. A utilização de Algoritmos Evolutivos aqui proposta origina-se no tratamento de um problema real, complexo e epistático, referente ao agendamento de intervenções em redes elétricas de potência, durante sua operação. Resultados numéricos obtidos com o emprego das estratégias de diversificação propostas ilustram seus efeitos na qualidade e custo computacional das soluções alcançadas.

Palavras-chave—algoritmos evolutivos, agendamento, sistemas de potência.

I. INTRODUÇÃO

Desde o trabalho seminal de John Holland sobre Algoritmos Genéticos (AGs), várias técnicas foram propostas na literatura especializada para melhorar a eficiência destes algoritmos (qualidade *versus* custo computacional) como máquinas de busca da solução de diversos problemas de otimização [1, 2], com especial atenção para aqueles de complexidade computacional NP-Difícil [3]. Considerando a inclusão destas técnicas, os AGs se tornaram mais abrangentes, o que lhes trouxe a denominação de Algoritmos Evolutivos (AEs) [1].

AEs são classificados como meta-heurísticas, ou seja, algoritmos não-exatos projetados para encontrar soluções em um espaço de busca através da exploração de melhores locais. Esta classe de algoritmos é adequada para problemas complexos de otimização, em que o ótimo global não pode ser obtido pela enumeração completa de todas as soluções possíveis, por conta do alto custo computacional [4]. Desta forma, o compromisso entre qualidade e custo é uma medida importante para avaliar meta-heurísticas como os AEs, considerando como desempenho eficiente a capacidade de

fornecer uma solução de boa qualidade a um custo computacional reduzido. Além disso, diversos problemas do mundo real apresentam desafios que impedem o uso de algoritmos exatos. Relações complexas e interdependência entre componentes do modelo são alguns destes desafios e constituem uma característica conhecida como epistasia no jargão da Computação Evolutiva (CE) [5].

O agendamento de intervenções em redes elétricas existente na operação de sistemas de potência foi tratado como um problema de otimização em [6, 7]. Nestas referências, um AG foi utilizado e apresentou soluções de boa qualidade e com custo computacional satisfatório para as instâncias de teste utilizadas. Porém, a característica complexa deste problema de agendamento reside parcialmente no fato que diferentes instâncias de teste trazem um grande espectro de variações na função objetivo, alterando profundamente seu comportamento por conta dos desligamentos a serem agendados e das características do sistema em estudo. O uso de um AE como estratégia para lidar com a epistasia do problema e com a necessidade de adaptação a diversas instâncias de teste torna-se promissor e merece ser investigado. No entanto, à medida que o porte dos sistemas usados como instâncias de entrada aumenta, o custo computacional do uso de um AG elitista simples para resolver o problema de otimização se torna proibitivo, até para estudos de planejamento. Neste trabalho, diferentes estratégias foram implementadas para reduzir o custo computacional total e trazer eficiência ao processo de busca, até para instâncias de teste mais complexas.

Este artigo encontra-se assim organizado: na Seção II, o problema de agendamento de desligamentos é apresentado, assim como sua formulação, características e desafios; na Seção III, duas estratégias para melhorar a eficiência e eficácia de um AG elitista simples são apresentadas e aplicadas ao problema de agendamento em estudo. Tais estratégias compreendem a técnica de repopulação com conjunto elite, para preservar soluções boas e diversificadas na população enquanto introduz novos indivíduos e o emprego de uma multi-codificação com representações genéticas em código Gray [5] e inteiro, alteradas durante o processo evolutivo; a Seção IV apresenta resultados da aplicação das técnicas propostas em um AE, de modo a resolver o problema de agendamento em quatro diferentes instâncias baseadas em sistemas do IEEE [8]; por fim, na Seção V, as conclusões alcançadas na pesquisa

Os autores agradecem o apoio financeiro do CNPq e da FAPERJ para a realização desta pesquisa.

realizada são apresentadas.

II. AGENDAMENTO DE INTERVENÇÕES EM REDES ELÉTRICAS

A operação de curto prazo em redes de transmissão de energia elétrica lida frequentemente com o agendamento de desligamentos de equipamentos para fins de manutenção. Em um sistema interligado, com diversos agentes mantendo os equipamentos de transmissão, um operador independente do sistema, como o Operador Nacional do Sistema Elétrico (ONS) no Brasil, deve avaliar pedidos simultâneos e manter a disponibilidade do sistema e sua correta operação. Programar um agendamento confiável para todos os pedidos requer um alto número de análises e esforço considerável, humano e computacional.

