

Estudo Comparativo entre um Modelo Matemático e os Métodos Heurísticos BRKGA, RKO e Clustering-BRKGA para o Problema de Atenção Domiciliar

Marcus Vinicius da Silva

Shayane da Silva Carvalho

Maristela Oliveira dos Santos

Instituto de Ciências Matemáticas e de Computação (ICMC), Universidade de São Paulo
Av. Trabalhador São-carlense, 400 - Centro, CEP 13566-590, São Carlos - SP.

marcussilva@usp.br

shayanecarvalho@usp.br

mari@icmc.usp.br

RESUMO

Neste artigo, são realizados estudos sobre o problema de *Home Health Care Service*, que envolve visitas feitas por equipes médicas a pessoas que necessitam de atendimento e que, por alguma razão, estão impossibilitadas de ir até um hospital. No entanto, a realização dessas visitas depende de uma série de requisitos técnicos. O artigo apresenta uma formulação exata da literatura e aborda métodos heurísticos, como o RKO, aplicado aqui pela primeira vez neste contexto, e o BRKGA, já utilizado anteriormente. Além disso, introduz o novo método *Clustering-BRKGA*, que incorpora uma estratégia de agrupamento ao BRKGA para melhorar seu desempenho em conjuntos de instâncias complexas. Os resultados demonstram que as abordagens são eficazes na obtenção de soluções de qualidade, especialmente para instâncias de grande porte. O novo método *Clustering-BRKGA* demonstrou um desempenho superior nas instâncias de maior dimensão, envolvendo 300 pacientes.

PALAVRAS CHAVE. Atenção Domiciliar, BRKGA, RKO, Clustering-BRKGA.

Tópicos SA - PO na Área da Saúde, MH - Metaheurísticas

ABSTRACT

This article studies the Home Health Care Service problem, which involves visits made by medical teams to people in need of care who, for some reason, are unable to go to a hospital, however, these visits depend on a series of technical requirements. The article presents an exact formulation from the literature, as well as heuristic methods such as RKO, recently proposed and applied here for the first time in this context, BRKGA, previously applied to the problem, in addition, the new Clustering-BRKGA method was introduced, which incorporates a clustering strategy into BRKGA in order to improve its performance on complex data sets. The results show that the approaches are effective in obtaining quality solutions, especially for large instances. The new Clustering-BRKGA method showed superior performance on larger instances.

KEYWORDS. Home Care, BRKGA, RKO, Clustering-BRKGA.

Paper topics SA - OR in Health, MH - Metaheuristics

1. Introdução

O envelhecimento populacional tem sido observado ao longo dos últimos anos, trazendo consigo preocupações crescentes quanto à prestação de cuidados aos idosos, que frequentemente apresentam mobilidade reduzida e dificuldades na realização de tarefas diárias. Segundo dados da Organização Mundial da Saúde, a expectativa de vida global aumentou mais de seis anos entre 2000 e 2019, passando de 66,8 anos em 2000 para 73,4 anos em 2019 [Vieira et al., 2022].

Os serviços de atenção domiciliar são essenciais, pois englobam cuidados de saúde e assistência social, incluindo banho, alimentação e limpeza da residência. Eles atendem não apenas idosos, mas também pessoas de diferentes idades que, devido a condições de saúde, não podem se locomover até um hospital. O desenvolvimento de estratégias eficientes para garantir a qualidade desses atendimentos é fundamental, pois impacta diretamente a saúde mental e a qualidade de vida dos pacientes.

Neste trabalho, investigamos o Problema de Roteamento e Agendamento de Cuidados Domiciliares de Saúde (*Home Health Care Routing and Scheduling Problem*) (HHCRSP). Sua complexidade decorre da necessidade de definir sequências de visitas, atribuir cuidadores qualificados e determinar horários dentro das janelas de disponibilidade dos pacientes. Diversos estudos revisaram a literatura sobre o tema, incluindo os trabalhos de [Cissé et al., 2017], [Grieco et al., 2021], [Di Mascolo et al., 2021] e [Euchi et al., 2022].

