



René González Hernández

**Otimização de Recursos para Procedimentos
Cirúrgicos Eletivos Utilizando Algoritmos
Genéticos com Inspiração Quântica**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica da PUC-Rio.

Orientadora: Profa. Marley Vellasco

Co-Orientadora: Profa. Karla Figueiredo

Rio de Janeiro

Abril 2018



René González Hernández

**Otimização de Recursos para Procedimentos Cirúrgicos
Eletivos Utilizando Algoritmos Genéticos com Inspiração
Quântica**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof.^a Marley Maria Bernardes Rebuszi Vellasco
Orientadora
Departamento de Engenharia Elétrica – PUC-Rio

Prof.^a Karla Tereza Figueiredo Leite
Co-Orientadora
UERJ

Prof. Luciano Reis da Silveira
LPO

Prof. Fabiano Saldanha Gomes de Oliveira
UERJ

Prof. Márcio da Silveira Carvalho
Coordenador Setorial do Centro
Técnico Científico – PUC-Rio

Rio de Janeiro, 10 de abril de 2018

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, da autora e do orientador.

René González Hernández

Graduou-se em Engenharia em Telecomunicações e Eletrônica pelo ISPAJE (Instituto Superior Politécnico José Antonio Echeverría) Cuba em 2012.

Ficha Catalográfica

González Hernández, René

Otimização de recursos para procedimentos cirúrgicos eletivos utilizando algoritmos genéticos com inspiração quântica / René González Hernández; orientadora: Marley Maria Bernardes Rebuzzi Vellasco; co-orientadora: Karla Tereza Figueiredo Leite. – 2018.

78 f.: il. color.; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2018.

Inclui bibliografia

1. Engenharia Elétrica – Teses. 2. Algoritmos genéticos com inspiração quântica. 3. Saúde. 4. Schedule. 5. Otimização. 6. Algoritmos genéticos. I. Vellasco, Marley M. B. R. II. Leite, Karla Tereza Figueiredo. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. IV. Título.

CDD: 621.3

Agradecimentos

Ao CAPES, pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

A meus amigos em todas partes do mundo que juntaram aquele suporte inicial sem o qual não poderia ter chegado ao Brasil. Estarei eternamente agradecido.

A minha tia Xiomara que sempre apostou em mim, graças a ela consegui chegar até aqui.

A minha tia Miriam, sei que onde seja que estiver está torcendo por mim. Este logro é dedicado a você.

À PUC-Rio, pela oportunidade dada de cursar e completar o mestrado.

Aos professores do Departamento de Engenharia Elétrica por me dedicar seu tempo e compartilhar seus conhecimentos.

À professora Marley por ter sido minha guia em todo o processo. Muito obrigado por toda sua ajuda e compreensão. Além de uma excelente professora tem sido para mim uma inspiração.

À professora Karla por estar sempre ao meu lado brindando-me seu apoio desde o começo deste trabalho. Suas observações e comentários foram determinantes.

A todos meus amigos cubanos em Rio, especialmente a Alimed e Daniel, longe de casa mais que amigos viraram família.

A meus pais e irmã que mesmo estando longe sempre senti sua força me empurrando para frente. Eu devo tudo a vocês.

A minha esposa que não permitiu que me desviasse de um instante desta meta que hoje estou alcançando. Muito obrigado por tua paciência e também por tua impaciência ☺ .

