

**ALGORITMOS GENÉTICOS COM CHAVES ALEATÓRIAS:
DESEMPENHO DE DUAS VARIANTES NA RESOLUÇÃO DO
PROBLEMA DO CAIXEIRO VIAJANTE**

**RANDOM-KEY GENETIC ALGORITHM:
PERFORMANCE OF TWO VARIANTS FOR SOLVING THE
TRAVELING SALESMAN PROBLEM**

**ALGORITMOS GENÉTICOS CON CLAVES ALEATORIAS:
DESEMPEÑO DE DOS VARIANTES EN LA RESOLUCIÓN DEL
PROBLEMA DEL VIAJERO**

Eduardo Paz Putti¹
Nathan Batistelli de Oliveira²
Carise Elisane Schmidt³

Artigo recebido em dezembro de 2024
Artigo aceito em fevereiro de 2025

DOI: 10.26853/Refas_ISSN-2359-182X_v11n04_07

RESUMO

O Problema do Caixeiro Viajante é um clássico problema de otimização combinatória, que está entre os mais estudados na literatura. Neste problema, contrastam a simplicidade da definição e a complexidade computacional da resolução. Por conta dessa complexidade, algoritmos heurísticos e metaheurísticos têm sido amplamente estudados para a resolução do problema. Este trabalho tem por objetivo avaliar o desempenho de duas variantes do algoritmo genético com chaves aleatórias: o RKGA e o BRKGA. Para isso, os dois algoritmos foram implementados computacionalmente e um conjunto de 20 instâncias da literatura foi selecionado para a execução de testes computacionais. Foram selecionadas instâncias simétricas que possuem entre 70 e 1748 pontos. Nos testes computacionais, foram analisados e comparados a qualidade da solução obtida e o tempo de processamento de cada algoritmo ao longo de três execuções. Os resultados indicaram que o BRKGA é mais eficiente na busca por soluções que o RKGA, considerando o conjunto de instâncias avaliado. A melhoria na qualidade da solução produzida foi, em média, superior a 20%.

Palavras-chave: Metaheurísticas; Algoritmos Evolucionários; Problemas de Roteamento.

¹ Discente do curso de Bacharelado em Engenharia de Controle e Automação. LABICON, Instituto Federal de Santa Catarina (IFSC). e-mail: eduardopazputti@gmail.com. Lattes: <http://lattes.cnpq.br/7790502306214334>. OrcId: <https://orcid.org/0009-0001-7327-0082>.

² Discente do curso de Bacharelado em Engenharia de Controle e Automação. LABICON, Instituto Federal de Santa Catarina (IFSC). e-mail: nathan.bo10@aluno.ifsc.edu.br. Lattes: <http://lattes.cnpq.br/2655471467083697>. OrcId: <https://orcid.org/0009-0008-0932-0891>.

³ Docente no curso de Bacharelado em Engenharia de Controle e Automação. LABICON, Instituto Federal de Santa Catarina (IFSC). Doutora em Métodos Numéricos em Engenharia. e-mail: carise.schmidt@ifsc.edu.br. Lattes: <https://lattes.cnpq.br/7888830128804858>. OrcId: <https://orcid.org/0000-0003-2274-1953>.

ABSTRACT

The Traveling Salesman Problem (TSP) is a classic combinatorial optimization challenge and one of the most extensively studied problems in the literature. It is characterized by the simplicity of its definition yet the computational complexity of its resolution. Due to this complexity, heuristic and metaheuristic algorithms have been widely explored to tackle the problem. This study aims to assess the performance of two variants of the genetic algorithm with random keys: the RKGA and BRKGA. For this purpose, both algorithms were computationally implemented, and a set of 20 benchmark instances was selected for testing. The selected instances are symmetric and feature between 70 and 1748 points. Computational experiments were conducted to evaluate and compare the solution quality and processing time of each algorithm over three executions. The results demonstrated that BRKGA outperforms RKGA in finding solutions, considering the evaluated instance set. On average, the BRKGA achieved a solution quality improvement exceeding 20%.

Keywords: Metaheuristics; Evolutionary Algorithms; Routing Problems.

