

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA POLITÉCNICA E DE ARTES
GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**



**Otimização da Cobertura de Dispensação de Medicamentos com Minimização de
Sobras: Um Sistema Baseado em Algoritmos Genéticos**

IGOR DA SILVA PAIXÃO

Goiânia
2025

IGOR DA SILVA PAIXÃO

Otimização da Cobertura de Dispensação de Medicamentos com Minimização de Sobras: Um Sistema Baseado em Algoritmos Genéticos

Monografia apresentada como Trabalho de Conclusão de Curso à Escola Politécnica e de Artes da Pontifícia Universidade Católica de Goiás, como parte dos requisitos exigidos para a obtenção do título de Bacharel em Ciência da Computação.

Orientador(a):

Prof. Dr. Sibelius Lellis Vieira

Banca examinadora:

Prof. Me. Fernando Gonçalves Abadia

Prof. Me. Gustavo Siqueira Vinhal

Goiânia
2025

IGOR DA SILVA PAIXÃO

Otimização da Cobertura de Dispensação de Medicamentos com Minimização de Sobras: Um Sistema Baseado em Algoritmos Genéticos

Trabalho de Conclusão de Curso aprovado em sua forma final pela Escola Politécnica e de Artes, da Pontifícia Universidade Católica de Goiás, para a obtenção do título de Bacharel em Engenharia de Computação em __/__/____.

Orientador(a): Prof. Dr. Sibelius Lellis Vieira

Prof. Me. Fernando Gonçalves Abadia

Prof. Me. Gustavo Siqueira Vinhal

Goiânia
2025

Resumo

Centros de dispensação de medicamentos de alto custo enfrentam um dilema logístico crítico: garantir cobertura total dos pacientes agendados enquanto minimizam o desperdício por vencimento de produtos perecíveis. Nesse contexto, este trabalho propõe um sistema computacional baseado em Algoritmo Genético (AG) para apoiar o planejamento de estoques, tomando como referência o *Centro Estadual de Medicação de Alto Custo Juarez Barbosa*. Devido à impossibilidade de acesso aos dados reais do centro, todas as execuções foram realizadas com conjuntos de dados simulados, projetados para refletir fielmente as dinâmicas operacionais desses ambientes — tornando o modelo aplicável a qualquer centro com sistema de agendamento e gestão de validade. O problema foi modelado como uma variante do *Lot-Sizing and Scheduling Problem with Shelf-Life Constraints*, onde a cobertura obrigatória da demanda programada é uma restrição crítica, e o objetivo é minimizar as sobras com risco de expiração antes da próxima aquisição. O AG foi integrado a um modelo de simulação Monte Carlo que considera a incerteza na adesão dos pacientes. Os experimentos demonstraram que o modelo converge para 100% de cobertura quando o estoque inicial permite atender toda a demanda, mantendo estabilidade mesmo com variações nos pesos da função-objetivo. Em cenários mais desafiadores, onde o estoque é limitado, a cobertura média variou entre 96,0% e 97,1%, com redução de até 28% nas sobras ao priorizar eficiência. Conclui-se que o sistema proposto é robusto, escalável e adequado como ferramenta preditiva para otimização logística sustentável em centros de medicação de alto custo.

Palavras-chave: algoritmos genéticos. otimização. gestão de estoques. medicamentos de alto custo. produtos perecíveis.

Abstract

High-cost medication centers face a critical logistical dilemma: ensuring full coverage of scheduled patients while minimizing waste due to product expiration. In this context, this work proposes a computational system based on a Genetic Algorithm (GA) to support inventory planning, using the *Juarez Barbosa State Center for High-Cost Medication* as reference. Due to the unavailability of real data from the center, all executions were performed with simulated datasets designed to accurately reflect the operational dynamics of such environments — making the model applicable to any center with scheduling and shelf-life management. The problem was modeled as a variant of the *Lot-Sizing and Scheduling Problem with Shelf-Life Constraints*, where mandatory coverage of scheduled demand is a critical constraint, and the goal is to minimize surplus stock at risk of expiring before the next acquisition. The GA was integrated with a Monte Carlo simulation model accounting for patient adherence uncertainty. Experiments showed that the model converges to 100% coverage when the initial stock allows full demand fulfillment, remaining stable even under changes in the objective function weights. In more challenging scenarios with limited stock, average coverage ranged between 96.0% and 97.1%, with up to 28% reduction in surpluses when efficiency was prioritized. It is concluded that the proposed system is robust, scalable, and suitable as a predictive tool for sustainable logistics optimization in high-cost medication centers.

Keywords: genetic algorithms. optimization. inventory management. high-cost medications. perishable products.

Lista de ilustrações

Figura 1 – Exemplo de População	21
Figura 2 – Fluxograma do AG	22
Figura 3 – Exemplo de roleta	23
Figura 4 – Algoritmo roleta	24
Figura 5 – Algoritmo torneio	24
Figura 6 – Exemplos de cruzamentos 1PX, MPX, UX	25

Lista de tabelas

Tabela 1 – Parâmetros utilizados na geração dos conjuntos de dados simulados	34
Tabela 2 – Parâmetros do Algoritmo Genético nas execuções realizadas . . .	35
Tabela 3 – Resultados médios das execuções do Algoritmo Genético (50 simulações)	36

Lista de abreviaturas e siglas

AG	Algoritmo Genético
AGs	Algoritmos Genéticos
CE	Computação Evolucionária
FEFO	First Expiry, First Out
FIFO	First In, First Out
IPEA	Instituto de Pesquisa Econômica Aplicada
LSS	Lot-Sizing and Scheduling Problem
NP	Não polinomial
OCDE	Cooperação e Desenvolvimento Econômico
OMS	Organização Mundial da Saúde
PRV	Problema de Roteamento de Veículos
UHC	Universal health coverage - Cobertura Universal de Saúde
VRP	Vehicle Routing Problem
WHO	World Health Organization

Lista de símbolos

$\in$	Pertence
$\forall$	Para todo
τ	Letra grega minúscula tau
Σ	Somatório
σ	Letra grega minúscula sigma
$\geq$	Maior Igual que
$\leq$	Menor Igual que
$\gg$	Muito Maior que

Sumário

1	INTRODUÇÃO	13
1.1	Objetivos	14
1.1.1	Objetivo Geral	14
1.1.2	Objetivos Específicos	14
1.2	Estrutura do trabalho	15
2	REFERENCIAL TEÓRICO	16
2.1	Sistemas de suprimento de medicamentos e desafios globais	16
2.2	Dispensação programada em centros de medicamentos de alto custo	16
2.3	Otimização da cobertura com minimização de sobras	17
2.4	O Problema de Dimensionamento e Agendamento de Lotes com Produtos Perecíveis	18
2.4.1	Impacto da perecibilidade no planejamento logístico	18
2.4.2	Políticas de gestão de estoque e controle de validade	19
2.4.3	Integração entre LSS e gestão farmacêutica	19
2.5	Problema de roteamento de veículos	20
2.6	Algoritmos genéticos	20
2.6.1	Características Gerais dos AGs	21
2.6.2	Avaliação	22
2.6.3	Operadores Genéticos	22
2.6.3.1	Seleção	22
2.6.3.2	Roleta	23
2.6.3.3	Torneio	24
2.6.3.4	Cruzamento	25
2.6.3.5	Mutação	25
2.6.4	Atualizando população	26
2.6.4.1	Elitismo	26
2.6.5	Critério de parada	26
2.7	Relação entre PRV, LSS e o uso de Algoritmos Genéticos	26
3	MATERIAIS E MÉTODOS	28
3.1	Formulação Matemática do Problema	28
3.2	Modelagem da Demanda com Incerteza	29
3.3	Modelo de Simulação	30
3.3.1	Política de Consumo de Estoque	30

3.3.2	Projeção da Demanda	30
3.4	Algoritmo Genético Proposto	30
3.4.1	Representação das Soluções	30
3.4.2	Função de Aptidão (<i>Fitness</i>)	31
3.4.3	Operadores Genéticos	31
3.4.3.1	Seleção	31
3.4.3.2	Crossover	31
3.4.3.3	Mutação	31
3.4.4	Parâmetros do Algoritmo	31
3.5	Metodologia de Avaliação	32
3.5.1	Protocolo de Simulação	32
3.5.2	Métricas de Desempenho	32
3.5.3	Comparação com Política de Referência	33
3.6	Implementação Computacional	33
4	RESULTADOS	34
4.1	Configurações dos Conjuntos de Dados	34
4.2	Configurações do Algoritmo Genético	34
4.3	Desempenho do Algoritmo Genético	34
4.3.1	Cobertura de Pacientes	35
4.3.2	Sobras Totais e Risco de Vencimento	35
4.3.3	Comparação entre Execuções	35
4.4	Comportamento do Sistema sob Diferentes Cenários	36
5	DISCUSSÃO	37
5.1	Convergência com a literatura sobre problemas de dimensionamento de lotes	37
5.2	Impacto da estrutura do conjunto de dados	37
5.3	Relação com o Problema de Roteamento de Veículos (PRV)	38
5.4	Implicações para a gestão de medicamentos de alto custo	38
5.5	Limitações do estudo	39
5.6	Contribuições do trabalho	39
5.7	Síntese da discussão	40
6	CONCLUSÃO	41
6.1	Contribuições do trabalho	41
6.2	Limitações e trabalhos futuros	42
6.3	Considerações finais	42