O problema de programação de intervenções em equipamentos de transmissão pode ser entendido como um problema de agendamento ótimo, onde os recursos são as violações e desvios associados a um desligamento específico e seu uso deve ser minimizado na solução. No entanto, a complexidade do problema é maior que em um problema de agendamento (*scheduling*) usual [9] devido a interdependência entre as variáveis. Desligamentos simultâneos e perfis diferentes de demanda podem alterar as condições operacionais e as violações, em um padrão não-linear induzido pelas equações de fluxo de potência. O alto custo computacional da avaliação de cada cenário e o número total de cenários por agendamento torna impraticável o uso de métodos exatos de otimização. Meta-heurísticas como os AEs [1] podem lidar com ambos desafios (complexidade e dimensionalidade) de maneira eficiente em problemas complexos de otimização.

O presente trabalho aborda o agendamento de intervenções como um problema de otimização com restrições, no qual uma função objetivo que representa o reagendamento de um grupo de desligamentos, requisitado por um ou mais agentes, deve ser minimizado. Os limites operacionais do sistema e atendimento à carga são as restrições a serem observadas enquanto se busca atingir um desvio mínimo do agendamento inicial proposto pelos agentes. A prioridade de cada desligamento também deve ser considerada no reagendamento, aumentando a penalidade atribuída aos desvios de agendamento dos desligamentos com maior prioridade. Desta forma, o problema de otimização pode ser descrito como:

$$\text{Min} \sum_{t=1}^n (\Delta h(t) \times P_{pri}(t)) \quad (1)$$

s.a:

$$g_k(\theta, V) = 0 \quad k = 1, \dots, na \quad (2)$$

$$V_{ik}^{HI} - V_{ik} \geq 0 \quad i = 1, \dots, nb; k = 1, \dots, na \quad (3)$$

$$V_{ik} - V_{ik}^{LO} \geq 0 \quad i = 1, \dots, nb; k = 1, \dots, na \quad (4)$$

$$\left| P_{jk}^{nom} \right| - \left| P_{jk} \right| \geq 0 \quad j = 1, \dots, nr; k = 1, \dots, na \quad (5)$$

$$\left| P_{jk}^{emerg} \right| - \left| P_{jk} \right| \geq 0 \quad j = 1, \dots, nr; k = 1, \dots, na \quad (6)$$

Em (1), $\Delta h(t)$ é o desvio, em horas, do agendamento atual com relação ao proposto pelos agentes e P_{pri} é a prioridade

associada com o t -ésimo desligamento. A restrição de igualdade (2) representa as equações de balanço de potência ativa e reativa em cada nó da rede, (i.e. solução do fluxo de potência para a determinação do vetor complexo de tensões em todas as barras da rede) para cada um dos na cenários a ser analisados, representados por uma topologia e carregamento específicos. A capacidade de suportar contingências simples, ou seja, a perda de um ramo de transmissão, é considerada na topologia destes cenários. Violações de limites operacionais são analisadas através das restrições (3) até (6) onde, para cada cenário denotado pelo índice k , as tensões de nb barras do sistema não devem violar os limites superiores e inferiores V^{HI} e V^{LO} , respectivamente, e os fluxos de potência ativa em nr ramos não podem ser maiores que o limite de emergência P^{emerg} ou que o limite nominal P^{nom} .

O processo evolutivo de um AE será responsável por fornecer o indivíduo com melhor aptidão, considerando os desvios devido ao reagendamento e as violações associadas à programação como penalidades com pesos. Este indivíduo é a solução do problema de agendamento de intervenções, sendo representado no AE pelas horas iniciais de cada desligamento agendado. Cada gene do genótipo representa um desligamento através de sua hora inicial e o cromossomo é composto por todos os desligamentos presentes no agendamento. Os alelos de cada gene são limitados à janela de tempo do agendamento, variando de 0 até a última hora da programação. Todas as operações do AE são restritas a estes valores, mantendo as variáveis dentro destes limites rígidos. No entanto, cenários diferentes que ocorrem após o final da janela de tempo, composto por desligamentos que se iniciaram dentro desta janela, são também considerados na análise. O alto custo computacional da avaliação da função de aptidão é ocasionado pelo fato que cada solução é composta por um agendamento de desligamentos com diferentes cenários e cada cenário é avaliado por diversas análises custosas computacionalmente. Neste problema de agendamento, a avaliação da função de aptidão requer diversas execuções de um algoritmo de fluxo de potência, o que requer a solução de um conjunto de equações algébricas não lineares, impondo alto custo computacional para sistemas de grande porte com agendamentos intrincados.