RESUMEN

El Problema del Viajante es un problema clásico de optimización combinatoria y uno de los más estudiados en la literatura. En este problema, se contrasta la simplicidad de su definición con la complejidad computacional de su resolución. Debido a esta complejidad, los algoritmos heurísticos y metaheurísticos han sido ampliamente investigados como enfoques de solución. Este trabajo tiene como objetivo evaluar el rendimiento de dos variantes del algoritmo genético con claves aleatorias: RKGA y BRKGA. Para ello, ambos algoritmos fueron implementados computacionalmente y se seleccionó un conjunto de 20 instancias de la literatura para la ejecución de experimentos computacionales. Se eligieron instancias simétricas que comprenden entre 70 y 1.748 puntos. En los experimentos, se analizaron y compararon la calidad de las soluciones obtenidas y el tiempo de procesamiento de cada algoritmo a lo largo de tres ejecuciones. Los resultados indicaron que BRKGA es más eficiente que RKGA en la búsqueda de soluciones, considerando el conjunto de instancias evaluadas. En promedio, la mejora en la calidad de la solución producida por BRKGA fue superior al 20%.

Palabras clave: Metaheurísticas; Algoritmos Evolutivos; Problemas de enrutamiento.

1 INTRODUÇÃO

O Problema do Caixeiro Viajante (PCV) é um dos problemas de otimização combinatória mais investigados na literatura. O amplo interesse pelo tema está associado com a grande variedade de aplicações, bem como com a sua complexidade computacional (Dahdahiya e Sangwan, 2018; Pop et al., 2024). Esses aspectos, aliados ao potencial que a sua aplicação possui para otimizar recursos, seja reduzindo tempo ou custos operacionais, têm atraído a atenção de pesquisadores ao longo de várias décadas.

Na forma clássica, o PCV consiste em determinar uma rota de custo mínimo, que passe por um conjunto de cidades, de forma que cada cidade seja visitada exatamente uma vez, retornando então à cidade de origem (Dantzig, Fulkerson e Johnson, 1954). Apesar da simplicidade na sua definição, a natureza combinatória torna a busca por soluções ótimas desafiadora.

Do ponto de vista das aplicações, é possível mencionar estudos envolvendo as mais diversas áreas. Problemas de logística, planejamento, programação de tarefas em máquinas, acesso à arquivos computacionais, fabricação de microchips, corte e perfuração de placas de

circuito impresso, controle do movimento de telescópios e sequenciamento de DNA são alguns exemplos que podem ser modelados a partir do PCV (Matai, Singh e Mitall, 2010; Goldbang e Luna, 2005).

Em relação à complexidade computacional, o problema é classificado como NP-Difícil (Laporte, 1992). Isso significa que nenhum algoritmo que possa resolver todas as instâncias do problema de forma exata e em tempo polinomial é conhecido. Este aspecto fez que com que diferentes abordagens de solução, exatas e heurísticas, fossem propostas para tratá-lo. Algumas delas permitindo que o problema fosse solucionável, mesmo em grafos de grande escala.

Dada essa complexidade computacional, presente em problemas de otimização combinatória do tipo NP-Difícil, métodos exatos tendem a se tornar inviáveis, do ponto de vista do processamento, conforme o aumento do tamanho do problema. Por outro lado, as metaheurísticas são abordagens importantes na busca por boas soluções (Chaves, Gonçalves e Lorena, 2018). Contudo, elas não possuem garantia teórica de obtenção da solução ótima.

Os Algoritmos Genéticos (AG) são um exemplo dessas metaheurísticas. Eles têm se mostrado efetivos na resolução de problemas desafiadores de otimização (Lode et al., 2025), além de se tornarem a metaheurística mais aplicada para resolver problemas de escalonamento baseados no PCV (Toaza e Esztergár-Kiss, 2023). Entre as suas variantes, um grupo tem se tornado especialmente popular por conta do sucesso da sua aplicação bem-sucedida em uma grande variedade de problemas. Elas combinam a eficiência dos AG com uma abordagem diferenciada de decodificação de soluções, que utiliza chaves aleatórias (Chaves et al., 2024).

Neste estudo, o desempenho de duas variantes do Algoritmo Genético com Chaves Aleatórias é investigado, considerando a sua aplicação para a resolução de um conjunto de instâncias do Problema do Caixeiro Viajante. Essas variantes são denominadas RKGA (do inglês, “Random-Key Genetic Algorithm”) e o BRKGA (do inglês, “Biased Random-Key Genetic Algorithm”) (Gonçalves e Resende, 2016).