REFERÊNCIAS 44

1 Introdução

Medicamentos são componentes centrais dos sistemas de saúde modernos, representando parcela significativa dos gastos públicos e privados em saúde. Em países membros da Organização para a Cooperação e Desenvolvimento Econômico (OCDE), os gastos com medicamentos correspondem a cerca de 20% do total investido em saúde ([Organisation for Economic Co-operation and Development, 2021](#)). No Brasil, segundo dados do Instituto de Pesquisa Econômica Aplicada (IPEA), os medicamentos respondem por 18,4% das despesas com bens e serviços de saúde e por 29,2% dos gastos diretos das famílias com saúde — um impacto que recai com maior intensidade sobre os grupos socioeconomicamente mais vulneráveis ([SILVA; OLIVEIRA; COSTA, 2019](#)).

Diante desse cenário, o acesso equânime e sustentável a medicamentos essenciais torna-se não apenas uma questão clínica, mas um imperativo ético, econômico e social. A garantia desse acesso está diretamente ligada à eficiência dos sistemas de suprimento farmacêutico, especialmente no caso de medicamentos de alto custo, cuja disponibilidade contínua é fundamental para a continuidade de tratamentos crônicos e de doenças raras.

Nesse contexto, centros especializados — como o *Centro Estadual de Medicação de Alto Custo Juarez Barbosa* — desempenham papel estratégico na cadeia de assistência. Por meio de um modelo baseado em agendamento prévio, esses centros conseguem prever com certa antecedência a demanda por medicamentos, o que permite um planejamento logístico mais preciso. No entanto, persiste um desafio operacional crítico: garantir cobertura total — isto é, assegurar que todos os pacientes agendados recebam seus medicamentos na data prevista — ao mesmo tempo em que se minimiza o desperdício por vencimento. Esse dilema surge porque muitos desses insumos possuem vida útil limitada e valor elevado, fazendo com que sobras não utilizadas representem perda financeira significativa e ineficiência no uso de recursos públicos.

Diante dessa tensão entre cobertura e perecibilidade, surge a seguinte questão norteadora deste trabalho: *como um sistema baseado em algoritmos genéticos pode apoiar a gestão de estoques em centros de dispensação de medicamentos de alto custo, de forma a garantir a cobertura da demanda agendada e reduzir o desperdício de produtos perecíveis?*

Este trabalho aborda esse problema como uma variante do *Lot Sizing Problem with Shelf-Life Constraints*, cujo objetivo é otimizar o planejamento de estoques considerando a perecibilidade dos produtos e a exigência de cobertura obrigatória. Dada a complexidade combinatória do problema — especialmente quando múltiplos medica-

mentos, lotes com diferentes datas de validade e restrições de armazenamento são considerados — métodos exatos mostram-se inviáveis para instâncias de tamanho realista.

Assim, propõe-se neste trabalho o desenvolvimento de um sistema computacional baseado em Algoritmo Genético (AG) para apoiar a tomada de decisão no planejamento de estoques desse centro. O AG será utilizado para buscar soluções que maximizem a cobertura dos agendamentos enquanto minimizem as sobras de medicamentos que vençam antes de serem dispensados.

O presente estudo justifica-se pela sua contribuição prática ao fortalecimento da gestão logística em serviços de saúde e pelo seu valor metodológico, ao aplicar técnicas de inteligência computacional a um problema real e relevante. A analogia com problemas clássicos de otimização, como o Problema de Roteamento de Veículos (PRV) e o Problema de Dimensionamento de Lotes (LSS), ambos amplamente resolvidos com metaheurísticas, reforça a pertinência da abordagem adotada (FILHO, 2016; TOTH; VIGO, 2002).

1.1 Objetivos

Este trabalho objetiva contribuir para a melhoria da gestão em centros de dispensação de medicamentos de alto custo, onde a garantia de cobertura total dos agendamentos e a redução do desperdício por vencimento são desafios operacionais críticos. Ao integrar técnicas de inteligência computacional à previsibilidade da demanda programada, propõe-se um sistema de apoio à decisão capaz de otimizar o planejamento de estoques com base em simulação e busca evolutiva.

1.1.1 Objetivo Geral

O objetivo geral deste trabalho é desenvolver e avaliar um sistema computacional baseado em Algoritmo Genético (AG) para apoiar o planejamento de aquisição de medicamentos em *Centros de Medicação de Alto Custo*, garantindo cobertura total dos agendamentos e minimizando as sobras com risco de vencimento antes da próxima aquisição.

1.1.2 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Modelar o problema de planejamento de estoques como uma variante do *Lot-Sizing and Scheduling Problem* com restrições de perecibilidade e cobertura obrigatória;

- Implementar um Algoritmo Genético com simulação Monte Carlo para considerar a incerteza na adesão dos pacientes aos agendamentos;
- Incorporar a política FEFO (*First Expired, First Out*) na simulação de consumo de estoque, priorizando o uso de medicamentos com validade mais próxima;
- Avaliar o desempenho do modelo em diferentes cenários simulados, variando tamanho do estoque, número de pacientes, estrutura de lotes e horizonte de planejamento;
- Comparar as soluções obtidas pelo AG com uma política de referência baseada na média histórica de consumo, destacando ganhos em cobertura, eficiência e redução de desperdícios.

1.2 Estrutura do trabalho

Este documento está organizado da seguinte forma: o Capítulo 2 apresenta o referencial teórico, com fundamentos sobre cadeias de suprimento de medicamentos, problemas de otimização combinatória e algoritmos genéticos. O Capítulo 3 detalha a metodologia empregada, incluindo modelagem do problema, codificação da solução e definição dos operadores genéticos. O Capítulo 4 traz os experimentos realizados e a análise dos resultados. Por fim, o Capítulo 6 apresenta as conclusões e sugestões para trabalhos futuros.

2 Referencial teórico

2.1 Sistemas de suprimento de medicamentos e desafios globais

A disponibilidade contínua de medicamentos essenciais é um pilar fundamental dos sistemas de saúde e um pré-requisito para a Cobertura Universal de Saúde (UHC). Segundo a Organização Mundial da Saúde (OMS), sistemas eficientes de suprimento de medicamentos estão intrinsecamente ligados à robustez do sistema de saúde como um todo, dependendo de recursos humanos adequados, financiamento sustentável, sistemas de informação abrangentes e coordenação entre instituições ([World Health Organization, 2023](#)). A ausência de estratégias de fornecimento de longo prazo — especialmente em países de baixa e média renda — contribui diretamente para a ocorrência de rupturas de estoque e escassez de medicamentos, comprometendo a continuidade dos tratamentos e os desfechos clínicos dos pacientes.

A OMS reconhece que a garantia de acesso a medicamentos seguros, eficazes e de qualidade não depende apenas da disponibilidade física, mas também da adequação da prescrição, da dispensação correta e da gestão eficiente das cadeias de suprimento. Nesse sentido, a organização tem apoiado países no diagnóstico e fortalecimento de seus sistemas farmacêuticos, com ênfase na redução de falhas logísticas e na melhoria da previsibilidade da demanda ([World Health Organization, 2023](#)).

Apesar dos avanços, dois desafios persistem de forma crítica: (i) a falta de medicamentos essenciais em unidades de saúde, frequentemente associada a falhas na comunicação entre níveis do sistema e à deficiência de sistemas de informação em tempo real; e (ii) o desperdício por vencimento, resultado de supercompras, má rotação de estoques ou planejamento inadequado frente à perecibilidade dos produtos. Esses problemas são particularmente sensíveis no caso de medicamentos de alto custo, cujo valor econômico e impacto terapêutico tornam tanto a ruptura quanto o desperdício inaceitáveis do ponto de vista ético e financeiro.

