

MODELAGEM MATEMÁTICA E META-HEURÍSTICA ANSGA-II APLICADAS NA OTIMIZAÇÃO DE CUSTO E EMISSÃO DE CO₂ PARA O PROBLEMA DO TRANSPORTE INTERMODAL DE SOJA

Eliel Lucas de Oliveira Silva
Alexandre Ribeiro
Jucelina Borges
Maria José Pereira Dantas
Tayná Rodrigues de Sousa Carvalho
Pontifícia Universidade Católica de Goiás

RESUMO

Este estudo abordou a problemática do transporte intermodal, com ênfase no sistema rodo-ferroviário voltado ao transporte de soja. Buscou-se minimizar tanto os custos quanto as emissões de CO₂. Para isso, foram empregadas duas estratégias de otimização: modelagem matemática com uso do solver Gurobi Optimizer (GO) e um Algoritmo Genético Adaptativo baseado em Ordenação Não Dominada (ANSGA-II). Os dados revelam que o GO identificou soluções ótimas em 100% das instâncias de dimensão moderada, em que o ANSGA-II teve uma eficácia média de 0.21% inferior em custo e 0.83% superior em redução de emissões quando comparada ao GO. Nos maiores *gaps*, as variações foram pequenas: somente 0.53% em emissões de CO₂ e 0.51% em custos. Assim, o ANSGA-II mostrou-se eficaz para o desafio do transporte intermodal bi-objetivo, mantendo uma margem estreita em relação ao solver e obtendo resultados para instâncias grandes em que o GO não conseguiu encontrar solução.

ABSTRACT

This article refers to the issue of intermodal transport, emphasizing the rail-road system for soy transportation. The focus was to minimize both cost and CO₂ emission. For such, two optimization strategies were used: math modeling with the usage of the tool solver Gurobi Optimizer (GO), and an Adaptive Genetic Algorithm based on Not Dominated Sorting (ANSGA-II). The data reveal that the GO identified optimal solution at 100% of the moderate-sized instances, in which the ANSGA-II had an average efficiency of 0.21%, a lower cost, and 0.83% higher at emission reduction. When compared to GO. At the larger gaps, the variation was small: Only 0.53% at the CO₂ emission and 0.51% at costs. Thus, the ANSGA-II showed up efficient for the rail and bi-objective intermodal transportation challenge, keeping a narrow margin when compared to the solver and takes results to large instances in which GO could not find a solution.

1. INTRODUÇÃO

O setor de transporte é um pilar fundamental da economia global, desempenhando um papel crítico na movimentação de mercadorias e pessoas. Com a crescente demanda por eficiência e sustentabilidade, a otimização de custos e a redução de emissões tornaram-se imperativos (Rodrigue, 2020; Shah *et al.*, 2021). Entre as várias mercadorias transportadas, a soja é de particular importância devido ao seu papel na alimentação e na indústria. Ao otimizar a logística de transporte de soja, permite que empresas do setor agrícola melhorem sua eficiência operacional e sustentabilidade ambiental. A redução nos custos de transporte e nas emissões de CO₂ pode ter um impacto positivo na lucratividade das empresas, ao mesmo tempo em que mitiga a pegada ambiental associada ao transporte de soja (Ballou, 2007; Pera, 2022).

Com base nessas informações, o presente artigo introduz uma abordagem para enfrentar o Problema do Transporte Intermodal, especificamente focado no transporte rodo-ferroviário de soja. Ao tratá-lo como um problema bi-objetivo, esta abordagem busca minimizar simultaneamente os custos de transporte e as emissões de CO₂. Isso culmina na promoção de práticas logísticas que não apenas são mais eficientes, mas também ecologicamente conscientes, no transporte de soja e, potencialmente, de outras commodities (Bektas e Laporte, 2011; Shah *et al.*, 2021).

No estudo abrangente documentado por Ma *et al.* (2023), foi observado que o *Non-dominated Sorting Genetic Algorithm II* (NSGA-II) tem sido amplamente aplicado em uma diversidade de contextos no planejamento de transporte. Tais aplicações englobam desde a otimização de rotas e alocação de berços em portos até a programação de veículos, dentre outras. A versatilidade e eficácia notáveis do NSGA-II, em particular na abordagem de problemas multiobjetivos, o posicionam como uma escolha estratégica ao se confrontar com os desafios intrínsecos dos sistemas de transporte, caracteristicamente complexos. Em suas recomendações para pesquisas futuras, Verma *et al.* (2021) sugere parâmetros dinâmicos para aprimorar o NSGA-II. O ANSGA-II (*Adaptive Non-dominated Sorting Genetic Algorithm*), abordado por Li *et al.* (2015), é uma versão adaptativa do NSGA-II, oferecendo uma configuração de parâmetros mais eficaz para a convergência.

Contudo, uma lacuna perceptível é a ausência de estudos que apliquem o ANSGA-II ao problema do transporte intermodal, particularmente no campo do transporte de soja. Portanto, é importante afirmar que a aplicação do ANSGA-II neste problema é promissora, tendo a sua capacidade de gerar um leque diversificado de soluções de alta qualidade, equilibrando de forma eficaz os custos de transporte e as emissões de dióxido de carbono (Deb *et al.*, 2002). Com base nesses aspectos e nas contribuições de Pera (2022), este estudo busca modelar matematicamente o problema em questão e implementá-lo usando o *Gurobi Optimizer* (GO) e o ANSGA-II, numa abordagem bi-objetiva. O objetivo é avaliar a eficácia da meta-heurística em paralelo com a ferramenta determinística.