A partir de modificações nos mecanismos de seleção e cruzamento, a primeira variante busca aumentar a diversidade da população e evitar a convergência prematura. Já a segunda, incorpora uma estratégia adaptativa de mutação, intensificando a exploração do espaço de soluções e permitindo que o algoritmo se adapte às características de cada instância. A partir dessa comparação, busca-se aprofundar o entendimento teórico das técnicas utilizadas, bem como avaliar seu desempenho prático, reforçando a importância do estudo do PCV.

A sequência deste documento está organizada conforme segue. Inicialmente, é apresentada uma revisão de literatura sobre os Algoritmos Genéticos e as variantes abordadas neste estudo. Em seguida, a metodologia aplicada é detalhada. Os resultados dos testes computacionais são apresentados e discutidos na sequência. Por fim, são realizadas as considerações finais

2 REFERENCIAL TEÓRICO

Os Algoritmos Genéticos (AG) foram introduzidos por Holland (1975) e, ao longo do tempo, foram aplicados em diferentes áreas, devido a sua eficiência e versatilidade na resolução de problemas de otimização. Classificado como uma meta-heurística evolucionária, o método é baseado em populações, e envolve princípios de seleção natural e de sobrevivência dos indivíduos mais aptos.

Cada solução é tratada como um indivíduo da população e representada como um cromossomo (vetor), ou uma sequência de genes. Assim, cada cromossomo representa uma codificação de uma solução, enquanto um gene é um elemento do cromossomo que está associado a um valor, denominado alelo (Goldberg e Holland, 1988).

A população evolui ao longo das gerações por meio da combinação e alteração dos indivíduos. Isso é realizado a partir de dois operadores: cruzamento e mutação. Como critério de adequação para seleção dos indivíduos mais aptos (fitness), é usada a função objetivo do problema de otimização. Nesse processo de busca por indivíduos mais aptos, o cruzamento é o principal responsável pela intensificação da procura em áreas promissoras do espaço de soluções, enquanto a mutação contribui para a diversificação, por meio da exploração de novas regiões (Londe et al., 2025).

Em problemas de otimização combinatória, uma solução é, geralmente, codificada por uma cadeia finita, ou vetor, de números binários ou inteiros, o que permite a representação da reprodução entre dois indivíduos. Contudo, o cruzamento de duas soluções factíveis gera, frequentemente, soluções infactíveis. Essas soluções também são chamadas de indivíduos espúrios e devem ser tratadas ou descartadas. Por isso, a sua ocorrência pode limitar o espaço de soluções o aumentar o tempo de processamento do algoritmo.

Problemas de localização de facilidades (Fernandes et al., 2014; Izdebski et al., 2018) e problemas de roteamento (Bernardino e Paias, 2021; Park et al., 2021) são exemplos de problemas de otimização combinatória da literatura que aplicaram AG como abordagem de resolução. Contudo, a sua aplicação é ampla e não está restrita apenas a esses problemas (Gen e Lin, 2023).

Bean (1994) propõe uma alteração no Algoritmo Genético padrão, introduzindo uma nova classe de AG para problemas de otimização combinatória que evita o problema causado durante o cruzamento, mencionado anteriormente para a versão padrão. Denominado de Algoritmo Genético com Chaves Aleatórias (do inglês, “Random-Key Genetic Algorithm” - RKGA), o método utiliza uma representação diferente do cromossomo, codificada por uma cadeia finita, ou vetor, de chaves aleatórias. Cada chave é um número real, gerada randomicamente no intervalo contínuo $[0,1)$.

A partir de um decodificador, que recebe como parâmetro uma cadeia finita de chaves aleatórias e a mapeia, gerando uma solução para o problema, cujo custo é então calculado. A decodificação proposta por Bean (1994) ordena os alelos do cromossomo (ou elementos do vetor de chaves aleatórias), produzindo uma permutação que corresponde aos índices dos alelos ordenados. Essa decodificação remove a ocorrência de indivíduos espúrios durante o cruzamento.