Este problema, no horizonte de planejamento diário, considera que os pacientes podem necessitar de atendimentos únicos ou duplos, realizados por profissionais qualificados de diferentes especialidades médicas. Esses atendimentos podem ocorrer simultaneamente ou com precedência, respeitando intervalos de tempo entre os serviços. Nos atendimentos simultâneos, os horários de início devem idênticos, o que exige que o primeiro profissional a chegar aguarde a chegada do segundo. Nos atendimentos com precedência, há um intervalo de tempo mínimo e máximo necessários entre o início dos serviços, seguindo uma ordem predefinida. Por exemplo, considerando o conjunto $S = \{1, 2, 3\}$, o serviço 1 tem prioridade sobre os serviços 2 e 3, enquanto o serviço 2 é prioritário em relação ao serviço 3. Assim, qualquer serviço i tem precedência sobre um serviço j se $i, j \in S$. Dessa forma, é necessária a sincronização entre os planos de trabalho para garantir que o paciente receba ambos os atendimentos dentro da sua janela de disponibilidade.

O objetivo deste trabalho é apresentar um estudo comparativo entre um modelo matemático e três métodos heurísticos aplicados à resolução do problema. A formulação matemática foi desenvolvida por Mankowska et al. [2014], e recentemente utilizada no trabalho de Kummer et al. [2024]. A primeira abordagem trata-se da meta-heurística evolutiva *Biased Random-key Genetic Algorithm* (BRKGA), proposta no trabalho de Kummer et al. [2024]. O segundo método é o *Random-Key Optimizer* (RKO), que é o um *framework* que utiliza diversas meta-heurísticas clássicas para a resolução de problemas de otimização combinatória proposto por Chaves et al. [2024]. Neste trabalho, propomos uma nova aplicação do RKO ainda não abordada na literatura. Por fim, o *Clustering-BRKGA*, é o método proposto neste artigo, inspirado no trabalho de Pahlavani et al. [2022] que utiliza técnicas de agrupamento para um Problema de *Home Health Care Service*, visando unir a meta-heurística do BRKGA com técnicas de agrupamento, com o objetivo de melhorar as soluções encontradas principalmente em grandes instâncias.

2. Métodos de Solução

2.1. Modelo Matemático

Considere um conjunto $|C|$ de pacientes, um conjunto $|V|$ de cuidadores e um conjunto $|S|$ de tipos de serviços. Seja C^s o subconjunto dos pacientes que necessitam de atendimentos únicos e C^d o subconjunto daqueles que requerem atendimentos duplos. Os cuidadores devem iniciar e finalizar suas rotas de atendimento no centro de saúde, representado pelo nó 0. Defina-se

$C^0 = \{0\} \cup C$ o conjunto de nós com o centro de saúde e as localizações dos pacientes. A Tabela 1 apresenta todos os parâmetros e variáveis de decisão, enquanto o modelo é descrito a seguir.

Tabela 1: Parâmetros e variáveis do modelo Mankowska et al. [2014].

Parâmetros:
a_{vs} - Igual a 1 se o cuidador $v \in V$ é qualificado para realizar o tipo de serviço $s \in S$;
r_{is} - Igual a 1 se o paciente $i \in C$ requer o tipo de serviço $s \in S$. 0, caso contrário;
δ_i^{min} - Variação de tempo mínima entre tempos de início dos serviços no paciente $i \in C^d$;
δ_i^{max} - Variação de tempo máxima entre tempos de início dos serviços no paciente $i \in C^d$;
$[e_i, l_i]$ - Janela de tempo do paciente $i \in C$;
d_{ij} - Distância de viagem entre as localizações $i \in C^0$ e $j \in C^0$;
p_{is} - Tempo de processamento do serviço $s \in S$ no paciente $i \in C$;
M - Número grande;
Variáveis de Decisão:
x_{ijvs} - 1, se o membro da equipe v se move de i para j para realizar o atendimento do tipo de serviço s no paciente j . 0, caso contrário;
t_{ivs} - tempo de início do atendimento s no paciente i realizado pelo cuidador v ;
z_{is} - Atraso no atendimento do tipo de serviço s no paciente i .
$\lambda_1, \lambda_2, \lambda_3$ - Pesos.