O artigo está estruturado para fornecer uma compreensão abrangente do problema, da metodologia empregada e das implicações práticas das soluções propostas. Após esta introdução, o leitor encontrará seções detalhando definição do problema (Seção 2), a formulação do problema (Seção 3), a meta-heurística ANSGA-II (Seção 4), e os resultados obtidos (Seção 5). As considerações finais (Seção 6) sintetizam as contribuições do estudo e sugerem direções para futuras pesquisas.

2. DEFINIÇÃO DO PROBLEMA

Este estudo visa estabelecer um novo modelo matemático para o problema do transporte intermodal de soja, considerado uma variação do problema de transbordo originalmente esboçado por Dantzig (2003). Este modelo também tem semelhanças com a pesquisa conduzida por Oliveira *et al.* (2021), que focaliza a logística do transporte de soja.

Neste trabalho, a variante em foco inicia o transporte em N pontos de origem (produtores de soja) sempre por meio rodoviário, pode passar por K nós intermediários (terminais ferroviários) e chega a M pontos de destino (portos de exportação), que entregam a soja a U clientes com demandas específicas $d \in D$. O objetivo é otimizar o custo e emissão de CO_2 do transporte para todos os clientes com suas demandas específicas, buscando as rotas mais eficientes.

A problemática em questão propõe duas estratégias de transporte possíveis: a primeira envolve a passagem por pontos intermediários entre a origem e o destino, enquanto a segunda adota uma rota direta, conectando origem e destino de forma ininterrupta. A Figura 1 mostra um exemplo de solução do problema, em que o produtor 3 realiza a entrega via intermodal rodo-ferroviário e também diretamente até o porto por meio rodoviário. Neste estudo, os custos de transporte,

os custos intermodais e as emissões de cada modal, foram representados considerando suas respectivas unidades em termos de toneladas por quilômetro útil (TKU). É crucial respeitar as capacidades dos terminais ferroviários e portos.

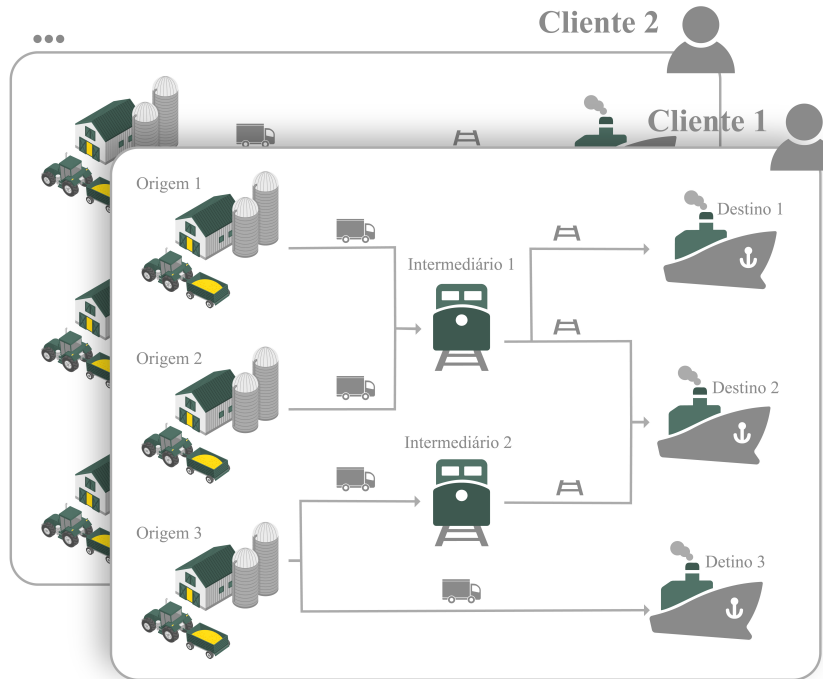


Figura 1: Possível representação de solução do problema

3. FORMULAÇÃO MATEMÁTICA

Esta seção detalha a formulação matemática associada ao problema bi-objetivo do transporte intermodal de soja proposta neste trabalho. A Equação (1) ilustra a função matemática que quantifica o custo associado ao transporte:

$$f_1 = \sum_{i=1}^N \sum_{k=1}^K \sum_{u=1}^U C_{iku} X_{iku} + \sum_{k=1}^K \sum_{j=1}^M \sum_{u=1}^U C_{kju} X_{kju} + \sum_{i=1}^N \sum_{j=1}^M \sum_{u=1}^U C_{iju} X_{iju} \quad (1)$$

A Equação (2) apresenta a função matemática responsável por calcular as emissões de CO₂ associadas ao transporte:

$$f_2 = \sum_{i=1}^N \sum_{k=1}^K \sum_{u=1}^U E_{iku} X_{iku} + \sum_{k=1}^K \sum_{j=1}^M \sum_{u=1}^U E_{kju} X_{kju} + \sum_{i=1}^N \sum_{j=1}^M \sum_{u=1}^U E_{iju} X_{iju} \quad (2)$$