A metodologia apresentada em [6, 7] tratou o problema do agendamento de intervenções de uma forma sistemática, contribuindo para o processo de planejamento da operação de sistemas de potência. No entanto, a partir da perspectiva do algoritmo apresentado para realizar a otimização, diversas melhorias foram necessárias de modo a aumentar sua eficiência para sistemas maiores. O alto custo computacional da avaliação da função de aptidão, que é ainda maior quando soluções de baixa qualidade são exploradas, é uma limitação à diversificação no processo evolutivo. Por outro lado, a complexidade e multimodalidade da função de aptidão demanda estratégias de diversificação. Nas próximas seções são apresentadas as estratégias e técnicas implementadas para resolver estas questões e seus efeitos nos resultados finais, medidos através da qualidade e tempo computacional das soluções.

III. ESTRATÉGIAS E TÉCNICAS

Diversos autores propuseram análises teóricas no processo

evolutivo de um AE [1, 2, 10]. Estas análises representam tipicamente a influência da estratégia ou técnica sobre a qualidade ou custo computacional da solução, considerando diferentes problemas de otimização ou instâncias distintas do mesmo problema. De modo a classificar esta influência no processo de busca de meta-heurísticas, [4] propôs uma visão unificadora do binômio *diversificação* (habilidade para investigar áreas inexploradas do espaço de busca) e *intensificação* (busca de uma melhoria local na vizinhança das soluções correntes). De acordo com [4], estes conceitos devem ser considerados como estratégias de médio e longo prazo baseadas no uso da memória adquirida durante o processo evolutivo. O processo de busca de um AE deve harmonizar diversificação e intensificação, usando diversas técnicas, para aumentar sua eficiência.

O conceito de *variação genética* [11] da biologia pode ser migrado e redefinido em CE como diversificação no processo de busca. Este conceito compartilha alguns elementos chave de seu análogo na rede conceitual da biologia. A variação genética pode ser entendida como uma métrica para avaliar como os indivíduos de uma mesma população tem genótipos diferentes que podem ser traduzidos em características ou traços, também chamados de fenótipo. Em CE estas diferenças podem compartilhar as mesmas propriedades, considerando a relação funcional entre genótipo e fenótipo. A presença de uma relação biunívoca entre genótipo e fenótipo é dependente da codificação, representação do problema ou até da natureza do próprio problema. É possível representar dois indivíduos em um AE com diferentes genótipos e mesmo valor de aptidão. No problema de agendamento abordado neste trabalho, esta situação pode ocorrer, por exemplo, com dois agendamentos diferentes que apresentam o mesmo desvio do agendamento original e não causem violações nos limites operativos do sistema.

Problemas com alto custo computacional para a função que calcula a aptidão de cada solução demandam estratégias para mitigar efeitos no custo total em AEs. Estes algoritmos, baseados em populações de indivíduos, geram um grande número de soluções durante o processo evolutivo. Técnicas que paralelizam o cálculo da função de aptidão por meio de tarefas independentes podem reduzir o custo total destes algoritmos [12]. Esta divisão pode ser particular ao problema e ocorrer dentro do algoritmo de avaliação da função de aptidão, ou explorar a independência intrínseca entre soluções ou indivíduos e dividir a tarefa de calcular a aptidão de cada solução a uma unidade de processamento diferente. Até quando nenhum paralelismo é implementado, uma lista que guarda todas as soluções diferentes já exploradas pelo AE [2] pode ser usada para evitar repetições e o consequente desperdício de tempo computacional. Estas técnicas não afetam a qualidade da solução, alterando apenas a ordem em que sua aptidão é calculada. Usando premissa similar, uma estratégia comum aplicada principalmente para problemas de otimização discreta [2] consiste em se computar a aptidão parcial associada a ocorrência de genes específicos no cromossomo da solução e adicionar este valor quando aquela sequência particular de genes ocorrer. No entanto, esta estratégia não pode ser aplicada em problemas epistáticos em que um gene específico não pode ser diretamente associado a um acréscimo ou decréscimo no