Função Objetivo e Restrições:

$$\min \lambda_1 D + \lambda_2 T + \lambda_3 T^{max} \quad (1)$$

$$s.a : D = \sum_{v \in V} \sum_{i \in C^0} \sum_{j \in C^0} \sum_{s \in S} d_{ij} x_{ijvs} \quad (2)$$

$$T = \sum_{i \in C} \sum_{s \in S} z_{is} \quad (3)$$

$$T^{max} \geq z_{is} \quad \forall i \in C, s \in S \quad (4)$$

$$\sum_{i \in C^0} \sum_{s \in S} x_{0ivs} = \sum_{i \in C^0} \sum_{s \in S} x_{i0vs} = 1 \quad \forall v \in V \quad (5)$$

$$\sum_{j \in C^0} \sum_{s \in S} x_{jivs} = \sum_{j \in C^0} \sum_{s \in S} x_{ijvs} \quad \forall i \in C, v \in V \quad (6)$$

$$\sum_{v \in V} \sum_{j \in C^0} a_{vs} x_{jivs} = r_{is} \quad \forall i \in C, s \in S \quad (7)$$

$$t_{ivs_1} + p_{is_1} + d_{ij} \leq t_{jvs_2} + M(1 - x_{ijvs_2}) \quad \forall i \in C^0, j \in C, v \in V, s_1, s_2 \in S \quad (8)$$

$$t_{ivs} \geq e_i \quad \forall i \in C, v \in V, s \in S \quad (9)$$

$$t_{ivs} \leq l_i + z_{is} \quad \forall i \in C, v \in V, s \in S \quad (10)$$

$$t_{iv_2s_2} - t_{iv_1s_1} \geq \delta_i^{min} \quad \forall i \in C^d, \quad (11)$$

$$-M \left(2 - \sum_{j \in C^0} x_{jiv_1s_1} - \sum_{j \in C^0} x_{jiv_2s_2} \right) \quad v_1, v_2 \in V, s_1, s_2 \in S : s_1 < s_2$$

$$t_{iv_2s_2} - t_{iv_1s_1} \leq \delta_i^{max} \quad \forall i \in C^d \quad (12)$$

$$+M \left(2 - \sum_{j \in C^0} x_{jiv_1s_1} - \sum_{j \in C^0} x_{jiv_2s_2} \right) \quad v_1, v_2 \in V, s_1, s_2 \in S : s_1 < s_2$$

$$x_{ijvs} \in \{0, a_{vs} r_{js}\} \quad \forall i, j \in C^0, v \in V, s \in S \quad (13)$$

$$t_{ivs} \geq 0 \quad \forall i \in C^0, v \in V, s \in S \quad (14)$$

$$z_{is} \geq 0 \quad \forall i \in C, s \in S \quad (15)$$

$$D, T, T^{max} \geq 0. \quad (16)$$

A função objetivo ponderada (1) minimiza simultaneamente a distância total, o atraso total e o atraso máximo, dados respectivamente por (2), (3), e (4). As restrições (5) impõem que o início e o término das rotas de atendimento de cada cuidador devem ser no centro de saúde. As restrições (6) garantem que se o cuidador vai para o paciente i realizar o atendimento s , ele deve sair deste paciente depois de finalizar o serviço. As restrições (7) asseguram que o atendimento de cada tipo de serviço s seja atribuído a exatamente um cuidador qualificado. As restrições (8) determinam os tempos de início dos atendimentos com respeito às durações dos serviços e aos tempos de viagem. Além disso, asseguram que os horários de início dos serviços ao longo da rota do cuidador sejam estritamente crescentes. Com isso, os ciclos na rota são evitados, visto que o retorno a um paciente já visitado violaria o horário de início da visita anterior. As restrições

(9) garantem que os tempos de início dos atendimentos seja pelo menos a janela de tempo de início do paciente. As restrições (10) enfatizam que os tempos de início dos atendimentos podem ultrapassar as janelas de tempo de término dos pacientes, que é contabilizado pela variável de atraso. As restrições (11) atribuem a interdependência temporal para realização dos atendimentos duplos, garantindo um intervalo de tempo mínimo entre os tempos de início. As restrições (12) garantem um intervalo de tempo máximo entre dois atendimentos duplos. O domínio das variáveis de roteamento é dado por (13), em que $a_{vs}r_{js} = 1$, se o cuidador v é qualificado para realizar o tipo de serviço s , que é requerido pelo paciente $j \in C$. O domínio das demais variáveis de decisão é definido nas restrições (14) - (16).