Segue o modelo de programação linear para o problema estudado, com função objetivo:

$$\min f = (f_1, f_2) \quad (3)$$

Sujeito a:

$$\sum_{k=1}^K \sum_{u=1}^U X_{iku} + \sum_{j=1}^M \sum_{u=1}^U X_{iju} \leq O_i, \forall i \in \mathbb{N}_0 \quad (4)$$

$$\sum_{k=1}^K \sum_{j=1}^M X_{kju} + \sum_{i=1}^N \sum_{j=1}^M X_{iju} = D_u, \forall u \in \mathbb{N}_0 \quad (5)$$

$$\sum_{i=1}^N \sum_{u=1}^U X_{iku} \leq CF_k, \forall k \in \mathbb{N}_0 \quad (6)$$

$$\sum_{k=1}^K \sum_{u=1}^U X_{kju} + \sum_{i=1}^N \sum_{u=1}^U X_{iju} \leq CP_j, \forall j \in \mathbb{N}_0 \quad (7)$$

$$\sum_{i=1}^N \sum_{u=1}^U X_{iku} = \sum_{j=1}^M \sum_{u=1}^U X_{kju}, \forall k \in \mathbb{N}_0 \quad (8)$$

As Equações (1) e (2) compreendem três partes. A primeira quantifica custo e emissões de CO₂ do transporte rodoviário de N origens a K intermediários. A segunda estima custo e emissões de CO₂ do transporte ferroviário dos K intermediários aos M destinos. O terceiro componente calcula o custo e emissões de CO₂ do transporte rodoviário direto, das N origens aos M destinos sem passar por intermediários. A Restrição (4) assegura que a quantidade de recursos enviados por um produtor não ultrapasse sua capacidade de oferta. Por sua vez, a Restrição (5) estipula que a quantidade de recursos recebidos por um cliente deve atender integralmente à sua demanda. As Restrições (6) e (7) são implementadas para garantir que as capacidades dos pontos de transbordo ferroviários e dos portos de destino, respectivamente, não sejam sobrecarregadas pelas alocações destinadas ao atendimento aos clientes. Adicionalmente, a Restrição (8) estabelece a conservação de fluxo nos pontos de transbordo, funcionando como uma restrição de igualdade.

3.1. Parâmetros e Variáveis

3.1.1. Parâmetros do modelo

- C_{ik} : Custo do transporte do produtor i até o ponto ferroviário k , sendo $C_{ik} = C_r$.
- E_{ik} : Emissão do transporte do produtor i até o ponto ferroviário k , sendo $E_{ik} = E_{ij} = E_r$.
- C_{kj} : Custo do transporte do ponto ferroviário k até o porto j , sendo $C_{kj} = C_f$.
- E_{kj} : Emissão do transporte do ponto ferroviário k até o porto j , sendo $E_{kj} = E_f$.
- C_{ij} : Custo do transporte do produtor i até o porto j , sendo $C_{ij} = C_r$.
- C_r : Custo de transporte rodoviário, em R\$/TKU.
- C_f : Custo de transporte ferroviário, em R\$/TKU.
- E_r : Emissão de transporte rodoviário, em gCO₂/h.
- E_f : Emissão de transporte ferroviário, em gCO₂/h.
- CF_k : Capacidade do ponto ferroviário k .
- CP_j : Capacidade do porto j .
- O_i : Oferta do produtor i .
- D_u : Demanda do cliente u .

3.1.2. Variáveis

- X_{iku} : Quantidade transportada entre o produtor i e o ponto ferroviário k , para o cliente u .
- X_{kju} : Quantidade transportada entre o ponto ferroviário k e o porto j , para o cliente u .
- X_{iju} : Quantidade transportada entre o produtor i e o porto j , para o cliente u .

4. ANSGA-II

Nesta seção é apresentado o Algoritmo Genético Adaptativo Baseado em Ordenação Não Dominada (ANSGA-II) (Li *et al.*, 2015), uma adaptação do NSGA-II (Deb *et al.*, 2002), notável pela eficácia na otimização multiobjetivo (OM) (Ma *et al.*, 2023). Apoiado nos conceitos de Fronteiras de Pareto, ele identifica soluções ótimas e não dominadas para vários objetivos. O ANSGA-II categoriza soluções em diferentes camadas usando Fronteiras de Pareto e, com o princípio do elitismo, preserva soluções ótimas entre gerações.

Este algoritmo começa com uma população inicial de 80 indivíduos, uma quantidade deliberadamente escolhida, neste trabalho, para balancear entre desempenho e diversidade. Continuando, o algoritmo é executado até que o tempo disponível se esgote, implementando operadores de mutação e cruzamento ao longo do processo. Posteriormente, é realizada uma ordenação com base na dominação e calculada a distância de aglomeração. Por fim, o operador de seleção é empregado. As diferentes partes do ANSGA-II são explicadas em maior detalhe nas seções a seguir.

4.1. Representação do cromossomo

Neste estudo, conforme a Figura 2, cada cromossomo é caracterizado pelo comprimento $|D|$, no qual cada gene representa o esquema específico de distribuição da soja, com o propósito de atender uma demanda distinta d , que faz parte do conjunto integral D . A soja destinada a essa demanda é originada diretamente de um ou mais produtores e se estende até os terminais ferroviários e portos de destino. É importante notar que cada gene possui sua rota designada, que será responsável pelo escoamento da demanda correspondente.