Na literatura, o algoritmo RKGA já foi aplicado, por exemplo, na resolução de problemas de otimização combinatória que envolvem roteamento de veículos (Snyder e Daskin, 2006), migração de máquinas virtuais em data centers (Sarker e Tang, 2014), corte e empacotamento (Pinheiro, Amaro Júnior e Saraiva, 2015), redes de distribuição de energia (Magalhães et al., 2019), e rede de transportes (Gu et al., 2024).

Uma alteração à proposta de Bean (1994) é apresentada por Gonçalves e Resende (2011a). A abordagem é denominada Algoritmo Genético com Chaves Aleatórias Viciadas (do inglês, “Biased Random-Key Genetic Algorithm” - BRKGA). As principais alterações dessa proposta estão associadas à forma tendenciosa como os indivíduos são selecionados para o cruzamento e a forma como o cruzamento ocorre.

No BRKGA, o método de cruzamento uniforme parametrizado, proposto por Spears e DeJong (1991), é incorporado ao processo iterativo de evolução populacional. Nesse método, dados dois cromossomos genitores, cada gene de um novo indivíduo gerado é definido a partir de um sorteio aleatório. Esse sorteio decide de qual genitor esse gene será herdado.

Em relação a forma de seleção dos cromossomos genitores, assim como no RKGA, cada novo indivíduo é gerado pela combinação de dois genitores selecionados aleatoriamente. Contudo, nesse caso, o viés adicionado na seleção dos genitores impõe que um deles seja escolhido entre o grupo classificado como elite da população, enquanto o outro faça parte do grupo não-elite. Esse viés contribui para a tendência do algoritmo de preservar e propagar as características das soluções mais promissoras ao longo do processo de evolução (Londe et al., 2025).

Resende e Gonçalves (2011a) ressaltam que as decisões do algoritmo não são dependentes do problema que será otimizado, exceto pelo decodificador. Ele é específico para cada problema de otimização.

O BRKGA tornou-se uma variante popular dos AG, sendo aplicada em estudos que envolvem uma ampla gama de problemas de otimização combinatória. Em um artigo de revisão, Londe et al. (2025) apontam pelo menos 34 aplicações existentes na literatura, onde o algoritmo já foi utilizado. Entre esses problemas, é possível encontrar exemplos da classe NP-Difícil (Rochman et al., 2017); problemas de empacotamento (Gonçalves e Resende, 2011b); problemas de localização de facilidades (Biajoli, Chaves e Lorena, 2019); problemas de programação de tarefas (Andrade, Silva e Pessoa, 2019); roteamento de veículos (Lopes et al., 2016; Maziero, 2023).

3 MÉTODO

Nesta seção são detalhadas as etapas deste estudo. Inicialmente, são especificadas as características das instâncias de testes selecionadas. Em seguida, são apresentados os parâmetros adotados em cada algoritmo avaliados. Por fim, são descritos os testes computacionais executados.

3.1 Instâncias de teste

As instâncias de teste foram selecionadas da biblioteca TSPLIB (2024). Todas estão vinculadas ao Problema do Caixeiro Viajante simétrico.

A Tabela 1 detalha as informações de cada uma dessas instâncias. Para cada uma, são reportados o nome e o número de pontos que ela contempla.

Tabela 1 – Informações sobre as instâncias de teste utilizadas

Instância	Nº de pontos	Instância	Nº de pontos
st70	70	pa561	561
rat99	99	u574	574
kroA150	150	p654	654
kroB150	150	u726	726
d198	198	rat783	783
kroA200	200	dsj1000	1000
kroB200	200	si1032	1032
ts225	225	u1060	1060
tsp225	225	vm1084	1084
a280	280	vm1748	1748

Fonte: autores

3.2 Parâmetros dos algoritmos avaliados

No RKGA, a população inicial é dada por p indivíduos, gerados aleatoriamente. Em seguida, os indivíduos dessa população são particionados em um pequeno conjunto $p_e < p/2$. Esse grupo é denominado elite e contém os indivíduos mais aptos (melhores soluções). O restante da população $p - p_e$ é caracterizada como não elite.

A próxima geração da população carrega todos os indivíduos da elite que estavam na geração atual. Além disso, é adicionado um grupo de indivíduos mutantes p_m , gerados aleatoriamente. A nova geração é completada com indivíduos gerados por cruzamento. Os genitores de cada indivíduo são escolhidos entre os elementos de toda população p , e a probabilidade de o indivíduo gerado herdar um gene do pai a é ρ_a , enquanto a probabilidade de herdar um gene do pai b é $\rho_b = 1 - \rho_a$.