2.2 Dispensação programada em centros de medicamentos de alto custo

No Brasil, a dispensação de medicamentos de alto custo para doenças crônicas e raras é centralizada em unidades especializadas, como o *Centro Estadual de Medicação de Alto Custo Juarez Barbosa*. Nesse modelo, os pacientes são atendidos mediante agendamento prévio, com base em protocolos clínicos validados e prescrições indivi-

dualizadas. Essa característica introduz um alto grau de previsibilidade na demanda, diferentemente de contextos de atendimento ambulatorial de demanda espontânea.

Embora a demanda seja programada, a gestão de estoques nesses centros permanece desafiadora. Os medicamentos de alto custo frequentemente possuem vida útil limitada, são adquiridos em lotes com datas de vencimento heterogêneas e, em muitos casos, não podem ser fracionados (embalagens unitárias fechadas). Assim, mesmo com demanda conhecida, o planejamento deve considerar cuidadosamente a alocação de lotes específicos a pacientes específicos, de modo a garantir que todos recebam seu medicamento no dia agendado, sem que sobras significativas venham a expirar ao final do ciclo.

Esse cenário configura um problema de alocação com restrições de prazo de validade e cobertura obrigatória, onde o objetivo não é apenas atender a demanda, mas fazê-lo de forma economicamente sustentável, evitando o desperdício de recursos públicos escassos.

2.3 Otimização da cobertura com minimização de sobras

Diante dessas particularidades, o problema abordado neste trabalho pode ser entendido como uma variante do *Lot Sizing Problem with Shelf-Life Constraints* (ZHOU et al., 2022), com a adição de uma restrição crítica: a cobertura total da demanda agendada é obrigatória. Ou seja, qualquer solução viável deve garantir que 100% dos pacientes tenham seu medicamento disponível na data prevista — não há margem para ruptura.

A função-objetivo, por sua vez, busca minimizar as sobras ao final do horizonte de planejamento, entendidas como quantidade de medicamentos não utilizados cujo prazo de validade expira antes de qualquer nova demanda. Essa formulação reflete diretamente a realidade operacional do centro de referência e alinha-se às recomendações da literatura sobre gestão eficiente de produtos perecíveis em saúde (RAHMANIANI et al., 2021).

Dada a natureza combinatória do problema — especialmente quando múltiplos medicamentos, múltiplos lotes e restrições de compatibilidade são considerados —, métodos exatos tornam-se inviáveis para instâncias realistas. Nesse contexto, as *metaheurísticas* emergem como alternativas eficazes. Em particular, os *algoritmos genéticos* têm demonstrado sucesso em problemas semelhantes de logística farmacêutica com perecibilidade, por sua capacidade de explorar grandes espaços de busca e convergir para soluções de alta qualidade em tempo computacional aceitável (CHEN; HSUEH; CHANG, 2010; GOLDBERG, 1989).

Portanto, este trabalho propõe um sistema de apoio à decisão baseado em algoritmos genéticos, voltado ao planejamento de estoques em *Centros de Medicação de Alto*

Custo, com o duplo objetivo de garantir cobertura total dos agendamentos e minimizar o desperdício por vencimento de medicamentos.

2.4 O Problema de Dimensionamento e Agendamento de Lotes com Produtos Perecíveis

O *Lot-Sizing and Scheduling Problem* (LSS) é um problema clássico no planejamento da produção que envolve decisões táticas e operacionais sobre **o tamanho dos lotes e o agendamento das ordens de produção**, com o objetivo de atender à demanda dentro de um horizonte de planejamento predefinido. Tradicionalmente, as funções-objetivo nesse tipo de problema estão voltadas para a minimização de custos — como custos de produção, preparação de máquinas e manutenção de estoque — ou para a maximização do nível de serviço ao cliente, garantindo assim a disponibilidade dos produtos sem excessos inviáveis (FILHO, 2016).

No entanto, quando aplicado a produtos perecíveis, como medicamentos, alimentos ou vacinas, o problema ganha uma nova dimensão: a **perecibilidade**. Essa característica impõe restrições temporais rígidas, pois os produtos perdem valor ou se tornam inutilizáveis após o vencimento do prazo de validade. Assim, o planejamento logístico não pode focar apenas na economia de escala ou na eficiência produtiva, mas também deve considerar o **tempo máximo de armazenamento viável** dos itens.

2.4.1 Impacto da perecibilidade no planejamento logístico

A perecibilidade afeta diretamente o espaço de soluções viáveis no LSS. Quando a vida útil (*shelf-life*) de um produto é menor ou comparável ao horizonte de planejamento, há um risco elevado de **desperdício por vencimento** caso os lotes sejam dimensionados de forma inadequada. Isso é especialmente crítico em cadeias de suprimentos farmacêuticas, onde medicamentos de alto custo podem representar perdas significativas se expirarem antes de serem dispensados (RAHMANIANI et al., 2021).

Nesse contexto, surge um dilema fundamental:

- **Economia de escala:** produzir em lotes maiores reduz custos de preparação e aquisição;
- **Risco de obsolescência:** lotes muito grandes aumentam o tempo médio de permanência em estoque, elevando a probabilidade de vencimento.

Portanto, o dimensionamento de lotes deve equilibrar essas forças opostas, especialmente em ambientes com demanda programada, como em centros de medicação de alto custo, onde a previsibilidade permite estratégias mais precisas de alocação temporal.

2.4.2 Políticas de gestão de estoque e controle de validade

Para mitigar o desperdício, políticas de gestão de inventário adequadas são essenciais. A política *First Expiry, First Out* (FEFO), que prioriza a saída de medicamentos com data de vencimento mais próxima, é amplamente recomendada em sistemas de saúde ([World Health Organization, 2023](#)). Embora o sistema *First In, First Out* (FIFO) ainda seja utilizado, ele pode levar a perdas se novos lotes com datas mais distantes forem armazenados atrás de lotes antigos com validade próxima.

Além disso, práticas de controle de qualidade devem incluir:

- Verificação rigorosa da data de vencimento no recebimento de medicamentos, evitando a aceitação de produtos com vida útil inferior a um limite mínimo (ex: 6 meses);
- Monitoramento contínuo das condições de armazenamento (temperatura, umidade, luz);
- Inventários físicos periódicos com registro de número de lote e datas de validade;
- Rotulagem clara de medicamentos vencidos ou danificados para descarte seguro via logística reversa.

Essas práticas são parte integrante de sistemas robustos de suprimento de medicamentos, conforme destacado pela Organização Mundial da Saúde (OMS), que enfatiza a necessidade de *sistemas de informação abrangentes e coordenação institucional* para garantir a disponibilidade ininterrupta de produtos essenciais ([World Health Organization, 2023](#)).

2.4.3 Integração entre LSS e gestão farmacêutica

Em cenários como o do *Centro Estadual de Medicação de Alto Custo Juarez Barbosa*, onde a demanda é conhecida com antecedência por meio de agendamentos, a integração entre o LSS e a gestão de validade torna-se ainda mais estratégica. Nesse caso, o problema pode ser modelado como uma variante do LSS com restrições de *shelf-life* e exigência de cobertura total, onde:

- As decisões de quantidade a adquirir/estocar devem considerar a data de validade dos lotes disponíveis;
- O cronograma de dispensação define janelas temporais fixas para utilização;
- O objetivo é minimizar sobras que vençam antes do próximo ciclo de demanda.

Estudos como o de [Filho \(2016\)](#) demonstram que modelos matemáticos e heurísticas — incluindo algoritmos genéticos — são eficazes na resolução de variações do LSS com perecibilidade. Esse tipo de abordagem permite simular diferentes cenários de entrada de lotes, combinar múltiplas datas de validade e otimizar a sequência de dispensação, alinhando-se diretamente aos objetivos deste trabalho.

Assim, o uso de técnicas computacionais avançadas para apoiar o planejamento de estoques em centros de alto custo não apenas reduz perdas econômicas, mas também fortalece a sustentabilidade do sistema de saúde e garante a continuidade do tratamento dos pacientes.

2.5 Problema de roteamento de veículos

O *Problema de Roteamento de Veículos* (PRV), ou *Vehicle Routing Problem* (VRP), é um dos problemas clássicos de otimização combinatória com ampla aplicação na logística e cadeia de suprimentos. Ele consiste em determinar um conjunto de rotas ótimas para uma frota de veículos que partem de um ou mais depósitos, de modo a atender uma série de clientes com demandas conhecidas, minimizando custos totais (como distância percorrida, tempo ou número de veículos utilizados) e respeitando restrições operacionais — como capacidade dos veículos, janelas de tempo e disponibilidade de recursos ([TOTH; VIGO, 2002](#)).