valor de aptidão. Nesta classe de problemas, as relações entre genes interferem no valor da aptidão obtido para a solução demandando a avaliação de toda a função aptidão para cada solução única. Estas características são atrativas para o uso de algoritmos estocásticos com alta diversificação. No entanto, esta estratégia traz consigo um aumento do custo computacional total, estimulado pelo grande número de avaliações da função de aptidão. Diferentemente das técnicas de paralelização e de não-recálculo da função de aptidão, estratégias que reduzem este efeito demandam uma redução seletiva da diversificação a fim de reduzir o custo computacional, o que pode induzir uma diminuição da qualidade da solução. Uma hipótese explorada em diferentes meta-heurísticas, e.g. Recozimento Simulado, GRASP [4], postula que a fase de diversificação deve ser aplicada desde o início da execução do algoritmo. Esta primeira fase permite a exploração de diferentes nichos do espaço de busca e deve ser seguida de uma fase de intensificação que deve refinar as soluções previamente obtidas através de uma busca em sua vizinhança.

Ainda, em funções de aptidão com vários ótimos locais, uma estratégia de diversificação que é removida prematuramente pode não ser eficiente contra a convergência prematura. Esta situação está usualmente presente em AEs com alta pressão seletiva, nos quais uma estratégia de diversificação pode forçar a exploração de outros nichos do espaço de busca, possivelmente escapando de um ótimo local. Técnicas de repopulação como as do algoritmo CHC proposto em [13] trazem diversidade genotípica ao processo evolutivo, aumentando a possibilidade de criatividade através das novas combinações. Para coordenar a diversificação e preservar o material genético de indivíduos de alta qualidade, estratégias elitistas são comumente utilizadas.

A abordagem subjacente das estratégias apresentadas nesta seção e aplicadas ao problema de agendamento em pauta é reduzir o custo computacional do AE, preservando ou melhorando a qualidade através do uso de técnicas que promovam alto nível de diversificação. O uso destas técnicas é guiado pela qualidade da solução, permitindo uma redução do custo computacional total. Adicionalmente, uma redução significativa do custo computacional foi obtida com o uso de uma técnica de computação paralela da função de aptidão ou *avaliação distribuída da aptidão* [12]. Esta técnica é também descrita como AG paralelo mestre-escravo em [10] e é implementada através da distribuição da execução da avaliação da função de aptidão, de todos os indivíduos na população de uma dada geração, por todos os núcleos de processamento disponíveis, usando *threads* independentes, um para cada execução da função. O uso desta técnica é especialmente útil quando o custo computacional da avaliação da função de aptidão é muito maior que o tempo de comunicação necessário para sincronizar os resultados obtidos em cada *thread*. Redução de tempo computacional adicional foi obtida através da manutenção de uma lista de todas as soluções únicas [2]. No final de cada geração, antes da avaliação do valor de aptidão de uma dada solução, seu genótipo é procurado na lista. Se a solução é única, seu genótipo é adicionado à lista e sua aptidão é avaliada. Se a solução é encontrada na lista, nenhuma avaliação é executada e o valor de aptidão avaliado

anteriormente é usado para aquela solução. Se o custo computacional do algoritmo de busca é menor que o da avaliação da função de aptidão, é possível obter redução de custo computacional sem perda de qualidade na solução.

A. Multi-codificação

O processo de codificação é a transformação de informação fenotípica (i.e. conjunto de variáveis que constituem o indivíduo) em um cromossomo, conforme ilustrado na Fig. 1 para o problema do agendamento de intervenções. Em um AE, o cromossomo é a representação genotípica de um indivíduo e permite a demarcação de um espaço de busca conhecido, facilitando o processo de busca por uma solução ótima. Em [14], a escolha da codificação é ressaltada como um elemento chave para evitar a perda de informação relevante neste processo de representação. O espaço de busca fenotípico é, por si só, uma redução do espaço real, contendo somente as variáveis selecionadas para representar o problema.