O BRKGA se distingue do RKGA em alguns pontos. Um deles é a forma como os genitores de cada indivíduo são escolhidos no cruzamento. Nesta variante, um genitor está, obrigatoriamente, entre o grupo da elite, enquanto o outro faz parte da não elite. Por conta disso, e como $p_e < p/2$, a probabilidade de um indivíduo da elite ser escolhido a cada cruzamento é de $1/p_e$, o que é superior a probabilidade de um indivíduo da não elite ser selecionado a cada cruzamento, que é de $1/(p - p_e)$.

Ambos os algoritmos utilizam o cruzamento uniforme parametrizado (Spears e DeJong, 1991) para gerar um indivíduo. Contudo, a probabilidade de herdar genes da elite é maior no BRKGA do que no RKGA, por conta da dinâmica de seleção dos genitores, que ocorre no cruzamento. O parâmetro ρ_e representa a probabilidade de que, no cruzamento, um indivíduo herde um gene do genitor da elite e $1 - \rho_e$ que ele o herde do genitor que não está na elite.

Em relação ao critério de parada, ambos os algoritmos são executados até que um dos critérios é atendido. Os critérios utilizados são o número máximo de gerações max_{ger} e tempo limite de execução t_{lim} .

Neste estudo, para ambos os algoritmos, todos os parâmetros comuns foram configurados da mesma forma para a execução dos testes. Eles seguem a sugestão proposta na literatura. A configuração adotada para os parâmetros intrínsecos aos algoritmos é apresentada na Tabela 2.

Tabela 2 – Configuração dos parâmetros adotada para os algoritmos RKGA e BRKGA

Parâmetro	Valor
Tamanho da população ρ	200
Número de indivíduos da elite ρ_e	$0,15 \times \rho$
Número de mutantes ρ_m	$0,05 \times \rho$
Probabilidade de herdar o gene do genitor da elite ρ_e	0,65
Número de máximo de gerações max_{ger}	300
Tempo limite de execução t_{lim}	3000 s

Fonte: autores

3.3 Testes computacionais

Em relação à condução dos testes computacionais, ambas as variantes do algoritmo foram implementadas em linguagem C++. Todos os testes foram conduzidos em uma máquina AMD Ryzen 7 2700, com processador de 8 núcleos e 4,1 GHz de frequência, 32 GB de memória RAM instalada, executando em sistema operacional Windows 11.

Para cada instância, foram executadas três repetições de cada teste em ambos os algoritmos avaliados. Desses testes, foram obtidos a melhor solução encontrada, o menor tempo de execução entre as três repetições realizadas e o tempo total das três execuções.

Para avaliar a qualidade das soluções, os resultados obtidos para as instâncias testadas foram comparados. O tempo de processamento até a obtenção da solução também foi analisado e comparado entre as variantes do algoritmo genético avaliadas.

4 RESULTADOS E DISCUSSÃO

Nesta seção, são reportados e analisados os resultados dos testes computacionais realizados com ambos os algoritmos. Inicialmente, é apresentado um comparativo sobre a qualidade da solução e, em seguida, os algoritmos são comparados em relação ao tempo de processamento.

Na Tabela 3 são apresentados os resultados médios obtidos para o conjunto de instâncias de teste. Eles são separados em dois grupos: as dez primeiras instâncias, que possuem até 280 pontos, e as 10 instâncias seguintes, com mais de 280 pontos. Primeiramente, é reportada a média das melhores soluções geradas pelo RKGA e pelo BRKGA, respectivamente. Em seguida, a melhoria na qualidade da solução do segundo algoritmo em relação ao primeiro é apresentada.

Tabela 3 – Resultados médios para qualidade da solução gerada pelos algoritmos RKGA e BRKGA

Conjunto de instâncias	RKGA	BRKGA	Melhoria do BRKGA sobre o RKGA
	Melhor solução	Melhor solução	Melhor solução (%)
até 280 pontos	130340	50593	34,96
mais de 280 pontos	54727568	12792789	6,31
Média geral	27428954	6421691	20,64

Fonte: autores

Os resultados detalhados dos testes mostraram que, para as instâncias testadas, o BRKGA gerou um maior número de melhores resultados. Quando comparamos a melhor solução obtida por cada algoritmo, após três repetições, a melhoria média do BRKGA sobre o RKGA é de 20,64%. Essa melhoria chegou a mais de 77% em instâncias em particular. Apesar de, em geral, o BRKGA ter gerado soluções consideravelmente menores, em um número menor de casos, o RKGA produziu soluções de melhor qualidade, interferindo assim na média.