Apesar de originalmente formulado para transporte terrestre, variações do PRV têm sido aplicadas a contextos de saúde, incluindo a distribuição de medicamentos entre centros de dispensação, coleta de amostras laboratoriais e entrega domiciliar de insumos. Nesses cenários, a eficiência do roteamento impacta diretamente na pontualidade da entrega, na redução de custos operacionais e, em última instância, na garantia do acesso contínuo aos medicamentos essenciais — um dos pilares da Cobertura Universal de Saúde defendida pela Organização Mundial da Saúde (OMS) ([World Health Organization, 2023](#)).

Uma característica marcante do PRV é sua complexidade computacional: ele pertence à classe de problemas NP-difíceis, o que significa que métodos exatos tornam-se inviáveis mesmo para instâncias de tamanho moderado. Por isso, o desenvolvimento de **metaheurísticas** eficientes tem sido foco central da pesquisa nas últimas décadas.

2.6 Algoritmos genéticos

Os Algoritmos genéticos (AGs) é uma meta-heurística que foi apresentada por ([HOLLAND, 1975](#)), um dos algoritmos evolutivos baseado na teoria da seleção natural de Charles Darwin, na qual possibilitou encontrar solução aproximadas para problemas em que o espaço de busca é muito grande, ou não se conhece o algoritmo exato.

Técnicas utilizam um método heurístico também chamado de meta-heurística resolvem de forma genérica problemas de otimização que tornar as buscas mais fáceis e rápidas pois nas heurísticas se desprezam parte da informação. Meta-heurísticas é qualquer algoritmo de otimização estocástica que são estratégias que empregam aleatoriedade para encontrar possíveis soluções ótimas para problemas difíceis (LUKE, 2013).

Das técnicas correlacionadas da seleção natural surge à Computação Evolucionária (CE), em que os mais aptos em uma população de indivíduos irão passar suas características à uma nova geração. Programação Evolucionária, Estratégias Evolucionárias, Algoritmos Genéticos e Programação Genética estão inclusas em CE (BANZHAF, 1998).

Figura 1 – Exemplo de População

População		População	
Individuo 1	011010110101	Individuo 1	17.1 7.9
Individuo 2	010100110101	Individuo 2	21.3 8.1
.	.	.	.
.	.	.	.
.	.	.	.
Individuo N	001000111011	Individuo N	15.7 6.8
a)		b)	

Fonte: computacaointeligente

Os AGs são amplamente usados podendo ser adaptados à uma grande variedade de problemas. Para moldar a solução dos problemas utilizam de termos e conceitos da teoria do evolucionismo. O indivíduo ou cromossomo é uma representação do espaço de busca do problema a ser resolvido, ou seja, uma solução candidata para o problema. Este indivíduo é composto por um conjunto finito de genes capaz de representar uma resposta para o problema, é comum que eles sejam binários mas podem ser de outros tipos como na Figura 1.


2.6.1 Características Gerais dos AGs

Os algoritmos genéticos são altamente adaptáveis pois para o utilizar não necessário se preocupar em como atingir à solução, apenas com sua representação, faz parte da sua generalidade desprezar o significado da estrutura pois executa uma busca codificada pois não operam sobre o domínio e sim sobre a representação do elemento

(GEYER-SCHULTZ, 1997; SERRADA, 1996), sendo assim necessário que problema possa ser codificado como indivíduos.

Os AGs são iterativos a população inicial geralmente é aleatória (Figura 1). e a cada iteração se cria uma nova geração usando a população como entrada. Para a criação da próxima geração se utiliza recursos de seleção e reprodução (Figura 2). Apesar de não ter um comportamento determinístico não se pode afirmar que são aleatórios sendo que manipula dados obtidos avaliando para selecionar e aprimorar a próxima geração da população. Indivíduos mais aptos terão maior probabilidade de serem escolhidos levando à convergir em uma solução satisfatória.

Figura 2 – Fluxograma do AG



Fonte: computacaointeligente

2.6.2 Avaliação

Antes da seleção é necessário descobrir qual o grau de aptidão do indivíduo ao problema e a função objetivo (*fitness*) é o que executa esta tarefa. A função objetivo é o início da etapa de seleção; cada um dos indivíduos submetidos à avaliação terá um valor quantitativo que poderá ser comparado.

Este é o processo mais dependente do problema pois aqui o algoritmo avalia o quão útil é o indivíduo para o problema que está sendo avaliado, e a avaliação deve ser o mais fidedigno ao problema, para convergência em resultados que possam ser utilizados.

2.6.3 Operadores Genéticos

2.6.3.1 Seleção

Utilizando da avaliação feita anteriormente da população é selecionado aleatoriamente indivíduos de forma que os mais aptos ao problema terão maior probabilidade


de serem escolhidos para o cruzamento. A metodologia da seleção costuma ser estocástica permitindo diversidade da população e previna convergência prematura.

Existe varias maneiras de executar a seleção sendo algumas delas: *ranking*, roleta, torneio.

2.6.3.2 Roleta

Na roleta a aptidão do individuo será proporcional a população logo os mais aptos terá uma proporção maior da roleta enquanto os menos aptos terão uma faixa menor. Sendo assim a probabilidade de escolher os indivíduos de alta aptidão com a roleta é maior mas não impede os outros de serem selecionados. Segundo Mitchell (1997) a implementação para roleta é apresentado na Figura 4.

Figura 3 – Exemplo de roleta



Fonte: Elaborado pelo autor

Figura 4 – Algoritmo roleta

```
Inicio
    T = soma dos valores de aptidão de todos os indivíduos da população
    Repita N vezes para selecionar n indivíduos
        r = valor aleatório entre 0 e T
        Percorra sequencialmente os indivíduos da população, acumulando em S o valor de aptidão dos indivíduos já percorridos
        Se S >= r então
            Selecione o indivíduo corrente
        Fim se
    Fim Repita
Fim
```

Fonte: Elaborado pelo autor

2.6.3.3 Torneio

O torneio escolhe aleatoriamente n indivíduos que disputarão entre si através de uma probabilidade k definida anteriormente. Este método é mais rápido do que a roleta, pois não precisa iterar sobre os indivíduos.

Figura 5 – Algoritmo torneio


```
Inicio
    k = 0.75
    Repita N vezes
        Escolha 2 indivíduos da população aleatoriamente
        r = valor aleatório entre 0 e 1
        Se r < k
            O melhor indivíduo é escolhido
        Senão
            O pior indivíduo é escolhido
        Fim se
    Fim Repita
Fim
```

Fonte: Elaborado pelo autor

2.6.3.4 Cruzamento

Cruzamento ou *crossover* é à combinação dos genes de dois indivíduos a fim de gerar outro indivíduo conhecido como filho que compartilha características dos indivíduos pais(Figura 6). O procedimento pode ser executado de diversas maneiras, sendo comum:

Figura 6 – Exemplos de cruzamentos 1PX, MPX, UX



Fonte: igoryepes

- Um ponto(1PX): nos pais uma posição de um gene é escolhido ao acaso, os valores para estruturas filhas intercala naquele ponto sendo que um dos filhos herda do primeiro pai até aquele ponto e após do segundo pai enquanto o outro começa pelo segundo pai;
- Multipontos(MPX): Executado como no cruzamento de um ponto mas diversos pontos são escolhidos;
- Uniforme(UX): para cada gene é escolhido de qual pai vai ser este gene, os filhos são gerados utilizando esta máscara sendo que um herda a máscara negada.

2.6.3.5 Mutação

A mutação é ato de modificar algum indivíduo da próxima geração dada uma probabilidade, ela mantém a diversidade da população e é capaz de inserir na população alguma característica que não existia nela além de evitar ótimos locais. Algumas das mutações conhecidas são:

- mutação aleatória (*Flip Mutation*): para todo gene a ser modificado, este recebe um valor aleatório do alfabeto;

- b) mutação por troca (*Swap Mutation*): n pares são escolhidos para trocarem de valor entre si;
- c) mutação *creep*: o valor do gene é modificado somando ou subtraindo um valor aleatório.

2.6.4 Atualizando população

A diversas formas de atualizar a população para criar a próxima geração com os descendentes podendo aumentar ou diminuir a população, substituir toda ela por descendentes ou apenas uma parte, uma dessas técnicas frequentemente usada é o elitismo.

2.6.4.1 Elitismo

Para não perder os melhores indivíduos de uma população se emprega o elitismo na geração, conservando estes indivíduos para a próxima geração. Se elitismo estiver grande o algoritmo pode não buscar outras soluções melhores no espaço de busca, prejudicando a busca. Se não houver pode perder uma solução melhor que se encontra numa geração futura durante as sucessivas iterações e cruzamentos.

2.6.5 Critério de parada

O critério de parada do algoritmo não é um operador genético e é um ponto pre-estabelecida em que se deseja atingir. Existe o mais diversos critérios, quantidade de gerações criados, tempo de execução, convergência da população.