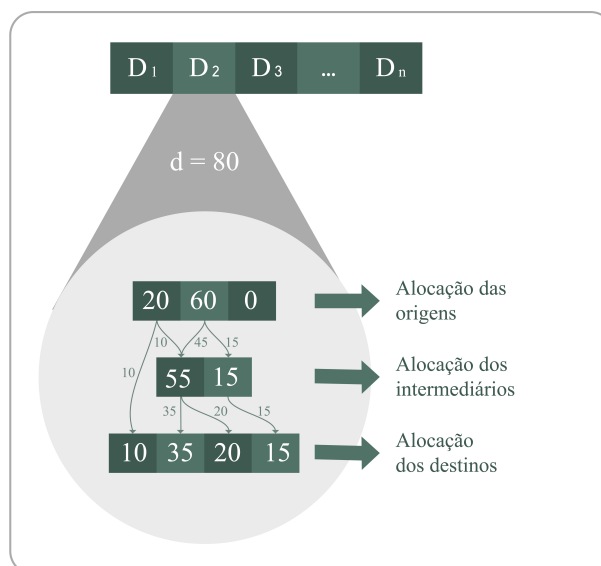


Figura 2: Representação do cromossomo

4.2. Geração da população inicial

A criação da população inicial é executada de forma aleatória. Durante este procedimento, cada gene equivale a um esquema de distribuição de soja destinado a satisfazer as necessidades de um cliente específico. Este esquema abrange a seleção aleatória das seguintes variáveis: a quantidade de soja fornecida por cada produtor, a quantidade de soja recebida em cada terminal ferroviário e a quantidade de soja entregue a cada porto de destino, tudo com o intuito de atender adequadamente à demanda do cliente correspondente ao respectivo gene.

Além disso, é necessário definir as rotas de distribuição a partir das alocações designadas. Para isso, foi empregada a heurística do vizinho mais próximo para determinar quais locais receberão os fluxos de soja. Estes fluxos são mapeados partindo dos pontos de produção, fluindo em direção aos terminais ferroviários e portos de destino, assim como dos terminais ferroviários diretamente aos respectivos portos finais. Após estabelecer essa rede de distribuição, são computados tanto o

custo total quanto as emissões totais de CO₂ geradas pelo transporte, com o intuito de satisfazer as demandas. Este processo é conduzido de maneira a respeitar todas as restrições referentes à oferta, capacidade e demandas.

4.3. Mecanismo Adaptativo

Neste estudo é adotada uma estratégia adaptativa para o NSGA-II, baseada na abordagem proposta por Li *et al.* (2015). Esta abordagem contesta a prática comum de evitar o cruzamento entre soluções ideais para prevenir a desestruturação de soluções e a precipitação para um ótimo local. O objetivo deste método é facilitar a transferência de estruturas eficientes entre gerações de soluções, com base no princípio de que soluções 'otimizadas' podem gerar soluções 'mais aperfeiçoadas'. Considerando essa premissa, ajustes adaptativos foram implementados nas taxas de crossover e mutação, aprimorando a flexibilidade e a reatividade do NSGA-II. Os mecanismos adaptativos aplicados aos operadores de cruzamento e mutação são explicados na Equação (9).

$$pc_i \approx \begin{cases} k_1 \frac{\bar{c} - c_{\min}}{c_i - c_{\min}} & , \text{ para } c_i > \bar{c} \\ k_3 & , \text{ para } c_i \leq \bar{c} \end{cases}, pm_i \approx \begin{cases} k_2 \frac{c_i - c_{\min}}{\bar{c} - c_{\min}} & , \text{ para } c_i \leq \bar{c} \\ k_4 & , \text{ para } c_i > \bar{c} \end{cases} \quad (9)$$

No contexto estudado, os termos pc_i e pm_i denotam, respectivamente, a probabilidade de cruzamento e a probabilidade de mutação do indivíduo i . Além disso, \bar{c} e c_{\min} são representações simbólicas para a média e o valor mínimo das classificações, respectivamente. Ademais, foi utilizado c_i para indicar a classificação do i -ésimo indivíduo. As constantes K1 a K4 servem para delimitar o valor máximo dessas operações, sendo definidas como K1=K3=1, K2=K4=0.5.

4.4. Operador de cruzamento

Foi proposto, neste trabalho, um operador de cruzamento que seleciona dois indivíduos via técnica do torneio, visando a geração de descendentes mais eficientes. A ativação deste operador depende de uma pc_i , favorável ao cruzamento, determinada pelo mecanismo adaptativo. Se os descendentes produzidos superam seus progenitores em eficácia, eles são incorporados à população existente.

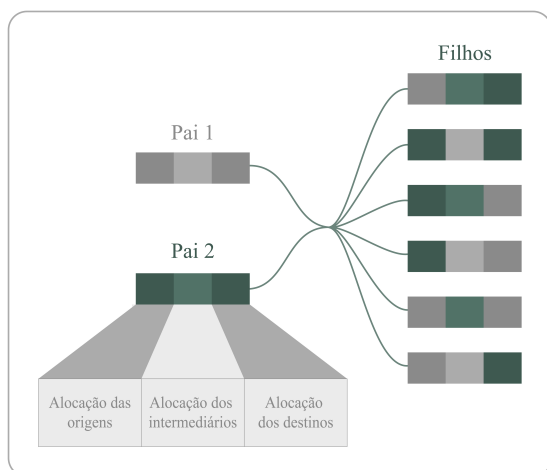


Figura 3: Visão básica do cruzamento

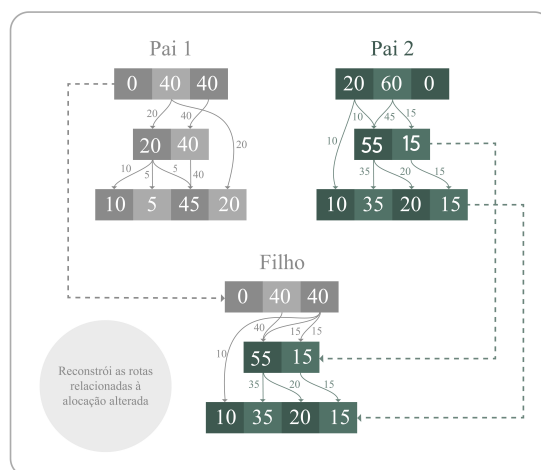


Figura 4: Visão detalhada do cruzamento

O processo específico do cruzamento, ilustrado nas Figuras 3 e 4, acontece para cada gene i dos progenitores, onde a operação é realizada em suas estruturas correspondentes de distribuição de demanda. O processo envolve a troca de estruturas de alocação relevantes entre os pais, aplicável para produtores, terminais ferroviários e portos de destino. Após à execução desse