Em seguida, na Tabela 4 são reportados os resultados médios para tempo de processamento. Novamente, eles são apresentados para dois subconjuntos de instâncias. São reportados os resultados médios para o RKGA, nesta sequência: menor tempo de execução, tempo total de execução de todos as repetições. Da mesma forma, em seguida, essas informações também são, respectivamente, fornecidas para o BRKGA.

Tabela 4 – Resultados médios para o tempo de processamento dos algoritmos RKGA e BRKGA

Conjunto de instâncias	RKGA		BRKGA		Melhoria do BRKGA sobre o RKGA	
	Menor tempo (s)	Tempo total (s)	Menor tempo (s)	Tempo total (s)	Menor tempo (%)	Tempo total (%)
até 280 pontos	138	1480	351	1317	49,84	-8,98
mais de 280 pontos	1624	5259	2920	8880	45,31	41,30
Média geral	881	3370	1636	5098	47,58	16,16

Fonte: autores

Em relação ao tempo de processamento, o RKGA atendeu os critérios de parada mais rapidamente. Quando avaliamos o melhor tempo entre as três repetições, a redução no tempo de processamento foi de 47,58% do RKGA em relação ao BRKGA, e de 16,16% quando avaliamos o tempo total das três execuções.

Considerando os resultados de uma forma geral, apesar de terem sido produzidos com base apenas em um conjunto de 20 instâncias, eles fornecem informações importantes sobre o desempenho dos algoritmos. Observou-se que em oito das vinte instâncias o BRKGA foi encerrado por atingir o limite de tempo de processamento estabelecido, enquanto no RKGA

essa mesma situação ocorreu apenas 2 vezes. Em ambos, tal situação compreendeu as instâncias com maior número de pontos.

Ainda, nos experimentos executados, os parâmetros foram definidos com base nos intervalos de valores sugeridos na literatura, sem que outras variações fossem executadas. Nos algoritmos genéticos com chaves aleatórias, a decodificação é a única questão dependente do tipo problema a ser resolvido; e as demais decisões são independentes. Contudo, os parâmetros do modelo influenciam na eficiência e eficácia da busca por melhores soluções, de forma que os resultados produzidos em cada problema ou conjunto de instâncias podem ser afetados por essa escolha.

A superioridade encontrada na qualidade média das soluções geradas pelo BRKGA justifica a crescente aplicação deste algoritmo nos últimos anos (Londe et al., 2025). A modificação proposta nesta variante, que busca preservar e propagar, ao longo das gerações, as características das soluções mais promissoras (Gonçalves e Resende, 2011a), é efetiva na geração de soluções finais de maior qualidade. Em contrapartida, esse processo pode demandar mais tempo de processamento. Ainda assim, é uma opção bastante interessante em relação aos algoritmos exatos, quando esse aspecto é analisado, especialmente considerando instâncias de grande porte.

Em suma, a condução deste estudo possibilitou aprofundar o entendimento teórico das técnicas utilizadas. A partir dos experimentos computacionais e da análise dos resultados foi possível avaliar o desempenho prático de cada um dos algoritmos envolvidos. Essa é uma etapa importante para uma posterior aplicação da abordagem em um contexto real.

5 CONSIDERAÇÕES FINAIS

Este estudo teve como foco avaliar o desempenho de dois algoritmos genéticos com chaves aleatórias na resolução de um problema clássico e complexo de otimização combinatória. As variantes abordadas foram o RKGA e o BRKGA. Um conjunto de instâncias da literatura, criadas para o Problema do Caixeiro Viajante simétrico, foi usado para executar os testes computacionais.

Os resultados encontrados forneceram informações importantes para a comparação dos dois métodos. Eles indicaram que a tendência incorporada no BRKGA, de preservar e propagar as características das soluções mais promissoras, é eficiente na melhoria da qualidade das soluções. No conjunto de instâncias avaliado, essa melhoria chegou, em média, a ser superior a 20%. Contudo, BRKGA também demonstrou exigir um tempo maior de execução. O tempo total foi, em média, mais de 16% superior quando comparado ao RKGA.