2.2. BRKGA: Biased Random-Key Genetic Algorithm

A metaheurística *Biased Random-Key Genetic Algorithm* (BRKGA), proposta por Gonçalves e Resende [2011], é uma variante do algoritmo genético de chaves aleatórias, o *Random-key Genetic Algorithms* (RKGA), introduzido por Bean [1994], ambos amplamente utilizados na resolução de problemas de otimização combinatória. O BRKGA difere dos algoritmos genéticos tradicionais por empregar o conceito de chaves aleatórias para representar uma solução. Uma chave aleatória é um número real, gerado aleatoriamente no intervalo contínuo $[0,1)$. Além disso, o método adota uma abordagem distinta no processo evolutivo entre gerações [Resende, 2013]. A aplicação do BRKGA a diferentes problemas é viabilizada por meio de um *decoder*. De acordo com Resende [2013], um *decoder* é um procedimento que mapeia um vetor de chaves aleatórias em uma solução factível do problema de otimização e calcula o custo associado a essa solução. O algoritmo inicia com uma população de vetores de chaves aleatórias, que, a cada iteração, é dividida em dois subconjuntos: elite (composto pelos melhores indivíduos) e não elite (composto pelos demais). Todos os cromossomos classificados como elite são transferidos para a próxima geração. Outra parte da nova população é gerada por meio de recombinação: para isso, um cromossomo do conjunto elite e outro do não elite são selecionados, e um descendente é produzido combinando os alelos dos dois pais, uma outra pequena parte da nova população é formada por novos vetores de chaves aleatórias, chamados de mutantes, eles têm o papel de evitar que a população convirja para um ótimo local não global. Caso não ocorra melhora na melhor solução após k iterações, toda a população é substituída por uma nova geração criada aleatoriamente.

2.3. RKO: Random-Key Optimizer

O *Random-Key Optimizer* (RKO) é um método de busca local estocástico que utiliza o conceito de chave aleatória para a representar soluções em problemas de otimização combinatória, [Chaves et al., 2024]. O método é composto por diversas metaheurísticas, que podem ser executadas de forma independente ou em paralelo. Ele pode ser aplicado a diferentes tipos de problemas, desde que estes adotem a estrutura de um *decoder*, procedimento responsável por mapear o vetor de chaves aleatórias em uma solução factível, conforme descrito na seção anterior.

Neste trabalho, foi utilizado o *framework* do RKO com todas as metaheurísticas operando em paralelo. As soluções geradas são inseridas em uma *solution pool*, e o processo continua até que a condição de parada (definida pelo tempo máximo de execução) seja atingida. Ao final, a melhor solução presente na *solution pool* é selecionada como resultado final. Como cada metaheurística possui parâmetros específicos, o RKO inclui um mecanismo adicional para a definição destes, baseado na técnica do *Q-Learning*. Segundo Chaves et al. [2024], o *Q-Learning* é um algoritmo clássico de aprendizado por reforço que busca encontrar uma política estacionária ideal para minimizar o custo de longo prazo, por meio da simulação das transições do sistema sob uma política gulosa, refinada via aproximação estocástica. Em Chaves et al. [2024], são apresentados exemplos de problemas que podem ser resolvidos com o RKO, como o Problema de Roteamento de Veículos

e o Problema do Caixeiro Viajante. Este último, além de mencionado, foi implementado no repositório oficial do projeto disponível no *GitHub*. Para viabilizar a comparação de desempenho com os outros métodos, foi desenvolvido um *decoder* com base no algoritmo proposto por Kummer et al. [2024], permitindo a aplicação do RKO ao problema HHCRSP.

2.4. Clustering-BRKGA

O *Clustering-BRKGA* é um método proposto neste estudo para resolução do problema que incorpora ao BRKGA estratégias de agrupamento visando melhorias nas soluções, principalmente em grandes instâncias. O método proposto consiste, essencialmente, em separar as instâncias em diferentes grupos com base na localização geográfica dos pacientes. Para isso, utiliza-se o algoritmo de aprendizado não supervisionado *K-means*, responsável pela formação dos *clusters* (ver o Algoritmo 1). Após a criação dos grupos, o número de *clusters* é definido com base na técnica do *within-cluster sum of squares (wcss)*. Cada grupo resultante passa, então, a representar uma sub-região sobre a qual o BRKGA pode ser aplicado.