procedimento, é necessário efetuar a reconstrução das rotas relativas ao gene específico. Tal processo é realizado através da seleção aleatória de pontos, os quais possuem alocações de soja, estabelecendo, assim, os novos locais para os quais as respectivas novas alocações serão direcionadas.

4.5. Operador de mutação

A mutação é um mecanismo estratégico, que visa à exploração de várias regiões dentro do extenso espaço de pesquisa. Esse processo é motivado, em cada indivíduo por uma pm_i favorável à mutação, fornecida pelo mecanismo adaptativo. No contexto deste estudo, a ocorrência da mutação resulta na geração de um novo indivíduo aleatório que substitui o original.

4.6. Ordenação não dominada

O método proposto envolve a categorização das soluções em diferentes níveis com base no princípio de dominância. Uma solução é considerada dominante se for pelo menos tão boa quanto todas as outras soluções em termos de objetivos e melhor em pelo menos um objetivo. O *ranking* é feito em várias frentes, onde a primeira frente consiste em soluções não dominadas com classificação 1, a segunda frente contém soluções dominadas apenas pelas da primeira frente com classificação 2, e assim por diante. Dessa forma, o método ANSGA-II promove a diversidade de soluções otimizadas ao abranger a fronteira de Pareto, oferecendo um conjunto diversificado de soluções de qualidade para problemas multiobjetivo (Verma *et al.*, 2021).

4.7. Distância de aglomeração

A métrica de distância de aglomeração utilizada pelo ANSGA-II é uma medida que quantifica a distância entre as soluções presentes na fronteira de Pareto, promovendo uma diversidade eficaz entre as soluções propostas. Essa métrica permite manipular a distância de aglomeração para preservar um equilíbrio adequado entre convergência, que busca soluções ideais, e diversidade, que busca explorar um amplo espectro de soluções ótimas. Para esse cálculo, estima-se a densidade de soluções próximas a uma solução específica (Verma *et al.*, 2021).

4.8. Operador seleção

No processo de seleção, são escolhidos os indivíduos mais promissores da população atual para gerar os indivíduos da próxima geração. Neste estudo, utilizou-se o método de seleção por torneio, no qual um conjunto predefinido de indivíduos é selecionado aleatoriamente da população atual para competir entre si. O competidor com a menor classificação é considerado o vencedor. No entanto, caso ocorra um empate de ranqueamento, o competidor com a maior distância de aglomeração é declarado vencedor. Esse ciclo é repetido até que o tamanho fixo estabelecido para a população seja alcançado (Verma *et al.*, 2021).

5. SIMULAÇÕES COMPUTACIONAIS

A eficácia do modelo matemático aplicado ao GO e do ANSGA-II foi avaliada através de instâncias geradas aleatoriamente devido à falta de bibliotecas adequadas para a variação específica deste estudo. O GO foi configurado para adotar uma estratégia hierárquica para multiobjetivos e resolver as instâncias, agindo como *benchmark* para o ANSGA-II. Os testes foram realizados no *Windows 10*, usando um Intel Core i7-1165G7, com o algoritmo ANSGA-II implementado em Python 3.8.

5.1. Resultados

5.1.1. Gurobi x ANSGA-II

No primeiro experimento, um conjunto de instâncias foi otimizado pelo GO, tendo f_1 como prioridade hierárquica. A Tabela 1 mostra uma seleção representativa das instâncias, com dimensões e resultados do GO. O Gurobi mostrou eficácia, alcançando soluções ótimas em 5 instâncias, em menos de 20 minutos, mas falhou em instâncias maiores devido ao consumo excessivo de recursos, levando à interrupção prematura do processo de otimização, denominada "Killed". Em seguida, o ANSGA-II otimizou as mesmas instâncias para avaliar a modelagem do problema sob a perspectiva do algoritmo evolutivo. Foram geradas vinte soluções por instância, cada execução por 20 minutos. Para fins de comparação, a solução não dominada com o menor valor de f_1 foi selecionada em cada caso. As médias dessas soluções, denotadas por \bar{f}_1 e \bar{f}_2 , foram depois comparadas com os resultados obtidos pelo GO.