2.7 Relação entre PRV, LSS e o uso de Algoritmos Genéticos

Embora o problema abordado neste trabalho não envolva roteamento físico, ele compartilha com o PRV — e também com o *Lot-Sizing Problem* — estruturas fundamentais de problemas combinatórios: múltiplas variáveis de decisão, grande espaço de soluções viáveis e forte dependência de restrições temporais e de recursos limitados.

Trabalhos como o de Filho (2016) destacam essa convergência metodológica, ao aplicar técnicas de otimização avançada para resolver tanto o dimensionamento de lotes quanto variações do PRV. Em sua tese, Belo Filho modela problemas com restrições de capacidade, janelas de tempo e vida útil limitada — elementos diretamente análogos aos encontrados no planejamento de estoques de medicamentos de alto custo. Além disso, o autor discute o uso de métodos heurísticos e metaheurísticos, incluindo algoritmos genéticos, para lidar com a complexidade desses modelos.

Essa literatura fornece respaldo técnico para a escolha do **Algoritmo Genético (AG)** como método de solução neste trabalho. Assim como no PRV e no LSS, o problema de otimização da cobertura com minimização de sobras:

1. Possui um espaço de busca extremamente grande (combinações de lotes, datas de validade e pacientes);
2. Envolve equilíbrio claros (cobertura total vs. desperdício);
3. Requer flexibilidade para incorporar restrições específicas (FEFO, agendamentos fixos, unidades indivisíveis).

Os AGs são particularmente adequados nesse cenário por sua capacidade de:

1. Trabalhar com codificações naturais (por exemplo, sequências de alocação de lotes a pacientes);
2. Evoluir soluções viáveis mesmo em espaços irregulares;
3. Escalar bem com o aumento do número de medicamentos e pacientes.

Portanto, a experiência consolidada no uso de metaheurísticas para problemas como o PRV e o LSS — especialmente em contextos com perecibilidade e planejamento logístico crítico — justifica plenamente a aplicação de um Algoritmo Genético ao problema de gestão de estoques em *Centros de Medicação de Alto Custo*. A analogia com esses problemas reconhecidos na literatura reforça não apenas a viabilidade, mas também a pertinência da abordagem proposta.

3 Materiais e Métodos

Este trabalho aborda o problema de otimização da aquisição de medicamentos em sistemas de saúde pública, com foco em **maximizar a cobertura de dispensação** enquanto **minimiza o desperdício por vencimento**. A formulação matemática do problema é apresentada a seguir.

3.1 Formulação Matemática do Problema

Seja $M = \{1, 2, \dots, m\}$ o conjunto de medicamentos a serem adquiridos, onde m representa o número total de medicamentos.

O problema consiste em determinar a quantidade ótima q_i a ser adquirida para cada medicamento $i \in M$, tal que:

$$\text{maximize } f(q_1, q_2, \dots, q_m) = w_1 \cdot C(q) - w_2 \cdot S(q) - w_3 \cdot R(q) \quad (3.1)$$

sujeito a:

$$q_i \geq 0, \quad \forall i \in M \quad (3.2)$$

Onde:

- $q = [q_1, q_2, \dots, q_m]$ é o vetor de decisão representando as quantidades a serem adquiridas;
- $C(q)$ é a cobertura de pacientes obtida com o plano de aquisição q ;
- $S(q)$ é a quantidade total de sobras após o período de simulação;
- $R(q)$ é o risco de desperdício (quantidade de medicamentos que vencerão antes da próxima aquisição);
- w_1, w_2, w_3 são pesos que refletem a importância relativa de cada componente ($w_1 \gg w_2, w_3$).

A cobertura $C(q)$ é definida como:

$$C(q) = \frac{\sum_{t=1}^T \sum_{i=1}^m D_i(t) \cdot I\{E_i(t, q) \geq D_i(t)\}}{\sum_{t=1}^T \sum_{i=1}^m D_i(t)} \quad (3.3)$$

Onde:

- T é o horizonte de simulação (em dias);
- $D_i(t)$ é a demanda do medicamento i no dia t ;

- $E_i(t, q)$ é o estoque efetivo do medicamento i no dia t considerando o plano q ;
- $I\{\cdot\}$ é a função indicadora.

A sobra $S(q)$ é calculada como:

$$S(q) = \sum_{i=1}^m \left(E_i(T, q) - \sum_{t=1}^T D_i(t) \cdot I\{E_i(t, q) \geq D_i(t)\} \right) \quad (3.4)$$

O risco de desperdício $R(q)$ é definido como:

$$R(q) = \sum_{i=1}^m \sum_{l \in L_i} (Q_{i,l} \cdot I\{V_{i,l} \leq T_a\}) \quad (3.5)$$

Onde:

- L_i é o conjunto de lotes do medicamento i ;
- $Q_{i,l}$ é a quantidade remanescente do lote l do medicamento i ;
- $V_{i,l}$ é o tempo até o vencimento do lote l ;
- T_a é o tempo até a próxima aquisição.

3.2 Modelagem da Demanda com Incerteza

A demanda futura é modelada considerando a **adesão probabilística** dos pacientes. Para cada paciente j e medicamento i , temos:

$$D_{i,j}(t) = \begin{cases} Q_{i,j} & \text{com probabilidade } a_j \\ 0 & \text{com probabilidade } 1 - a_j \end{cases} \quad (3.6)$$

Onde:

- $a_j \in [0, 1]$ é a taxa de adesão do paciente j ;
- $Q_{i,j}$ é a quantidade que o paciente j necessita do medicamento i ;
- t representa os dias em que o paciente estaria programado para retirada.

A demanda total para o medicamento i no dia t é então:

$$D_i(t) = \sum_{j \in P} D_{i,j}(t) \quad (3.7)$$

Onde P é o conjunto de pacientes que utilizam o medicamento i .

3.3 Modelo de Simulação

Para avaliar uma solução q , foi implementado um modelo de simulação discreto que projeta o consumo de medicamentos ao longo do horizonte de planejamento T .

3.3.1 Política de Consumo de Estoque

Foi implementado uma política **FEFO (First Expired, First Out)** para consumo dos medicamentos:

$$\text{ordem de consumo} = \underset{l \in L_i}{\operatorname{argmin}} \{V_{i,l}\} \quad (3.8)$$

Ou seja, foi priorizado o consumo dos lotes com menor tempo restante até o vencimento.

3.3.2 Projeção da Demanda

A demanda é projetada considerando:

1. A programação inicial de retiradas (t_0);
2. A frequência de retirada (f);
3. A taxa de adesão (a_j).

Para cada paciente j , as datas de retirada programadas são:

$$t_k = t_0 + k \cdot f, \quad k = 0, 1, 2, \dots \quad (3.9)$$

Para cada data programada $t_k \leq T$, o paciente comparece com probabilidade a_j .

3.4 Algoritmo Genético Proposto

3.4.1 Representação das Soluções

Cada solução (cromossomo) é representada como um vetor de inteiros:

$$x = [x_1, x_2, \dots, x_m] \quad (3.10)$$

Onde x_i representa a quantidade do medicamento i a ser adquirida.

3.4.2 Função de Aptidão (*Fitness*)

A função de aptidão incorpora a natureza estocástica do problema através de múltiplas simulações:

$$\text{fitness}(x) = \frac{1}{N} \sum_{s=1}^N (w_1 \cdot C_s(x) - w_2 \cdot S_s(x) - w_3 \cdot R_s(x)) \quad (3.11)$$

Onde N é o número de simulações Monte Carlo realizadas para cada solução ($N = 20$ nas implementações).

3.4.3 Operadores Genéticos

3.4.3.1 Seleção

Foi utilizado seleção por torneio com tamanho de torneio $\tau = 3$:

$$P(\text{selecionar } x_i) = \frac{1}{\tau} \sum_{j=1}^{\tau} I\{f(x_i) \geq f(x_j)\} \quad (3.12)$$

3.4.3.2 Crossover

Operador de *crossover* de dois pontos com probabilidade $p_c = 0.7$:

$$\text{Se } u < p_c : \quad x_{\text{novo}}^1[k] = \begin{cases} x^1[k] & \text{se } k < p_1 \text{ ou } k > p_2 \\ x^2[k] & \text{caso contrário} \end{cases} \quad (3.13)$$

$$x_{\text{novo}}^2[k] = \begin{cases} x^2[k] & \text{se } k < p_1 \text{ ou } k > p_2 \\ x^1[k] & \text{caso contrário} \end{cases} \quad (3.14)$$

Onde p_1 e p_2 são pontos de corte aleatórios.