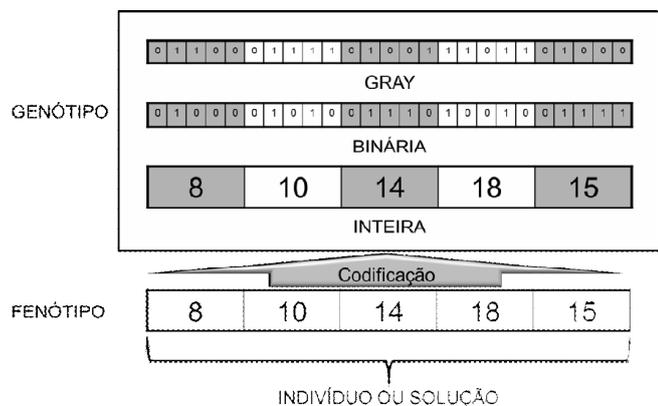


Fig. 1. Representação do problema de agendamento para codificações Gray, binária e inteira.

O uso de diferentes codificações foi explorado na literatura de CE. O uso de codificação real como uma representação natural de fenótipos reais ou inteiros foi investigado em [14]. Naquele trabalho, a dificuldade de propagar blocos representativos dos cromossomos dos pais através de cruzamento é discutida e um operador de cruzamento SBX para codificação real é proposto. Em [15], o uso da codificação delta (*delta coding*) e Gray é considerado como uma estratégia de remapeamento que pode apresentar um problema de busca mais fácil para o AE. Também é proposto através do *delta coding* mudar dinamicamente a representação para evitar vieses que podem estar associados a uma representação de espaço de busca específica. A referência [15] também cita os benefícios da codificação Gray e seu uso em trabalhos anteriores. O código binário refletido, usualmente chamado de código Gray, é um sistema numérico com a distância de Hamming sempre igual a 1, i.e. dois valores sucessivos se diferenciam em apenas um bit. Neste mapeamento, é possível ter um comportamento de mudança gradual tanto no genótipo quanto no fenótipo, e introduzir mudanças de alta ordem com mutações de um bit. A referência [16] avalia alterações na vizinhança de um fenótipo inteiro codificado em um genótipo Gray ou binário. Em funções de aptidão multimodais, um ordenamento distinto da vizinhança, introduzido pelo uso da codificação Gray, pode eliminar ótimos locais que podem se

apresentar num espaço de busca representado por outras codificações. A referência [5] demonstrou que, no pior caso, uma mudança para codificação Gray preserva o número de ótimos locais presentes na codificação anterior.

É importante notar que mudar codificações demanda o emprego de operadores de mutação e cruzamento distintos e sua influência no processo evolutivo deve também ser considerada. Em [14], é apontado que o desempenho de um AG é afetado pela escolha do par codificação e operador de cruzamento, sugerindo que uma harmonia entre estes dois elementos é importante para o sucesso do processo de otimização. Esta relação é também destacada pelos resultados obtidos em [16].

Neste trabalho, uma estratégia chamada multi-codificação é apresentada. Esta técnica introduz mudanças na representação do espaço de busca, alterando a codificação durante o processo evolutivo do AE. Ela explora a diversificação introduzida pelo uso da codificação Gray [7] e a redução do custo computacional obtido quando a codificação inteira é utilizada. O uso desta estratégia é regulado por um parâmetro que indica, através de um percentual do número total de gerações, definido no critério de parada, em qual parte do processo evolutivo a codificação será alterada.

B. Repopulação com Conjunto Elite

A estratégia de *Repopulação com Conjunto Elite* (RCE) apresentada neste trabalho é suportada pelo conceito de *fluxo gênico* na biologia. Este conceito [17], também chamado *migração*, denota o movimento de informação genética de uma população para outra e pode ser uma fonte importante de variação genética [11] sobre os genes migrados. De acordo com Hartl & Clark, “Como um processo evolutivo que traz potencialmente novos alelos para uma população, a migração é qualitativamente similar à mutação”. O conceito de repopulação durante o processo evolutivo em um AE foi abordado pelo algoritmo *delta coding* [15] e pelo algoritmo de busca adaptativo CHC [13]. No *delta coding*, uma solução parcial, obtida da primeira fase de um processo evolutivo, é usada para rescalonar a aptidão de novos indivíduos após uma reinicialização. Na abordagem do CHC, um membro elite da população é selecionado para produzir indivíduos para a nova população através de um operador especialmente projetado. A população anterior é removida do processo e somente os novos indivíduos gerados pelo operador constituirão a nova população. A estratégia RCE proposta no presente trabalho preserva um grupo de indivíduos da última população, chamado conjunto elite, e popula as demais posições com novos indivíduos. Desta forma, esta estratégia pretende produzir inovação baseado nas interações entre um conjunto elite migrado e uma população com novos indivíduos. Estas interações são representadas por operadores genéticos como seleção e recombinação, complementados pela mutação. De modo a gerar inovação com boa qualidade das interações entre estes dois grupos de indivíduos, a estratégia RCE almeja produzir um conjunto elite que tem indivíduos com um genótipo diversificado e boa qualidade, esta medida pelas respectivas aptidões.