Tabela 1: Perfil Dimensional das Instâncias de Teste e resultados do GO

Instância	Produtores	Ferrovias	Portos	Clientes	f_1 Gurobi	f_2 Gurobi
1	47	10	216	65	1.8006711e+07	1.82320e+05
2	60	20	30	200	3.7616628e+07	8.35866e+05
3	98	2	26	758	3.30420609e+08	2.887000e+06
4	120	30	60	300	7.961368e+06	2.23574e+05
5	110	28	5	1594	8.11359533e+08	5.417581e+06
6	230	31	120	4379	<i>killed</i>	<i>killed</i>
7	2000	80	1000	3000	<i>killed</i>	<i>killed</i>

Tabela 2: Comparativo de Resultados: Gurobi x ANSGA-II

Instância	\bar{f}_1 ANSGA - II	\bar{f}_2 ANSGA - II	$\bar{f}_1 - gap$ %	$\bar{f}_2 - gap$ %
1	1.8007702e+07	1.82337e+05	0.005	0.009
2	3.7794254e+07	8.29942e+05	0.4	-0.7
3	3.30860517e+08	2.902556e+06	0.13	0.53
4	8.002391e+06	2.14599e+5	0.51	-4
5	8.11407115e+08	5.417621e+06	0.005	0.0007
6	1.70618967e+08	3.699404e+06	-	-
7	2.0910889e+07	5.67803e+05	-	-
Média			0.21	-0.83

A Tabela 2 apresenta os resultados do ANSGA-II e a análise de discrepâncias (*gap*) para as funções f_1 e f_2 , com relação aos resultados obtidos pelo GO. Para f_1 , o maior *gap* obtido foi na Instância 4, em que o ANSGA-II alcançou um resultado 0.51% pior que a solução exata do GO. Para f_2 , o maior *gap* positivo obtido foi na Instância 3, em que o ANSGA-II alcançou um resultado 0.53% pior que a solução exata do GO. Porém, devido a escolha hierárquica de f_1 , o ANSGA-II apresentou resultados melhores de f_2 em duas instâncias, chegando a ser 4% melhor que o GO na Instância 4. Além disso, as médias dos valores de \bar{f}_1 e \bar{f}_2 para as instâncias testadas apresentaram uma degradação de 0.21% e uma melhoria de 0.83%, respectivamente. Isso indica uma pequena diferença no custo e uma otimização nos *gaps* de emissão, comparados ao GO.

5.1.2. Teste com dados realísticos

Utilizando o GO e o ANSGA-II, otimizou-se um caso de transporte de soja com cidades de Goiás e da Bahia com dados realísticos. As Tabelas 3 e 4 mostram as cidades de origem, destino, pontos ferroviários e suas respectivas distâncias que foram retiradas de (ANTT, 2023). A Tabela 5 apresenta as capacidades de armazenamento de soja por origem, obtidas de (IBGE, 2023), considerando que 76% da oferta total será direcionada para exportação, conforme (ABIOVE, 2023). As Tabelas 6 e 7 apresentam as capacidades de cada ponto ferroviário e porto que foram arbitradas em função do total das ofertas de todas as origens com a proporção da quantidade de soja recebida em cada ponto ferroviário e porto no ano de 2022 (ANTT, 2023; CONAB, 2023). No estudo em questão, estabeleceu-se a capacidade das ferrovias de Anápolis, Rio Verde, São Simão, Ipameri em 8,12%, 62,18%, 25,14% e 4,56% do valor total das ofertas, respectivamente. De forma comparativa, os portos de Tubarão, Santos e Salvador apresentaram capacidades de 53,73%, 0,3% e 16,27% em relação ao total ofertado, respectivamente. Intencionalmente, atribuiu-se ao porto de Santos uma capacidade bem inferior à sua realidade, buscando um cenário mais conflituoso para o ANSGA-II, uma vez que é o porto mais próximo das origens.

Tabela 3: Distância de Origens para Ferrovias e Portos (Km)

	Anápolis	Rio Verde	São Simão	Ipameri	Tubarão	Santos	Salvador
Aragarças	408.00	372.00	523.00	588.00	1 753.00	1 354.00	1 998.00
Catalão	256.00	392.00	367.00	62.40	1 150.00	774.00	1 725.00
Cristalina	223.00	499.00	548.00	173.00	1 136.00	957.00	1 542.00
Porangatu	392.00	654.00	772.00	586.00	1 652.00	1 441.00	1 536.00
Goiânia	57.10	249.00	367.00	204.00	1 418.00	1 010.00	1 646.00
LEM	691.00	977.00	1113.00	811.00	1 654.00	1 594.00	954.00

Tabela 4: Distâncias Ferrovias-Portos (Km)

Ponto Ferroviário	Tubarão	Santos	Salvador
Anápolis	1 750.57	1 541.01	1950.00
Rio Verde	2 079.07	1 212.51	2300.00
São Simão	2 298.07	989.27	2750.00
Ipameri	1 536.01	1 033.66	2100.00

Tabela 5: Ofertas das origens (t)

Origem	Ofertas
Aragarças	243 138.00
Catalão	1 253 270.00
Cristalina	755 250.00
Porangatu	354 063.00
Goiânia	143 703.00
LEM	1 631 300.00

Tabela 6: Capacidade Ferrovias (t)

Ponto Ferroviário	Capacidade
Anápolis	355 714.00
Rio Verde	2 723 934.00
São Simão	1 101 314.00
Ipameri	199 761.00

Tabela 7: Capacidade dos portos (t)

Porto	Capacidade
Tubarão	2 353 763.00
Santos	1 314 217.00
Salvador	712 743.00

Segundo (ONTL, 2023), os valores de emissão de CO₂ são 18,05 gCO₂/TKU e 52,77 gCO₂/TKU para os modais ferroviário e rodoviário, respectivamente. Conforme (EPL, 2023), o custo de transporte rodoviário é 15,42 R\$/TKU e 7,03 R\$/TKU para o ferroviário, ambos para granel

agrícola. Valores hipotéticos foram utilizados para as demandas dos clientes e para velocidades médias utilizadas para calcular o tempo do transporte, devido à falta de dados reais.