Com a realização deste estudo foi possível compreender melhor a dinâmica de funcionamento dos Algoritmos Genéticos com Chaves Aleatórias, em especial às variantes RKGA e BRKGA, proporcionando um aprofundamento teórico em relação a ambos. Essa dinâmica mostra que a inserção de chaves aleatórias à meta-heurística padrão é interessante, especialmente na resolução de problemas de otimização combinatória, evitando a geração de indivíduos espúrios durante o cruzamento. Contudo, como em qualquer algoritmo genético, os parâmetros adotados constituem um ponto crítico dessa abordagem. Estudos mais amplos são necessários para confirmar se a combinação de valores adotados é, de fato, a opção mais interessante para a resolução do problema abordado nesta pesquisa.

6 REFERÊNCIAS

- ANDRADE, C. E.; SILVA, T.; PESSOA, L. S. Minimizing flowtime in a flowshop scheduling problem with a biased random-key genetic algorithm. **Expert Systems with Applications**, n. 128, p. 67–80, 2019.
- BEAN, J. C. Genetic algorithms and random keys for sequencing and optimization. **ORSA Journal on Computing**, v. 6, p. 154–160, 1994.
- BERNARDINO, R.; PAIAS, A. Heuristic approaches for the family traveling salesman problem. **International Transactions in Operational Research**, v. 28, n. 1, p., 262–295, 2021.
- BIAJOLI, F. L.; CHAVES, A. A.; LORENA, L. A. N., A biased random-key genetic algorithm for the two stages capacitated facility location problem. **Expert Systems and Applications**, v. 115, p. 418–426, 2019.
- CHAVES, A. A.; GONÇALVES, J. F.; LORENA, L. A. N. Adaptive biased random-key genetic algorithm with local search for the capacitated centered clustering problem. **Computers & Industrial Engineering**, v. 124, p. 331–346, 2018.
- CHAVES; A. A.; VIANNA, B. L.; SILVA; T. T.; SCHENEKEMBERG, C. M. A parallel branch-and-cut and an adaptive metaheuristic to solve the Family Traveling Salesman Problem. **Expert Systems with Applications**, v. 228, Part A, 2024.
- DAHIYA, C.; SANGWAN, S. Literature Review on Travelling Salesman Problem. **International Journal of Research**, v. 5, n. 16, p. 1152–1155, 2018.
- DANTZIG, G.; FULKERSON, R.; JOHNSON, S. Solution of a large-scale traveling - salesman problem. **Journal of the Operations Research Society of America**, v. 2, n. 4, p. 393–410, 1954.
- FERNANDES, D. R. M.; ROCHA, C.; ALOISE, D.; RIBEIRO, G. M.; SANTOS, E. M.; SILVA, A. A simple and effective genetic algorithm for the two-stage capacitated facility location problem. **Computers & Industrial Engineering**, v. 75, p. 200–208, 2014.
- GEN, M., LIN, L. Genetic Algorithms and Their Applications. In: Pham, H. (Eds). **Handbook of Engineering Statistics**. London: Springer, 2023.
- GOLBARG, M. C.; LUNA, H. P. L. **Otimização combinatória e programação linear: modelos e algoritmos**. 2. ed. Rio de Janeiro: Campus, 2005.
- GOLDBERG, D.E.; HOLLAND, J. H. Genetic Algorithms and Machine Learning. **Machine Learning**, v. 3, p. 95–99, 1988.
- GONÇALVES, J. F.; RESENDE, M. G. C. Biased random-key genetic algorithm for combinatorial optimization. **Journal Heuristics**, v. 17, p. 487–525, 2011a.
- GONÇALVES, J. F.; RESENDE, M. G. C. A. A parallel multi-population genetic algorithm for a constrained two-dimensional orthogonal packing problem. **Journal of Combinatorial Optimization**, v. 22, n. 2, p. 180–201, 2011b.
- GONÇALVES, J. F.; RESENDE, M. G. C. Random-Key Genetic Algorithms. In: MART, R.; PARDALOS, P. M.; RESENDE, M. G. C. (Org.) **Handbook of Heuristics**, Springer International Publishing, p. 1–13, 2016.
- GU, Y.; RYU, S.; XU, Y.; CHEN, A.; CHAN, H. -Y.; XU, X. A random-key genetic algorithm-

based method for transportation network vulnerability envelope analysis under simultaneous multi-link disruptions. **Expert Systems with Applications**, v. 248, 123401, 2024.