Após a etapa de criação dos *clusters*, inicia-se o processo de distribuição dos veículos (ver o Algoritmo 2). Essa etapa tem como objetivo de atribuir veículos aos grupos de forma a minimizar o compartilhamento entre eles. Idealmente, um veículo X atenderia apenas os pacientes pertencentes a um único *cluster* Y . Essa condição foi adotada com o intuito de simular uma situação prática, como a de um hospital que dispõe de equipes e veículos para realizar atendimentos domiciliares em diferentes regiões de uma cidade. O *Clustering-BRKGA* organiza estas regiões em grupos, e a restrição de que um veículo não atenda mais de um *cluster* busca evitar deslocamentos excessivos entre pacientes de regiões distintas. Uma restrição semelhante foi utilizada em Pahlevani et al. [2022], que abordou casos reais de *Home Health Care Service* na Austrália.

Depois desses dois processos, cada *cluster* é submetido ao *decoder*, de forma similar ao procedimento adotado no BRKGA clássico. Com isso, conclui-se a execução do *Clustering-BRKGA*. É importante destacar que o desempenho do algoritmo é muito sensível a forma como ele é parametrizado. Por esse motivo, utilizou-se a técnica de parametrização automática baseada em *Q-Learning*, conforme proposto em Chaves et al. [2024].

Algorithm 1 Pseudocódigo referente a criação dos *clusters*

```
for  $i \leftarrow 0$  to número de pacientes - 1 do
    Armazene o ID do paciente  $i$ 
    Armazene a posição no eixo X do paciente  $i$ 
    Armazene a posição no eixo Y do paciente  $i$ 
end
if número de pacientes  $\geq 75$  then
    número de clusters = função numClusters
end
else
    número de clusters = 1
end
Defina os centroides dos clusters
Aplique a função kmeans para montar os clusters
for  $i \leftarrow 0$  to número de clusters do
    Atribua um ID para o cluster  $i$ 
    Armazene o cluster  $i$  em um vetor de clusters
end
return vetor de clusters
```

Algorithm 2 Pseudocódigo referente a distribuição de veículos nos *clusters*

```
totalVehi ← número de veículos
numClusters ← número de número de clusters
Crie um vetor para armazenar as distribuições de veículos
Crie um vetor para armazenar os serviços requeridos em cada clusters
for  $i \leftarrow 0$  to número de clusters do
    | Armazene os serviços requeridos do cluster  $i$  no vetor correspondente
end
for  $v \leftarrow 0$  to número de veículos do
    | for  $i \leftarrow 0$  to número de clusters do
        | if Veículo  $v$  pode realizar o serviço do cluster  $i$  then
            | | Veículo  $v$  é atribuído exclusivamente ao  $i$ 
        end
        | Atualize o vetor de distribuição de veículos
    end
end
Garanta que o conjunto de veículos de cada cluster pode atender os serviços deles
if Um cluster precisa de um veículo para um serviço then
    | Compartilhe o veículo de outro grupo com ele
    | Atualize o vetor de distribuição de veículos
end
return vetor de distribuição de veículos
```

3. Resultados

Nesta seção são apresentados os experimentos computacionais realizados utilizando um conjunto de instâncias geradas no estudo de Mankowska et al. [2014], empregando as abordagens de solução descritas na Seção 2. O modelo matemático foi desenvolvido usando a linguagem de programação Python 3.10 e as instâncias foram resolvidas usando o solver de otimização Gurobi 11.0.3, com tempo limite de 7200 segundos. Os testes computacionais no modelo foram realizados no Cluster Euler, o qual possui processamento paralelo de 104 Blades Computacionais IP113, cada um equipado com 2 processadores Intel Xeon E5-2680v2 de 2,8 GHz, com vinte núcleos e 128 GB de memória DDR3 1866MHz, no sistema CentOS Linux 7. Os experimentos computacionais com os métodos heurísticos, todos implementados em C++, foram executados em um computador Intel i7-11370H de 4,80 GHz (clock máximo) com 16 GB de memória DDR4 3200MHz e rodando no Ubuntu 24.04 com o kernel Linux 6.11.0. Os códigos, disponibilizados pelos autores do artigo Kummer et al. [2024], foram utilizados para os testes do BRKGA, bem como as instâncias, cujas características são apresentadas na Tabela 2. Cada um dos conjuntos possui dez instâncias, que diferem na quantidade de pacientes, que contém de 10 a 300, e no conjunto de cuidadores, que pode conter de 3 a 40 cuidadores.