Para otimizar o caso em questão, foi utilizado o ANSGA-II, que operou por 5 minutos com 80 indivíduos. Os resultados gerados pelo ANSGA-II apresentaram um conjunto de soluções não dominadas, as quais estão especificadas na Tabela 8. A evolução final desse conjunto pode ser observada na Figura 5. Nessa imagem, a frente de Pareto, constituída por soluções não dominadas, é destacada em verde. A Figura 6 ilustra a solução de menor custo, enquanto a Figura 7 evidencia a solução com a menor emissão, correspondendo, respectivamente, às soluções 1 e 5. As duas soluções apresentam uma diferença de 2.09% para f_1 e 0.62% para f_2 . Esta variação é considerável, especialmente quando se leva em conta um caso de teste de pequena magnitude.

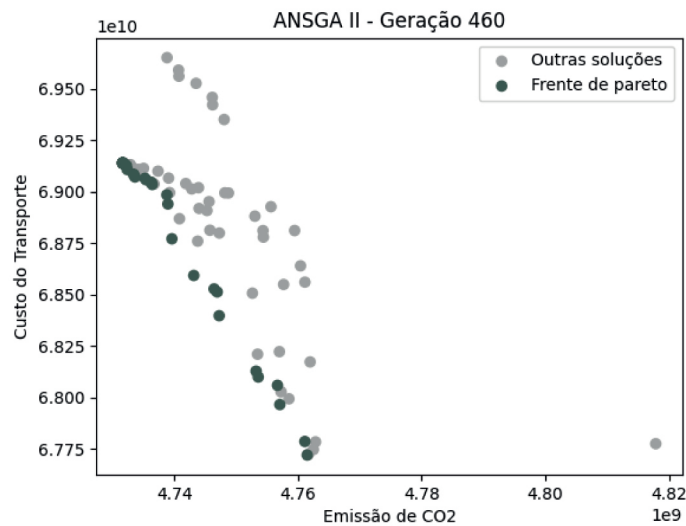


Figura 5: Frente de Pareto obtida para a solução do problema (R\$, gCO₂)

Tabela 8: Conjunto de Soluções não dominadas (R\$, gCO₂)

	f_1	f_2
Solução 1	67 721 739 074.29	4 761 491 591.20
Solução 2	68 771 585 626.57	4 739 608 177.96
Solução 3	69 079 250 755.63	4 733 505 329.32
Solução 4	69 127 372 350.55	4 732 255 125.49
Solução 5	69 139 887 114.61	4 731 642 756.61

Este trabalho não compara o tempo de execução do GO e do ANSGA-II, pois o último continua a descobrir novas soluções e expandir a frente de Pareto ao longo do tempo. Portanto, um tempo de execução mais curto pode resultar em um conjunto limitado de soluções na frente de Pareto, restringindo as escolhas para os gerentes de transporte. Para um cenário de teste baseado em dados parcialmente reais e de tamanho pequeno, um período de 5 minutos de execução foi suficiente para avaliar a eficácia do ANSGA-II na obtenção de uma variedade extensa de

soluções viáveis com valores próximos ao ótimo.

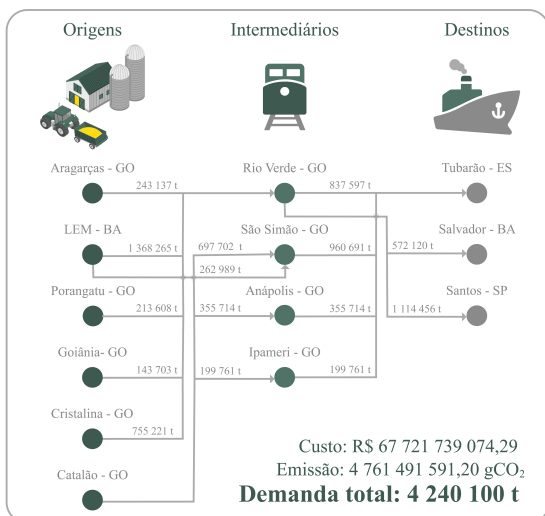


Figura 6: Solução com menor custo

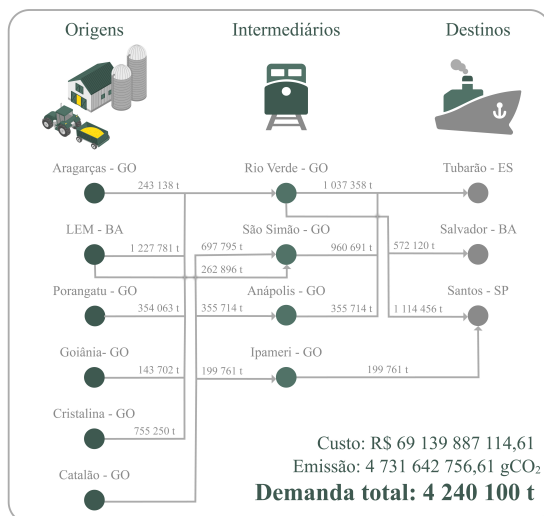


Figura 7: Solução com menor emissão

6. CONSIDERAÇÕES FINAIS

Neste estudo, o algoritmo NSGA-II, enriquecido com mecanismos adaptativos, foi aplicado ao desafio do transporte intermodal de soja, com foco em dois objetivos. Para instâncias de tamanho moderado, o ANSGA-II mostrou *gaps* em relação ao GO de apenas 0.53% a mais em emissão de CO₂ e 0.51% a mais em custo. Notavelmente, estes apresentaram um acréscimo de 0.13% no custo e uma redução de 4% na emissão, respectivamente. Isso indica que a meta-heurística não apenas minimiza custos operacionais, mas supera o GO em termos de redução de CO₂, tendo implicações significativas do ponto de vista ambiental.