IZDEBSKI, M.; JACYNA-GOLDA, I.; WASIAK, M.; JACHIMOWSKI, R., KŁODAWSKI, M.; PYZA, D.; ŻAK, J., The application of the genetic algorithm to multi-criteria warehouses location problems on the logistics network. **Transport**, v. 33, n. 3, p.741–750, 2018.

LONDE, M. A.; PESSOA, L. S.; ANDRADE, C. E.; RESENDE, M. G. C. Biased random-key genetic algorithms: a review. **European Journal of Operational Research**, v. 321, n.1, 2025.

LOPES, M. C.; ANDRADE, C. E.; QUEIROZ, T. A.; RESENDE, M. G. C.; MIYAZAWA, F. K., Heuristics for a hub location-routing problem. **Networks**, v. 68, n. 1, p. 54–90, 2016.

MAGALHÃES, M. T.; MIRANDA, G. B.; GONÇALVES, L. B.; MORENO, L. L. O.; SOARES, S. S. R. F.; OLIVEIRA, L. W. **A Random Keys Genetic Algorithm Approach for Reconfiguration Problem in Distribution Power Networks**. In: 2019 8th Brazilian Conference on Intelligent Systems (BRACIS), p. 866–871, 2019.

MATAI, R; SINGH, S. P.; MITALL, M. L. Traveling salesman problem: an overview of applications, formulations, and solution approaches. In: DAVENDRA D. (Ed.). **Traveling salesman problema, theory and applications**. InTech Press, London, p. 1–26, 2010.

MAZIERO, L. P. **Exact and heuristic algorithms for covering routing problems**. 2023. 106 f. Tese (Doutorado em Ciência da Computação) – Instituto de Computação, Universidade Estadual de Campinas, Campinas, 2023.

PARK, H.; SON, D.; KOO, B.; JEONG, B. Waiting strategy for the vehicle routing problem with simultaneous pick-up and delivery using genetic algorithm. **Expert System with Applications**, v. 165, 113959, 2021.

PINHEIRO, P. R.; AMARO JÚNIOR, B.; SARAIVA, R. D. A random-key genetic algorithm for solving the nesting problem. **International Journal of Computer Integrated Manufacturing**, v. 29, n.11, p. 1159–1165, 2015.

POP, P. C; COSMA, O.; SABO, C.; SITAR, C. P. A comprehensive survey on the generalized traveling salesman problem. **European Journal of Operational Research**, v. 314, n. 3, p. 819–835, 2024.

ROCHMAN, A.N.; PRASETYO, H.; NUGROHO, M.T. Biased random key genetic algorithm with insertion and gender selection for capacitated vehicle routing problem with time windows. In: **AIP Conference Proceedings**, v. 1855, n. 1, article 020025, 2017.

SARKER, T. K.; TANG, M. A Random Key Genetic Algorithm for Live Migration of Multiple Virtual Machines in Data Centers. In: **International Conference of Neural Information Processing - ICONIP**. Neural Information Processing, Lecture Notes in Computer Science, v. 8835, p. 212–220, 2014.

SNYDER, L. V.; DASKIN, M. S., A random-key genetic algorithm for the generalized traveling salesman problem. **European Journal of Operational Research**, v. 174, n. 1, p. 38–53, 2006.

SPEARS, W. M.; DEJONG, K. A. On the virtues of parameterized uniform crossover. In: **Fourth International Conference on Genetic Algorithms**. Proceedings of the Fourth International Conference on Genetic Algorithms, p. 230–236, 1991.

TOAZA, B.; ESZTERGÁR-KISS, D. A review of metaheuristic algorithms for solving TSP - based scheduling optimization problems. **Applied Soft Computing**, v. 148, n. 110908, 2023.

TSPLIB. **Traveling Salesman Problem Library**. Disponível em: <<http://comopt.ifl.uni-heidelberg.de/software/TSPLIB95/>>. Acesso em: 11 mar. 2024.