3.4.3.3 Mutação

Mutação uniforme com probabilidade $p_m = 0.2$ por gene:

$$\text{Se } u < p_m : \quad x_{\text{novo}}[k] = \text{randint}(0, Q_{\max}) \quad (3.15)$$

Onde $Q_{\max} = 1000$ é o limite superior para quantidade a ser adquirida.

3.4.4 Parâmetros do Algoritmo

Os parâmetros utilizados foram:

- Tamanho da população: $|P| = 100$;

- Número de gerações: $G = 50$;
- Probabilidade de *crossover*: $p_c = 0.7$;
- Probabilidade de mutação: $p_m = 0.2$;
- Tamanho do torneio: $\tau = 3$;
- Número de simulações Monte Carlo: $N = 20$;
- Pesos na função objetivo: $w_1 = 10.0$, $w_2 = 1.0$, $w_3 = 2.0$;
- Horizonte de simulação: $T = 60$ dias;
- Próxima data de aquisição: $T_a = 30$ dias.

3.5 Metodologia de Avaliação

3.5.1 Protocolo de Simulação

Para cada solução avaliada, realizamos $N = 20$ simulações independentes do processo estocástico de demanda. Os resultados finais são reportados como médias dessas simulações, com desvio padrão para indicar a variabilidade.

3.5.2 Métricas de Desempenho

As seguintes métricas foram utilizadas para avaliação das soluções:

1. **Cobertura média** ($\bar{C}$):

$$\bar{C} = \frac{1}{N} \sum_{s=1}^N C_s(x) \quad (3.16)$$

2. **Desvio padrão da cobertura** (σ_C):

$$\sigma_C = \sqrt{\frac{1}{N-1} \sum_{s=1}^N (C_s(x) - \bar{C})^2} \quad (3.17)$$

3. **Sobra média** ($\bar{S}$):

$$\bar{S} = \frac{1}{N} \sum_{s=1}^N S_s(x) \quad (3.18)$$

4. **Risco médio de desperdício** ($\bar{R}$):

$$\bar{R} = \frac{1}{N} \sum_{s=1}^N R_s(x) \quad (3.19)$$

3.5.3 Comparação com Política de Referência

Para validação dos resultados, a solução obtida pelo AG foi comparada com uma política de referência baseada na média histórica de consumo.

$$q_i^{\text{ref}} = \left[\frac{1}{K} \sum_{k=1}^K D_i^{\text{hist}}(k) \right] \cdot T \quad (3.20)$$

Onde K é o número de períodos históricos considerados e $D_i^{\text{hist}}(k)$ é a demanda histórica do medicamento i no período k .

3.6 Implementação Computacional

O algoritmo foi implementado em Python 3.10, utilizando as seguintes bibliotecas:

- DEAP (Distributed Evolutionary Algorithms in Python) para a estrutura do AG;
- NumPy para operações numéricas;
- JSON para manipulação de dados.

4 Resultados

Este capítulo apresenta os resultados obtidos com a execução do Algoritmo Genético (AG) para otimização da aquisição de medicamentos em diferentes cenários simulados. Os experimentos foram realizados com variações nos parâmetros do conjunto de dados e do algoritmo, visando avaliar o comportamento do modelo sob diferentes condições de estoque, demanda, adesão e políticas de aquisição.

4.1 Configurações dos Conjuntos de Dados

Foram gerados 4 conjuntos de dados simulados, denominados V2 a V5, com características progressivamente ajustadas para aumentar a complexidade e induzir situações críticas, como risco de vencimento e falha na cobertura. As configurações principais são apresentadas na Tabela 1.

Tabela 1 – Parâmetros utilizados na geração dos conjuntos de dados simulados

Conjunto	Medicamentos	Pacientes	Adesão	Max Venc.	Lotes/Med	Estoque/Lote
V2	50	500	[0.85, 1.0]	365 dias	1–3	2–1000
V3	50	500	[0.85, 1.0]	120 dias	1–3	2–1000
V4	50	700	[0.85, 1.0]	120 dias	2–5	2–200
V5	50	700	[0.95, 1.0]	120 dias	1–5	2–100

Fonte: Elaborado pelo autor

Os conjuntos V2 e V3 foram projetados para avaliar o impacto do tempo máximo de validade sobre o risco de vencimento. O conjunto V4 introduziu maior fragmentação de estoque por lote, enquanto o V5 aumentou a frequência de dispensação e reduziu o estoque médio por lote, buscando criar cenários com possível insuficiência de cobertura.

4.2 Configurações do Algoritmo Genético

O AG foi executado com diferentes configurações de população, pesos na função objetivo e horizonte de simulação. A Tabela 2 resume as principais variações testadas.

4.3 Desempenho do Algoritmo Genético

Os resultados foram obtidos com base em 50 simulações Monte Carlo para cada execução, garantindo robustez estatística na avaliação das soluções. Os valores reportados correspondem às médias dessas simulações.

Tabela 2 – Parâmetros do Algoritmo Genético nas execuções realizadas

Execução	Dataset	Pop.	Período	T_a	w_1	w_2	w_3
1	V2	100	60	30	10.0	-1.0	-2.0
2	V2	50	60	30	10.0	-1.0	-2.0
3	V3	50	60	30	4.0	-1.0	-4.0
4	V3	50	60	25	10.0	-1.0	-2.0
5	V3	50	90	45	10.0	-1.0	-2.0
6	V3	50	90	45	2.0	-1.0	-10.0
7	V3	50	90	45	0.1	-5.0	-2.0
8	V4	50	90	45	0.1	-5.0	-2.0
9	V4	50	90	45	0.1	-1.0	-10.0
10	V5	50	90	45	0.1	-1.0	-10.0
11	V5	50	90	45	5.0	-5.0	-1.0
12	V5	50	90	45	10.0	-3.0	-0.1

Fonte: Elaborado pelo autor

4.3.1 Cobertura de Pacientes

Em todos os experimentos com os conjuntos V2 a V4, o AG alcançou consistentemente 100,0% de cobertura média, independentemente da configuração de pesos ou tamanho da população. O desvio padrão foi nulo em todas as execuções, indicando estabilidade completa entre as simulações.

No conjunto V5, onde o estoque inicial é mais limitado e a demanda mais intensa, a cobertura média variou entre **96,0% e 97,1%**, com desvio padrão de $\pm 0,1\%$. Essa redução indica que o sistema atingiu um limite físico de disponibilidade, mesmo com a priorização máxima de cobertura.

4.3.2 Sobras Totais e Risco de Vencimento

A quantidade de sobras totais variou conforme o conjunto de dados, refletindo a escala de demanda e estoque. No conjunto V2, as sobras médias ficaram entre **52.229 e 52.631 unidades**. Nas execuções com V3, esse valor oscilou entre **49.366 e 52.899 unidades**.

O risco de vencimento foi significativo apenas quando o horizonte de simulação e a data de próxima aquisição permitiam essa condição. No conjunto V3, com período de 90 dias e aquisição em 45 dias, o número médio de unidades em risco de vencimento foi de **4.080 a 4.090 unidades**, contra **6.713 unidades** em risco mesmo sem nova aquisição (estoque remanescente não retirado).

Já no conjunto V5, o risco de vencimento foi sempre **nulo**, indicando que a rotatividade do estoque é suficiente para evitar perdas por validade.

4.3.3 Comparação entre Execuções

A Tabela 3 apresenta um resumo dos resultados médios por execução.

Observou-se que:

Tabela 3 – Resultados médios das execuções do Algoritmo Genético (50 simulações)

Exec.	Dataset	Cobertura (%)	Sobras (unid.)	Risco Venc. (unid.)	Risco Sem Retirada
1	V2	100,0	52.631	0	2910
2	V2	100,0	52.229	0	2910
3	V3	100,0	50.579	242	393
4	V3	100,0	52.899	244	393
5	V3	100,0	49.366	4.088	6.713
6	V3	100,0	49.556	4.080	6.713
7	V3	100,0	50.845	4.090	6.713
8	V4	100,0	20.409	1.323	5.378
9	V4	100,0	21.150	1.322	5.378
10	V5	97,1	10.292	0	2.427
11	V5	96,9	7.939	0	2.427
12	V5	96,5	7.313	0	2.427

Fonte: Elaborado pelo autor

- Alterações no tamanho da população (50 vs 100) não impactaram significativamente os resultados.
- Mudanças nos pesos da função objetivo tiveram pouco efeito quando o estoque inicial já garantia cobertura total.
- Em V3, a antecipação da data de aquisição de 45 para 25 dias eliminou completamente o risco de vencimento.
- No conjunto V5, com restrições mais apertadas, o AG conseguiu reduzir as sobras em até 28% ao priorizar esse objetivo, com pequena queda na cobertura.