Com o intuito de deixar a comparação dos métodos a mais justa possível, além de testar todos na mesma máquina, ambos os BRKGAs utilizaram o *Q-Learning* com os mesmos parâmetros. Como o RKO tem como condição de parada o tempo de execução, em cada uma das categorias de instância foi dado um limitante similar ao tempo que os outros métodos heurísticos gastaram para convergir a uma solução. A Tabela 3 apresenta os resultados obtidos após a realização dos testes, tanto do modelo matemático quanto dos métodos heurísticos, para as instâncias. Observando os dados, nota-se que todos os métodos mostram-se similares, com diferenças mínimas em alguns casos, e nenhuma diferença em outros. Conforme as instâncias aumentam a dimensão, começam a aparecer algumas diferenças, no entanto, nenhum dos métodos se sobressai em relação aos outros. Para as instâncias de 300 pacientes, conjunto G, ambos os métodos RKO e o *Clustering-BRKGA* conseguiram superar o BRKGA em todos os casos. É possível ainda observar uma diferença nas soluções geradas por cada um desses dois métodos, onde o *Clustering-BRKGA* acaba tendo resultados inferiores aos outros métodos.

Tabela 2: Conjuntos de Dados: [Mankowska et al., 2014]

Conjuntos	$ C $	$ C^s $	$ C^d $	$ V $
A	10	7	3	3
B	25	17	8	5
C	50	35	15	10
D	75	52	23	15
E	100	70	30	20
F	200	140	60	30
G	300	200	100	40