Resumo

González Hernández, René; Marley Maria Bernardes Rebuszi Vellasco (Orientadora). Karla Tereza Figueiredo Leite (Co-Orientadora). **Otimização de Recursos para Procedimentos Cirúrgicos Eletivos Utilizando Algoritmos Genéticos com Inspiração Quântica**. Rio de Janeiro, 2018. 78p. Dissertação de Mestrado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Atualmente as Unidades de Saúde, em um grande número de países do mundo, apresentam demandas de serviços que superam suas capacidades reais. Por esta razão, o surgimento das listas de espera é inevitável. Preparar o planejamento das mesmas, de modo otimizado resulta, portanto, em um grande desafio, devido à quantidade de recursos que devem ser considerados. O caso particular dos procedimentos cirúrgicos é particularmente crítico pela quantidade de recursos que se precisam para a realização do mesmo. Poucos projetos têm sido desenvolvidos para a gestão completa dessas listas. O trabalho desenvolvido nesta Dissertação propõe o uso de um modelo, baseado em algoritmos genéticos com inspiração quântica, para a automatização e otimização do planejamento de procedimentos cirúrgicos eletivos. Este modelo, denominado Algoritmo Evolucionário com Inspiração Quântica para a Área de Saúde (AEIQ-AS), além de alocar os pacientes e os recursos necessários para que o processo cirúrgico seja exitoso, procura reduzir o tempo total para que todas as cirurgias sejam realizadas. Este trabalho apresenta também uma ferramenta que permite a modelagem, de modo simplificado, de uma Unidade Cirúrgica de Saúde. Esta ferramenta possibilita a realização de simulações com o objetivo de ver o efeito de diferentes configurações dos recursos nas Unidades de Saúde. Para a validação do modelo proposto foi criada, de modo artificial e fazendo uso da ferramenta de simulação, uma lista de espera de 2000 cirurgias. Caso as cirurgias fossem realizadas seguindo a ordem de chegada, seriam necessárias pouco mais de 37 semanas e teria 1066 operações fora do prazo. Foram feitos vários experimentos onde se buscava a otimização destes valores. Esta busca foi feita, primeiramente, tomando em consideração só um dos parâmetros e a continuação eles em conjunto. Na primeira abordagem o AEIQ-AS consegue a realização das mesmas cirurgias em aproximadamente 31 semanas. Assim, observa-se que há uma redução de aproximadamente 16,25% do tempo. O número de operações fora do prazo, por

sua vez, foi reduzido pelo modelo para 927 (13,04%). Na abordagem simultânea, o AEIQ-AS, consegue uma diminuição do tempo total de alocação em 16,22% e o número de operações fora do prazo em 9,76%. Foram feitas, também, várias simulações da Unidade de Saúde mantendo as características da lista de cirurgias para ver seu efeito no tempo total de alocação de todos os processos cirúrgicos.

Palavras-Chaves

Algoritmos Genéticos com Inspiração Quântica; Saúde; Schedule; Otimização; Algoritmos Genéticos.

Abstract

González Hernández, René; Marley Maria Bernardes Rebuszi Vellasco (Advisor). Karla Tereza Figueiredo Leite (Co-advisor). **Resource Optimization for Elective Surgical Procedures Using Quantum-inspired Genetic Algorithms**. Rio de Janeiro, 2018. 78p. Dissertação de Mestrado - Electrical Engineering Department, Pontifícia Universidade Católica do Rio de Janeiro.

Currently, Health Units in a large number of countries in the world present service demand that exceed their real capacities. For this reason, is inevitable the emergence of the waiting lists. To prepare the planning of this in an optimized manner results in a substantial challenge due to the number of resources that should be considered. The case of chirurgical procedures is particularly critical by the number of resources needed for their realization. A small quantity of projects has been developed to fully manage these lists. The work developed in this Dissertation proposes the use of a model based on evolutionary algorithms with quantum inspiration for the automation and optimization of the planning of elective chirurgical procedures. This model, denominated Evolutionary Algorithm with Quantum Inspiration for the Health Field (AEIQ-AS), beyond patients and necessary resources for the successful completion of the chirurgical procedure allocation, pursue the reduction of the total time of realization of all the surgeries. The work presents also a tool that allows the modeling, in a simplified manner, of a Chirurgical Health Unit. This tool enables the realization of simulations with the objective of seeing the effect of different configurations of the resources in the Health Units. To validate the proposed model was created, in artificial mode and employing the simulation tool, a waiting list of 2000 surgeries. In case that the surgeries were realized following the arrival order, will be needed a little more than 37 weeks and will have 1066 surgeries out of time. Several experiments were conducted in order to optimize these values. This search was executed, firstly, considering only one of the parameters and, in continuation, all together. In the first approach, the AEIQ-AS obtains the realization of the same surgeries in approximately 16,25% of the time. The number of operations out of time was reduced by the model to 927 (13,04%). In the simultaneous approach, the AEIQ-AS achieves a decrease of the allocation total time in 16,22% and the number of operations out of time in 9,76%. It were done, also, several simulations of the

Health Unit maintaining the characteristics of the surgeries list in order to look the effect in the allocation total time of all the surgical procedures.