4.4 Comportamento do Sistema sob Diferentes Cenários

Os experimentos revelaram que o desempenho do modelo é altamente dependente das características do conjunto de dados. Quando o estoque atual e a programação de dispensação permitem cobertura plena, o AG mantém sistematicamente 100% de cobertura, independentemente dos pesos atribuídos aos demais objetivos.

Em contrapartida, em cenários com restrições operacionais mais severas (V5), o algoritmo demonstrou capacidade de ajuste fino entre cobertura, sobras e risco, permitindo decisões balanceadas conforme a política de prioridades definida.

Todos os resultados foram obtidos com convergência estável do AG, geralmente antes da geração 40, indicando boa eficiência computacional para o problema abordado.

5 Discussão

Os resultados obtidos neste estudo demonstram que o Algoritmo Genético (AG) proposto é capaz de encontrar soluções eficazes para o problema de planejamento de estoques em centros de medicamentos de alto custo, especialmente quando o sistema já possui condições mínimas de cobertura garantida. Esta discussão analisa os achados à luz do referencial teórico apresentado, destacando convergências com a literatura, implicações práticas e limitações do modelo.

5.1 Convergência com a literatura sobre problemas de dimensionamento de lotes

O problema abordado neste trabalho pode ser classificado como uma variante do *Lot-Sizing and Scheduling Problem with Shelf-Life Constraints* [Zhou et al. \(2022\)](#), diferindo principalmente pela exigência de cobertura total da demanda agendada. Esse requisito transforma a função-objetivo em um problema de *otimização com restrição de serviço obrigatório*, onde o nível de atendimento não é um objetivo, mas uma condição de viabilidade da solução.

Essa característica foi decisiva nos experimentos: em todos os cenários onde o estoque inicial permitia atender integralmente a demanda programada (V2 a V4), o AG convergiu consistentemente para 100% de cobertura, independentemente dos pesos atribuídos aos demais objetivos. Esse comportamento está alinhado com a literatura sobre metaheurísticas aplicadas a problemas com restrições rígidas, que mostra que operadores evolutivos tendem a priorizar a viabilidade antes da otimalidade ([FILHO, 2016](#)).

A capacidade do AG de manter cobertura plena mesmo ao reduzir drasticamente o peso w_1 (como na execução 7, com $w_1 = 0.1$) reforça a robustez do modelo em ambientes previsíveis, como centros com dispensação programada. Isso contrasta com estudos em contextos de demanda estocástica ([RAHMANIANI et al., 2021](#)), onde a cobertura geralmente é tratada como um objetivo probabilístico. No caso estudado, a previsibilidade da demanda permite um controle mais preciso do inventário, tornando o AG particularmente adequado.

5.2 Impacto da estrutura do conjunto de dados

Um dos achados mais relevantes deste estudo é a alta sensibilidade do desempenho do AG às características do conjunto de dados. Quando o estoque atual e a política de

rotação (FEFO) são suficientes para atender toda a demanda no horizonte de simulação, o algoritmo se concentra quase exclusivamente na minimização de sobras e risco de vencimento — mesmo sem ênfase explícita nesses objetivos.

Esse fenômeno explica por que alterações nos pesos da função objetivo (w_2 , w_3) tiveram pouco impacto nas execuções com V2 a V4. Em contrapartida, no conjunto V5, onde o estoque é mais fragmentado e a rotatividade é maior, o AG demonstrou flexibilidade para ajustar o dilema entre cobertura e desperdício, reduzindo as sobras em até 28% ao priorizar esse objetivo, com perda marginal na cobertura (96,0% a 97,1%).

Esse resultado está em sintonia com a análise de [Chen, Hsueh e Chang \(2010\)](#), que destaca a importância da qualidade dos dados de entrada na eficácia de sistemas baseados em AGs. O presente estudo confirma que modelos preditivos em logística farmacêutica não operam no vácuo: sua eficiência depende diretamente da maturidade do sistema de informação e da disciplina na gestão de validade.

5.3 Relação com o Problema de Roteamento de Veículos (PRV)

Apesar de não envolver movimentação física, o problema abordado compartilha estruturas combinatórias fundamentais com o *Vehicle Routing Problem* (VRP), especialmente em formulações com janelas de tempo e restrições de capacidade ([TOTH; VIGO, 2002](#)). Neste caso, os “veículos” são os lotes de medicamentos, cada um com uma “janela de tempo” definida pela data de vencimento, e a “rota” é a sequência de dispensações que ele deve atender.

A política FEFO implementada equivale a uma heurística de despacho prioritário, análoga à regra de atendimento em ordem de chegada em sistemas de filas. A diferença crucial é que, enquanto no PRV o foco é a eficiência temporal, aqui o foco é a sustentabilidade econômica — evitar que “cargas” (lotes) expirem antes de serem utilizadas.

A analogia reforça a pertinência do uso de metaheurísticas, como os AGs, para resolver problemas com múltiplas dimensões temporais e restrições rígidas. Assim como no PRV, onde pequenas variações no cronograma podem gerar grandes mudanças na frota necessária, neste trabalho, pequenas antecipações na data de aquisição (ex: de 45 para 25 dias) eliminaram completamente o risco de vencimento, evidenciando o alto ganho com decisões proativas.

5.4 Implicações para a gestão de medicamentos de alto custo

Do ponto de vista operacional, os resultados indicam que o sistema proposto pode atuar como um **sistema de apoio à decisão preditivo**, ajudando gestores a:

- Planejar compras com base em demanda real projetada, não apenas em médias históricas;
- Evitar aquisições desnecessárias que levariam a desperdício por vencimento;
- Identificar antecipadamente medicamentos com alto risco de obsolescência.

Além disso, o modelo incorpora explicitamente a incerteza na adesão dos pacientes, um fator frequentemente negligenciado em sistemas de gestão de estoques, mas reconhecido como crítico pela OMS ([World Health Organization, 2023](#)). Ao simular múltiplos cenários com base na probabilidade de comparecimento, o AG produz planos mais robustos, preparados para flutuações naturais na demanda.

A eliminação do risco de vencimento em V5, apesar da alta frequência de dispensação, sugere que centros com boa rotatividade de estoque podem operar com segurança mesmo com políticas menos conservadoras de reposição — desde que apoiadas por modelagem preditiva.

5.5 Limitações do estudo

Este trabalho possui algumas limitações que devem ser consideradas:

- Os dados utilizados são simulados, o que pode não capturar toda a complexidade de falhas logísticas reais (ex: atrasos na entrega, erros de digitação, ruptura inesperada).
- A adesão dos pacientes foi modelada como estacionária, enquanto na prática pode variar sazonalmente ou por eventos externos.
- O modelo não considera custos de aquisição nem restrições orçamentárias, hipótese válida para centros com financiamento garantido, mas limitante para generalização.
- A função de fitness utiliza pesos fixos, o que pode não refletir adequadamente as prioridades dinâmicas de um centro de saúde.

Essas simplificações foram intencionais, visando isolar o efeito da perecibilidade e da cobertura obrigatória. No entanto, trabalhos futuros devem incorporar essas variáveis para aumentar a fidelidade do modelo.

5.6 Contribuições do trabalho

Este estudo contribui para a literatura e para a prática em três frentes:

1. **Metodológica:** Propõe uma adaptação do AG para um problema de cobertura obrigatória com perecibilidade, demonstrando sua eficácia em cenários realistas.
2. **Prática:** Oferece um sistema aplicável a centros de medicação de alto custo, com potencial de reduzir desperdícios financeiros significativos.
3. **Conceitual:** Reforça a importância da integração entre previsão de demanda, gestão de validade e tomada de decisão apoiada por inteligência computacional em saúde.

A abordagem está alinhada com recomendações internacionais da OMS para fortalecimento de sistemas de suprimento de medicamentos ([World Health Organization, 2023](#)) e com tendências globais de digitalização da gestão em saúde.

5.7 Síntese da discussão

Em síntese, o AG mostrou-se uma ferramenta poderosa para otimização de estoques em ambientes com demanda programada. Sua principal força reside na capacidade de explorar o espaço de soluções e encontrar combinações não óbvias de aquisição que equilibram cobertura e eficiência. A dependência em relação à qualidade dos dados de entrada, embora seja uma limitação, também é um incentivo para melhorar os sistemas de informação locais — um benefício indireto, mas valioso.

No próximo capítulo, serão apresentadas as conclusões finais do trabalho, bem como sugestões para pesquisas futuras e possíveis extensões do modelo proposto.