Tabela 3: Resultados dos testes nos conjuntos de instâncias

Instância	Gurobi 11.0.3				BRKGA		RKO		Clustering-BRKGA	
	LB	Solução	Gap	Tempo (s)	Solução	Tempo (s)	Solução	Tempo (s)	Solução	Tempo (s)
A1	218,19	218,19	0,0	0,4	218,19	0,9	226,97	0,1	226,97	0,9
A2	246,62	246,62	0,0	0,48	246,62	0,9	246,62	0,1	246,62	0,8
A3	305,85	305,85	0,0	0,67	305,86	1,0	305,85	0,1	305,86	0,8
A4	186,89	186,89	0,0	0,66	186,89	0,9	186,89	0,1	186,89	0,7
A5	189,54	189,54	0,0	0,50	189,54	0,9	191,97	0,1	189,54	0,8
A6	200,09	200,09	0,0	0,37	200,12	0,9	200,12	0,1	200,09	0,8
A7	225,36	225,36	0,0	0,43	225,36	0,9	225,36	0,1	225,36	0,85
A8	232,04	232,04	0,0	0,35	232,04	0,9	232,04	0,1	232,04	0,8
A9	222,29	222,29	0,0	0,85	222,29	0,9	234,21	0,1	222,29	0,9
A10	225,00	225,00	0,0	0,25	225,01	0,9	225,01	0,1	225,01	0,8
B1	428,09	428,09	0,0	100,94	428,09	1,2	428,09	0,2	428,09	1,3
B2	476,04	476,04	0,0	16,28	476,05	1,3	483,63	0,1	486,67	1,2
B3	399,09	399,09	0,0	88,67	399,09	1,4	399,09	0,2	402,79	1,4
B4	411,29	411,29	0,0	44,22	422,06	1,6	420,28	0,3	438,11	1,3
B5	366,33	366,33	0,0	78,60	373,73	1,3	371,25	0,7	373,73	1,3
B6	440,92	440,92	0,0	236,45	470,59	1,3	470,99	0,2	470,99	1,4
B7	328,67	328,67	0,0	20,66	328,67	1,5	328,67	0,1	328,67	1,4
B8	357,68	357,68	0,0	14,71	357,68	1,4	359,69	0,1	357,68	1,4
B9	393,22	402,67	2,34	7200,0	402,67	1,4	402,67	0,2	402,67	1,7
B10	462,74	462,74	0,0	595,40	469,58	1,3	469,58	0,2	469,58	1,5
C1	597,49	945,42	36,79	7200,0	970,58	2,5	964,47	6,1	971,29	3,2
C2	448,24	571,32	21,54	7200,0	582,22	2,7	582,22	2,8	586,42	3,7
C3	85,11	565,93	14,27	7200,0	565,91	2,4	548,36	1,2	554,23	3,8
C4	444,43	495,16	10,24	7200,0	530,21	2,6	516,74	4,5	536,34	3,5
C5	632,86	657,57	3,75	7200,0	676,46	2,4	670,60	3,3	684,52	3,9
C6	435,41	814,63	46,55	7200,0	846,94	2,4	826,46	4,5	842,64	4,6
C7	431,33	522,28	17,41	7200,0	531,91	2,6	528,53	7,6	536,67	5,7
C8	420,51	473,05	11,10	7200,0	480,10	3,0	471,84	5,6	471,33	4,5
C9	440,89	549,00	19,69	7200,0	548,95	3,0	531,15	5,7	540,76	5,6
C10	551,22	590,25	6,61	7200,0	615,73	2,6	606,88	3,1	619,42	4,2
D1	624,36	1184,26	47,24	7200,0	1189,99	5,1	1155,63	8,2	840,44	4,7
D2	452,43	710,80	36,34	7200,0	689,58	4,3	701,86	8,8	721,65	5,0
D3	448,23	622,43	27,98	7200,0	660,02	5,1	639,91	8,3	616,17	5,3
D4	506,63	768,09	34,04	7200,0	845,35	4,1	794,84	9,0	649,63	4,5
D5	479,94	661,73	27,47	7200,0	721,76	4,9	690,11	9,4	727,54	5,1
D6	485,83	737,96	34,16	7200,0	754,34	6,1	727,55	10,0	741,72	6,8
D7	439,12	568,40	22,74	7200,0	598,26	5,4	590,17	10,4	596,35	5,5
D8	494,20	673,02	26,56	7200,0	711,38	5,9	663,48	8,9	705,53	4,9
D9	474,96	681,63	30,32	7200,0	725,39	4,7	709,37	9,8	891,03	4,8
D10	548,87	1276,14	56,98	7200,0	1352,44	4,1	1205,15	9,5	834,39	4,4
E1	513,06	1462,52	64,91	7200,0	1378,12	8,1	1367,04	10,3	880,69	8,5
E2	533,22	921,58	42,14	7200,0	1013,19	8,1	897,00	11,1	1002,9	9,7
E3	526,86	771,94	31,74	7200,0	818,76	8,1	815,65	10,8	867,62	8,8
E4	496,41	711,94	30,27	7200,0	741,56	15,8	754,60	10,8	782,91	10,9
E5	484,87	780,25	37,85	7200,0	832,48	7,9	844,93	9,59	872,21	9,30
E6	507,59	770,27	34,10	7200,0	880,72	11,2	801,71	11,0	853,22	7,9
E7	491,73	695,63	29,31	7200,0	739,25	9,60	758,63	11,67	825,23	12,2
E8	523,27	720,97	27,42	7200,0	775,37	8,5	764,65	10,6	825,82	10,1
E9	533,69	920,67	42,03	7200,0	1099,58	8,2	936,95	10,7	1014,26	10,6
E10	547,72	836,43	34,50	7200,0	908,87	9,6	855,50	10,6	859,72	10,8
F1	-	-	-	7200,0	1743,79	31,9	1538,88	34,3	1736,18	18,5
F2	-	-	-	7200,0	1742,32	29,1	1533,03	34,9	1535,8	25,2
F3	-	-	-	7200,0	1640,23	29,3	1388,19	34,2	1499,95	21,6
F4	580,63	2847,12	79,61	7200,0	1447,05	40,5	1210,30	37,8	1185,69	22,6
F5	560,88	8725,01	93,57	7200,0	1684,0	34,7	1548,51	34,3	1534,54	16,1
F6	552,36	7515,09	92,65	7200,0	1702,46	30,4	1510,23	34,4	1487,22	22,8
F7	550,33	2801,65	80,36	7200,0	1408,06	38,1	1312,85	35,9	1238,19	23,5
F8	591,94	2723,36	78,26	7200,0	1451,61	32,3	1332,42	33,7	1271,57	19,1
F9	574,89	7319,37	92,15	7200,0	1688,24	36,5	1516,02	35,8	1548,19	28,5
F10	-	-	-	7200,0	1774,15	36,4	1574,60	35,2	1571,63	28,2
G1	-	-	-	7200,0	2526,69	56,7	2184,96	97,8	1962,88	37,9
G2	-	-	-	7200,0	2532,18	62,4	2213,29	109,8	2143,13	65,1
G3	-	-	-	7200,0	2087,69	55,6	1782,84	94,5	1738,86	57,2
G4	-	-	-	7200,0	2166,51	66,8	1890,99	101,9	1742,97	64,0
G5	-	-	-	7200,0	2337,09	54,5	1970,33	97,7	1916,70	37,8
G6	-	-	-	7200,0	2471,32	66,9	2117,37	109,1	1914,95	41,5
G7	-	-	-	7200,0	2255,89	58,4	1943,39	95,9	1871,40	57,4
G8	-	-	-	7200,0	2208,86	55,4	1909,29	100,7	1745,07	56,9
G9	-	-	-	7200,0	2652,71	56,5	2233,65	102,4	2118,48	37,1
G10	-	-	-	7200,0	2761,45	51,1	2230,50	93,4	2219,19	54,5