Sendo que, para instâncias maiores o ANSGA-II foi o único capaz de obter soluções, dada a interrupção prematura pelo consumo excessivo de recursos computacionais. Isso demonstra a eficácia e vantagens de abordar o problema do transporte intermodal de soja sob uma perspectiva multiobjetivo utilizando a meta-heurística ANSGA-II.

Adicionalmente, um aspecto notável do ANSGA-II foi observado: a sua inerente capacidade de fornecer um vasto conjunto de soluções, construído sobre o conceito de Frente de Pareto. Esta característica é de suma importância, particularmente para gestores de empresas de transporte. Ela proporciona um espectro abrangente de opções de rotas para atender a demandas que exibem diferentes balanços entre os objetivos estabelecidos, permitindo a escolha de uma solução que se alinhe de maneira mais eficiente às necessidades específicas de cada situação. Quais sejam, a priorização do menor custo, da menor emissão de CO₂ ou de uma ponderação entre os dois objetivos.

Outro ponto crucial que beneficia os gestores em questão é a integração de mecanismos adaptativos no NSGA-II (ANSGA-II). Esses mecanismos simplificam consideravelmente a configuração do algoritmo, dado que o único parâmetro a ser calibrado é o tamanho da população. Isso resolve uma dificuldade recorrente na utilização de algoritmos genéticos: a obrigatoriedade de ajustar múltiplos parâmetros para garantir uma melhor convergência (Li *et al.*, 2015).

Pesquisas futuras relacionadas a este campo poderiam enriquecer a análise ao incorporar critérios adicionais de otimização, tal como a mitigação das perdas de soja durante o transporte. É plausível considerar, também, uma modificação no modelo que permita que algumas demandas fiquem sem atendimento, com a adição de uma meta voltada para a otimização do número de demandas efetivamente satisfeitas. Ainda, a investigação de outras metaheurísticas que possam gerar melhores resultados.

Agradecimentos

Agradecimento ao CNPQ pela bolsa PIBIC.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABIOVE (mar. de 2023) *Estatísticas do Complexo Soja*. [Planilha de dados].
- ANTT (jul. de 2023) *Transporte de Carga - Origem Destino - 2006 - maio 2023*. [Planilha de dados].
- Ballou, R. H. (2007) *Gerenciamento da cadeia de suprimentos/logística empresarial*. (5ª ed.) Bookman, Porto Alegre.
- Bektas, T. e G. Laporte (2011) The Pollution-Routing Problem. *Transportation Research Part B: Methodological*, v. 45, n. 8, p. 1232–1250.
- CONAB (2023) *Boletim Logístico*.
- Dantzig, G. (2003) Transportation Problem and Variations. *Linear Programming: 2: Theory and Extensions*. Springer New York, New York, NY, p. 207–229.
- Deb, K.; A. Pratap; S. Agarwal e T. Meyarivan (2002) A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, v. 6, n. 2, p. 182–197.
- EPL (2023) *Simulador de Custo de Transporte*.
- IBGE (2023) *Produção Agrícola Municipal*.
- Li, J.; J. Chen; B. Xin e L. Dou (2015) Solving multi-objective multi-stage weapon target assignment problem via adaptive nsga-ii and adaptive moea/d: A comparison study. *2015 IEEE Congress on Evolutionary Computation (CEC)*. IEEE, p. 3132–3139.
- Ma, H.; Y. Zhang; S. Sun *et al.* (2023) Uma pesquisa abrangente sobre NSGA-II para otimização e aplicativos multiobjetivos. *Artificial Intelligence Review*.
- Oliveira, A. L. R. d.; M. Filassi; B. F. R. Lopes e K. B. Marsola (2021) Logistical transportation routes optimization for Brazilian soybean: an application of the origin-destination matrix. *Ciência Rural*, v. 51, n. 2, p. e20190786.
- ONTL (2023) *Simulador de Gases de Efeito Estufa (GEE)*.
- Pera, T. G. (2022) «Efeitos das mudanças tecnológicas e infraestruturais do transporte para o fomento da logística verde da soja brasileira: abordagens multiobjetivos». Tese de doutoramento. Universidade de São Paulo.
- Rodrigue, J.-P. (2020) *The Geography of Transport Systems*. Routledge.
- Shah, K. J.; S.-Y. Pan; I. Lee; H. Kim; Z. You; J.-M. Zheng e P.-C. Chiang (2021) Green transportation for sustainability: Review of current barriers, strategies, and innovative technologies. *Journal of Cleaner Production*, v. 326, p. 129392.
- Verma, S.; M. Pant e V. Snasel (2021) A Comprehensive Review on NSGA-II for Multi-Objective Combinatorial Optimization Problems. *IEEE Access*, v. 9, p. 57757–57791.

Eliel Lucas de Oliveira Silva (eliel.lucas3000@gmail.com)

Alexandre Ribeiro (alexribeiro@pucgoias.edu.br)

Jucelina Borges (juceleandro@bol.com.br)

Maria José Pereira Dantas (mjpdantas@gmail.com)

Tayná Rodrigues de Sousa Carvalho (tayrscarvalho@gmail.com)

Escola Politécnica e de Artes, Pontifícia Universidade Católica de Goiás

Goiânia, GO, 74605-020, Brasil