6 Conclusão

Este trabalho teve como objetivo desenvolver e avaliar um sistema computacional baseado em Algoritmo Genético (AG) para apoiar o planejamento de estoques em *Centros de Medicação de Alto Custo*, com foco na garantia de cobertura total dos agendamentos e na minimização do desperdício por vencimento de medicamentos. A partir da modelagem do problema como uma variante do *Lot-Sizing and Scheduling Problem with Shelf-Life Constraints*, foi proposto um modelo evolutivo capaz de simular múltiplos cenários de demanda, considerando incertezas na adesão dos pacientes e restrições temporais impostas pela validade dos produtos.

Os experimentos realizados demonstraram que o AG é altamente eficaz em ambientes onde o estoque atual e a política de rotação (FEFO) permitem atender integralmente a demanda programada. Em todos os cenários com cobertura viável (v2 a v4), o algoritmo convergiu consistentemente para soluções com **100% de cobertura**, independentemente das variações nos pesos da função-objetivo ou no tamanho da população. Esse comportamento evidencia a robustez do modelo em priorizar a viabilidade logística antes da otimização secundária, refletindo a natureza crítica do serviço prestado por centros de medicação de alto custo.

Em situações mais desafiadoras, como no conjunto v5, onde o estoque é mais fragmentado e a rotatividade é elevada, o AG mostrou flexibilidade para ajustar o dilema entre cobertura e eficiência. Mesmo com redução nos pesos de cobertura, o modelo manteve níveis acima de **96% de cobertura**, enquanto conseguiu reduzir as sobras em até 28% ao priorizar esse objetivo. Isso demonstra que o sistema pode ser adaptado a diferentes políticas de gestão, oferecendo suporte à decisão conforme as prioridades institucionais.

A sensibilidade do modelo às características do conjunto de dados também se destacou como um achado relevante. Quando o sistema já opera com boas práticas de gestão de validade e previsibilidade de demanda, o AG tende a estabilizar em soluções ótimas com baixo risco de perda. Isso indica que sua aplicação contínua pode funcionar como um mecanismo de retroalimentação positiva, incentivando a melhoria dos sistemas de informação e a disciplina operacional nos centros de dispensação.

6.1 Contribuições do trabalho

Este estudo contribui de forma significativa para a área de gestão logística em saúde, especialmente no contexto de medicamentos de alto custo e vida útil limitada. Suas principais contribuições são:

1. **Metodológica:** Apresenta uma adaptação inovadora do Algoritmo Genético para problemas de cobertura obrigatória com perecibilidade, incorporando simulação estocástica de adesão e política FEFO.
2. **Prática:** Oferece uma ferramenta aplicável a centros de dispensação programada, com potencial real de reduzir desperdícios financeiros e fortalecer a continuidade dos tratamentos.
3. **Conceitual:** Reforça a importância da integração entre previsão de demanda, gestão de validade e tomada de decisão apoiada por inteligência computacional — um passo essencial rumo à digitalização da cadeia de suprimentos farmacêuticos.

Além disso, o trabalho está alinhado com recomendações internacionais da Organização Mundial da Saúde (OMS) para fortalecimento de sistemas de suprimento de medicamentos ([World Health Organization, 2023](#)), ao promover eficiência, sustentabilidade e equidade no acesso a insumos críticos.

6.2 Limitações e trabalhos futuros

Apesar dos resultados promissores, este estudo possui limitações. Os dados utilizados são simulados, o que pode não capturar toda a complexidade de falhas logísticas reais. Além disso, o modelo não considera custos de aquisição nem restrições orçamentárias, hipóteses válidas para centros com financiamento garantido, mas limitantes para generalização.

Como trabalhos futuros, sugere-se:

- Incorporar restrições orçamentárias e custos unitários na função-objetivo;
- Integrar o modelo a um sistema de informação em tempo real, com alimentação direta dos agendamentos e estoques;
- Expandir o horizonte de simulação com previsão de demanda baseada em séries temporais ou aprendizado de máquina;
- Testar o modelo com dados reais do centro de referência, em colaboração com a gestão local.

6.3 Considerações finais

Em síntese, este trabalho demonstrou que o uso de algoritmos genéticos pode transformar o planejamento de estoques de medicamentos de alto custo em um processo mais preciso, eficiente e sustentável. Ao combinar previsibilidade da demanda com

inteligência computacional, o modelo proposto vai além da simples otimização: atua como um **sistema de apoio à decisão preditivo**, capaz de antecipar riscos e propor ações proativas.

A abordagem desenvolvida neste TCC não apenas responde aos objetivos propostos, mas abre caminho para a modernização da gestão logística em saúde pública, reforçando o papel da Ciência da Computação como aliada estratégica na construção de sistemas de saúde mais resilientes, justos e humanizados.

Referências

- CHEN, H. K.; HSUEH, C. F.; CHANG, M. S. A genetic algorithm for the vehicle routing problem with time windows and stochastic demands in pharmaceutical distribution. *Expert Systems with Applications*, v. 37, n. 12, p. 7813–7821, 2010. Citado 2 vezes nas páginas 17 e 38.
- FILHO, M. A. F. B. *Dimensionamento e Sequenciamento de Lotes com Restrições de Capacidade, Janelas de Tempo e Vida Útil Limitada*. Tese (Doutorado) — Universidade de São Paulo, 2016. Disponível em: <<https://www.teses.usp.br/teses/disponiveis/55/55134/tde-29042016-142624/publico/MarcioAntonioFerreiraBeloFilho.pdf>>. Acesso em: 20 nov. 2025. Citado 5 vezes nas páginas 14, 18, 20, 26 e 37.
- GEYER-SCHULTZ, A. *Fuzzy Rule-Based Expert Systems and Genetic Machine Learning*. [S.l.: s.n.], 1997. Citado na página 22.
- GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization, and Machine Learning*. [S.l.]: Addison-Wesley, 1989. Citado na página 17.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control and Artificial Intelligence*. Ann Arbor, MI: University of Michigan Press, 1975. Citado na página 20.
- LUKE, S. *Essentials of Metaheuristics*. second. Lulu, 2013. Disponível em: <<https://cs.gmu.edu/~sean/book/metaheuristics/>>. Citado na página 21.
- Organisation for Economic Co-operation and Development. *Health at a Glance 2021: OECD Indicators*. [S.l.]: OECD Publishing, 2021. Citado na página 13.
- RAHMANIANI, R. et al. A robust optimization approach for drug supply chain network design under demand uncertainty. *Computers & Chemical Engineering*, v. 145, p. 107187, 2021. Citado 3 vezes nas páginas 17, 18 e 37.
- SERRADA, A. P. *Una introducción a la Computación Evolutiva*. 1996. Citado na página 22.
- SILVA, R. M.; OLIVEIRA, M. A.; COSTA, J. F. *Gastos com medicamentos no Brasil: acesso, financiamento e impacto sobre as famílias*. [S.l.], 2019. Disponível em: <<https://repositorio.ipea.gov.br/handle/11058/9423>>. Acesso em: 21 nov. 2025. Citado na página 13.
- TOTH, P.; VIGO, D. *The Vehicle Routing Problem*. [S.l.]: SIAM, 2002. (SIAM Monographs on Discrete Mathematics and Applications). Citado 3 vezes nas páginas 14, 20 e 38.
- World Health Organization. *Medicines Supply*. 2023. Disponível em: <<https://www.who.int/teams/health-product-policy-and-standards/medicines-selection-ip-and-affordability/medicines-policy/medicines-supply>>. Acesso em: 20 nov. 2025. Citado 6 vezes nas páginas 16, 19, 20, 39, 40 e 42.

ZHOU, Y. et al. A hybrid genetic algorithm for inventory routing problem with perishable products. *Applied Soft Computing*, v. 115, p. 108152, 2022. Citado 2 vezes nas páginas 17 e 37.



**PUC
GOIÁS**

Pontifícia Universidade Católica de Goiás
Pontifical Catholic University of Goiás
Av. Universitária, 1069, Setor Universitário
Caixa Postal 86 - CEP 74.605-010
Goiânia - Goiás - Brasil

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O estudante _____ Igor da Silva Paixão _____ do Curso de
_____ Ciência _____ da _____ Computação _____ matrícula
_____ 20131002804927 _____, telefone: _____ 62 993902146 _____ e-mail
_____ igordasilvapaixao@hotmail.com _____, na qualidade de titular
dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor),
autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho
de Conclusão de Curso intitulado _____ Otimização da cobertura de dispensação de
medicamentos com minimização de sobras: um sistema baseado em algoritmos genéticos
_____, gratuitamente, sem
ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento,
em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF);
Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT);
outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de
divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 30 _____ de _____ setembro _____ de 2025 _____.

Assinatura do autor: _____ Igor da Silva Paixão _____

Nome completo do autor: _____ Igor da Silva Paixão _____

Assinatura do professor-orientador: _____ Sibélius Lellis Vieira _____
Nome completo do professor-orientador: Sibélius Lellis Vieira