O algoritmo da RCE executa o seguinte procedimento de

duas etapas:

Etapas 1 – Seleção de Candidatos (critério de aptidão)

De uma lista de indivíduos ordenados pela sua aptidão, o grupo de indivíduos com melhores (menores) valores de aptidão serão selecionados como candidatos. O ponto de corte para a seleção é o percentual p acima do valor de aptidão da melhor solução (i.e. indivíduo elite). O indivíduo elite é sempre selecionado e a ordem crescente de aptidão é mantida.

Etapas 2 – Formação do Conjunto Elite (filtro de diversidade)

A lista de candidatos gerada na Etapa 1 é avaliada de modo a remover soluções muito similares genotipicamente. Os seguintes passos são executados:

1. Selecione o próximo elemento da lista e o compare com as demais soluções candidatas;
2. Se o indivíduo selecionado é significativamente diferente das demais soluções, ele é inserido no conjunto elite. Caso contrário, ele é descartado. Enquanto houver candidatos a analisar, retorne para 1.

Esta estratégia é aplicada através da segmentação do processo evolutivo em dois laços aninhados: um laço geracional interno com g gerações onde o elitismo de apenas um indivíduo é implementado entre gerações; e um laço de repopulações externo com r repopulações onde a estratégia RCE é aplicada. O número de indivíduos selecionado como candidatos, regulado automaticamente pela qualidade da população atual e pelo parâmetro p , pode ser reduzido dramaticamente pelo critério do filtro de diversidade. Neste trabalho a seleção de candidatos foi realizada com soluções que tem valores de aptidão até 40% piores que a aptidão do melhor indivíduo obtido após g gerações. Dois indivíduos foram considerados significativamente diferentes quando, em seus agendamentos, as horas iniciais propostas para pelo menos um dos desligamentos tivessem uma diferença de 3 horas.

Pretende-se com a técnica RCE trazer diversificação através da introdução de um grupo de novos indivíduos na população em substituição a soluções de baixa qualidade e a boas soluções que não são diversas genotipicamente. A mesma técnica provê intensificação em um grau menor pela preservação de soluções boas fenotipicamente (elitismo), o que pode aumentar a pressão seletiva.

IV. RESULTADOS DAS SIMULAÇÕES

A fim de avaliar a influência de cada estratégia no problema de agendamento de intervenções, simulações foram realizadas utilizando os sistemas teste IEEE 14, 30, 57 e 118 barras. Os resultados foram avaliados com base na melhor aptidão obtida (mínimo), aptidão média e desvio padrão dos valores de aptidão de todas as soluções obtidas em um grupo de 100 execuções do AE, usando diferentes sementes para os geradores de números pseudo-aleatórios. O tempo de execução médio de cada teste representa a média dos tempos necessários para cada uma das execuções do AE. Todas as técnicas foram aplicadas considerando os parâmetros dos AEs já utilizados em [6, 7]. Dados estruturais para os 4 sistemas utilizados foram obtidos de [8].

A. Repopulação com Conjunto Elite

Simulações com diferentes valores do parâmetro g foram feitas de modo a calibrar o número de gerações do laço geracional. Um valor de 10 foi escolhido e utilizado em todas as simulações descritas neste trabalho. De modo a manter o mesmo número de gerações usado no critério de parada para o caso sem a estratégia (igual a 700), 70 repopulações foram feitas em cada execução do AE. A Tabela I mostra resultados obtidos para todos os casos teste, usando codificação Gray e inteira, com e sem o uso da estratégia RCE.