4. Conclusões

Este artigo analisou diferentes abordagens para a resolução do *Home Health Care Routing and Scheduling Problem* (HHCRSP), abrangendo desde a modelagem matemática até a aplicação de metaheurísticas e *frameworks*. Com base nos resultados obtidos, observa-se que os algoritmos apresentaram desempenhos satisfatórios. O RKO, em particular, mostrou-se uma ferramenta

promissora, com grande potencial de aplicação em outros problemas de otimização, dada sua versatilidade. Além disso, os resultados obtidos com o RKO poderiam ser ainda melhores caso o tempo limite de execução fosse ampliado. O mesmo pode ser afirmado em relação ao BRKGA e ao *Clustering-BRKGA*, que também apresentaram soluções de boa qualidade. Ambos os métodos tem potencial para alcançar custos ainda menores com a adoção de estratégias mais refinadas de ajuste de parâmetros. Destaca-se, ainda, que o *Clustering-BRKGA* se revelou como uma alternativa eficaz à medida que aumenta a dimensão das instâncias, sendo adequado para problemas de grande escala.

Agradecimentos

Agradecemos o apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), número 125199/2024-4, e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES). Foram utilizados os recursos computacionais do Centro de Ciências Matemáticas Aplicadas à Indústria (CeMEAI), financiados pela FAPESP (proc. 2013/07375-0).

Referências

- Bean, J. C. (1994). Genetic algorithms and random keys for sequencing and optimization. *ORSA journal on computing*, 6(2):154–160.
- Chaves, A. A., Resende, M. G., de Arruda, E. F., e Silva, R. (2024). A random-key optimizer for combinatorial optimization. *arXiv preprint arXiv:2411.04293*.
- Cissé, M., Yalçındağ, S., Kergosien, Y., Şahin, E., Lenté, C., e Matta, A. (2017). Or problems related to home health care: A review of relevant routing and scheduling problems. *Operations research for health care*, 13:1–22.
- Di Mascolo, M., Martinez, C., e Espinouse, M.-L. (2021). Routing and scheduling in home health care: A literature survey and bibliometric analysis. *Computers & Industrial Engineering*, 158: 107255.
- Euichi, J., Masmoudi, M., e Siarry, P. (2022). Home health care routing and scheduling problems: a literature review. *4OR*, 20(3):351–389.
- Gonçalves, J. F. e Resende, M. G. (2011). Biased random-key genetic algorithms for combinatorial optimization. *Journal of Heuristics*, 17(5):487–525.
- Grieco, L., Utley, M., e Crowe, S. (2021). Operational research applied to decisions in home health care: A systematic literature review. *Journal of the Operational Research Society*, 72(9):1960–1991.
- Kummer, A. F., de Araújo, O. C., Buriol, L. S., e Resende, M. G. (2024). A biased random-key genetic algorithm for the home health care problem. *International Transactions in Operational Research*, 31(3):1859–1889.
- Mankowska, D. S., Meisel, F., e Bierwirth, C. (2014). The home health care routing and scheduling problem with interdependent services. *Health care management science*, 17:15–30.
- Pahlevani, D., Abbasi, B., Hearne, J. W., e Eberhard, A. (2022). A cluster-based algorithm for home health care planning: A case study in australia. *Transportation Research Part E: Logistics and Transportation Review*, 166:102878.
- Resende, M. G. (2013). Introdução aos algoritmos genéticos de chaves aleatórias viciadas. *Simpósio Brasileiro de Pesquisa Operacional*, p. 16–19.
- Vieira, B., De Armas, J., e Ramalhinho, H. (2022). Optimizing an integrated home care problem: A heuristic-based decision-support system. *Engineering Applications of Artificial Intelligence*, 114:105062.