TABELA I
REPOPULAÇÃO COM CONJUNTO ELITE E CODIFICAÇÕES

Caso Teste	Cod.	RCE	Aptidão			Tempo
			Min.	Média	σ	Média(s)
IEEE14	Gray	Não	42.064	42.590	0.840	8
	Gray	Sim	42.064	42.354	0.576	22
	Int.	Não	42.064	46.108	2.647	1
	Int.	Sim	42.064	42.933	0.788	14
IEEE30	Gray	Não	8.449	10.648	1.424	77
	Gray	Sim	8.449	10.432	1.263	108
	Int.	Não	8.748	18.269	4.667	5
	Int.	Sim	8.720	13.712	2.604	60
IEEE57	Gray	Não	17.029	18.610	0.860	381
	Gray	Sim	17.029	18.382	0.865	508
	Int.	Não	17.564	23.464	4.109	16
	Int.	Sim	17.029	20.317	1.553	322
IEEE118	Gray	Não	10.021	17.091	4.818	1777
	Gray	Sim	10.021	16.822	4.505	3239
	Int.	Não	19.714	33.600	9.028	87
	Int.	Sim	19.714	28.054	4.793	2126

Os resultados da Tabela I mostram que para ambas as codificações foi possível melhorar ou preservar a qualidade em todos os valores mínimos de aptidão com o uso da estratégia RCE. Todos os valores médios de aptidão foram melhorados com o uso da RCE, mostrando que a estratégia faz com que as soluções do AE se aproximem mais do melhor valor obtido em todas as execuções. A redução do tempo computacional observado em testes sem o uso da estratégia RCE ocorreu devido ao uso da técnica de não-recálculo sobre um número excessivo de soluções idênticas obtidas nos processos evolutivos destes testes. A maior diversidade obtida com o uso da estratégia RCE permitiu a exploração de mais soluções únicas durante o processo evolutivo, demandando mais avaliações da função de aptidão quando comparada com execuções do AE sem o uso desta estratégia. O benefício com o emprego da RCE foi evidenciado pela melhoria da qualidade das soluções obtidas.

B. Multi-Codificação

Além da melhoria na qualidade devido ao uso da técnica RCE em ambas as codificações, os resultados da Tabela I mostraram também uma maior capacidade de se encontrar boas soluções, quando se usa a codificação Gray, e uma

convergência mais rápida, quando a codificação inteira é empregada. Assim, a combinação das codificações Gray e inteira em conjunto com a estratégia RCE foi investigada com o intuito de permitir identificar boas relações de compromisso entre qualidade das soluções e custo computacional associado. Para tal, a codificação Gray, que naturalmente introduz uma maior diversificação das soluções, foi empregada no início do processo evolutivo. Posteriormente, tal codificação foi substituída pela representação inteira, menos diversa, mas com característica de convergência mais rápida.

Simulações com a alternância entre as codificações Gray e inteira foram executadas, tendo cada uma destas sido empregada em 50% do total de gerações. Resultados para estas simulações com todos os casos testados podem ser vistos na Tabela II. Para fins de comparação, resultados de simulações com codificações Gray e inteira sem o uso da multi-codificação também foram incluídos em cada teste. Em todas as simulações, a estratégia RCE foi empregada com um número fixo de 10 gerações por ciclo geracional.

TABELA II
MULTI-CODIFICAÇÃO 50%

Caso Teste	1ª Codif.	2ª Codif.	Aptidão			Tempo Média(s)
			Mínima	Média	σ	
IEEE14	Gray	-	42.064	42.354	0.576	22
	Int.	-	42.064	42.933	0.788	14
	Gray	Int.	42.064	42.430	0.645	18
IEEE30	Gray	-	8.449	10.432	1.263	108
	Int.	-	8.720	13.712	2.604	60
	Gray	Int.	8.449	10.552	1.456	87
IEEE57	Gray	-	17.029	18.382	0.865	508
	Int.	-	17.029	20.317	1.553	322
	Gray	Int.	17.029	18.470	0.856	418
IEEE118	Gray	-	10.021	16.822	4.505	3239
	Int.	-	19.714	28.054	4.793	2126
	Gray	Int.	10.021	16.756	4.596	2852

Todos os casos apresentaram redução do custo computacional quando comparados com o caso em que se usou apenas a codificação Gray e uma significativa melhora de qualidade quando comparados com o emprego apenas da codificação inteira. Observou-se ainda que para o sistema IEEE 118 barras houve uma melhoria da qualidade da solução obtida com o emprego da multi-codificação em relação ao uso isolado não apenas da codificação inteira, mas também da Gray.

V. CONCLUSÕES

O presente trabalho apresentou duas técnicas aplicadas a um AE projetado como uma ferramenta de otimização para resolver um problema complexo e real da operação de sistemas elétricos de potência. Devido às características multimodais e complexas da função de aptidão, todas as estratégias propostas visaram a manutenção de um alto nível de diversificação

durante o processo evolutivo. No entanto, o problema de agendamento de intervenções apresenta uma avaliação de função aptidão de alto custo computacional. Tal custo aumenta em soluções de baixa qualidade, demandando assim uma estratégia como a RCE para guiar o processo evolutivo na busca por soluções de boa qualidade. Através da estratégia de multi-codificação aplicada sobre a técnica RCE, foi possível obter um adequado equilíbrio qualidade-custo, com nenhuma ou muito pouca perda de qualidade e significativa redução de custo computacional. As estratégias apresentadas para o problema abordado podem ser boas opções para a solução de outros problemas que apresentem características similares, o que será alvo de investigação futura.

REFERÊNCIAS

- [1] K.A. De Jong, "Evolutionary computation: a unified approach", Cambridge, Mass.: MIT Press, 2006.
- [2] C. R. Reeves, "Genetic algorithms", Gendreau, In M. Gendreau, and J.-Y. Potvin, Eds., Handbook of Metaheuristics, 2nd edition. Vol. 146 in Int. Series in Oper. Res. & Manag. Science, Springer, Verlag, New York, 2010, pp. 109-139.
- [3] M.R. Garey and D.S. Johnson, "Computers and intractability: a guide to the theory of NP-completeness", San Francisco: W.H. Freeman, 1979.
- [4] C. Blum and A. Roli, "Metaheuristics in combinatorial optimization: overview and conceptual comparison", ACM Computing Surveys, Vol. 35, No. 3, September 2003, pp. 268-308.
- [5] J. Rowe, D. Whitley, L. Barbulescu, and J.P. Watson, "Properties of Gray and binary representations", Evolutionary Computation, Vol. 12, Issue 1, 2004, pp.47-76.
- [6] J.C.S. Souza, M.B. Do Coutto Filho and M.L.R. Roberto, "A genetic-based methodology for evaluating requested outages of power network elements", IEEE Trans. Power Syst., Vol. 26, 2011, pp.2242-2249.
- [7] R. Zanghi, J.C.S. Souza and M.B. Do Coutto Filho, "Agendamento de desligamentos em redes de transmissão empregando estratégias evolutivas", XIII SEPOPE, Foz do Iguaçu, Brasil, 2014.
- [8] R.D. Christie, "Power systems test case archive" [online], 1999, Disponível em: <http://www.ee.washington.edu/research/pstca/>, [acessado em 28/04/2011].
- [9] M.L. Pinedo, "Scheduling. Theory, Algorithms, and Systems", 3rd edition, 2008, Springer New York.
- [10] D.E. Goldberg, "Genetic Algorithms in Search, Optimization and Machine Learning", Boston, MA: Addison-Wesley, 1989.
- [11] D. L. Hartl and A.G. Clark, "Principles of Population Genetics", 4th ed., Sinauer Associates, Inc., 2007.
- [12] T. Crainic and M. Toulouse, "Parallel meta-heuristics", In M. Gendreau, and J.-Y. Potvin, Eds., Handbook of Metaheuristics, 2nd edition. Vol. 146 in Int. Series in Oper. Res. & Manag. Science, Springer, Verlag, New York, 2010, pp. 497-541.
- [13] L.J. Eshelman, "The CHC adaptive search algorithm: how to have safe search when engaging in nontraditional genetic recombination", In: Proceedings of the First Workshop on Foundations of Genetic Algorithms, 1991, pp. 265-283, ISBN 1-55860-170-8.
- [14] K. Deb and R.B. Agrawal, "Simulated binary crossover for continuous search space. complex systems", Vol. 9, 1994, pp. 1-34.
- [15] K. Mathias and L. Whitley, "Changing representations during search: a comparative study of delta coding", Evolutionary Computation, Vol. 2, No. 3, 1995, pp. 249-278.
- [16] U. Chakraborty and C. Janikow, "An analysis of Gray versus binary encoding in genetic search", Information Sciences, Vol. 156, No. 3-4, 2003, pp. 253-269.
- [17] M. Slatkin, "Gene flow in natural populations", Annual Review of Ecology and Systematics, Vol. 16, No. 1, 1985, pp. 393-430.