Keywords

Genetic Algorithms with Quantum Inspiration; Health; Schedule; Optimization; Genetic Algorithms.

Sumário

1. Introdução.....	14
1.1 Motivação	14
1.2 Objetivos.....	15
1.3 Descrição do Trabalho	15
1.4 Organização da Dissertação.....	17
2. O Problema de Planejamento de Procedimentos Cirúrgicos.....	18
2.1 Unidades Cirúrgicas De Saúde	18
2.2 Recursos Materiais e Humanos.....	20
2.3 Prioridade do Paciente	21
3. Algoritmos genéticos de ordem com inspiração quântica.....	24
3.1 Algoritmos Genéticos	24
3.1.1 Operador cruzamento	24
3.1.2 Elitismo	26
3.2 Computação quântica.....	26
3.2.1 O Qbit.....	26
3.2.2 O Q-Gate	28
3.3 Algoritmos Genéticos com inspiração quântica	29
3.4 AEIQ para problemas de ordem	31
3.4.1 Representação do Indivíduo Quântico	31
3.4.2 Inicialização do Indivíduo Quântico	32
3.4.3 Observação do Indivíduo Quântico.....	33
3.4.4 Atualização do Indivíduo Quântico.....	35
4. Algoritmo Evolutivo com Inspiração Quântica para a Área da Saúde	
AEIQ-AS	38
4.1 Introdução.	38
4.2 Geração da população Quântica.....	40

4.3	Geração e atualização da População Clássica.....	41
4.3.1	Observação da População Quântica	42
4.4	Avaliação	44
4.5	Atualização da população Quântica.....	47
5.	Estudo de Caso	48
5.1	Introdução	48
5.2	Base de Dados.....	48
5.2.1	Lista de espera.....	49
5.2.2	Recursos Humanos	53
5.2.3	Recursos Materiais	55
5.2.4	Calendário	55
5.3	Resultados	56
	Experimento 1:	59
	Experimento 2:	64
	Experimento 3:	65
	Experimento 4:	67
	Experimento 5:	68
5.4	Conclusões	70
6.	Conclusões e Trabalhos Futuros.....	72
6.1	Conclusões	72
6.2	Trabalhos Futuros	73
7.	Referências bibliográficas.....	75

Lista de Figuras

Figura 1: Diagrama em blocos do processo Cirúrgico.	19
Figura 2: Classificação dos recursos.	21
Figura 3: Árvore de decisão para definir a prioridade.	23
Figura 4: Crossover Uniforme Baseado em Ordem.	25
Figura 5: Interpretação geométrica da matriz de rotação.	28
Figura 6: Pseudocódigo do AEIQ.	29
Figura 7: Representação do gene quântico real.	30
Figura 8: Diagrama em bloco do AEIQ-AS.	39
Figura 9: Pseudocódigo do modelo proposto.	40
Figura 10: Exemplo de um Cromossomo com três elementos.	41
Figura 11: Inicialização do Cromossomo da Figura 10.	41
Figura 12: Calendário de Operações.	44
Figura 13: Exemplo de alocação de duas operações no Calendário.	56
Figura 14: Curva de Evolução do melhor indivíduo no Experimento 1.	61
Figura 15: Valores médios e desvio padrão por geração.	62
Figura 16: Curva de Evolução do melhor indivíduo no Experimento 3.	66
Figura 17: Tempo total do melhor indivíduo, por geração, do Experimento 3.	67

Lista de Tabelas

Tabela 1: Prioridade vs. Tempo.....	22
Tabela 2: Percentual de Tipo de cirurgia por especialidade	49
Tabela 3: Percentual de Tipo de cirurgia para cada Complexidade.	50
Tabela 4: Percentual de Tipo de cirurgia para cada Tempo.	50
Tabela 5: Exemplo da Matriz CC.	50
Tabela 6: Percentual do total de procedimentos para cada Prioridade.	51
Tabela 7: Exemplo da Matriz CP.	52
Tabela 8: Médico Especialista vs Especialidade.	53
Tabela 9: Instrumentistas vs Especialidade.	54
Tabela 10: Disponibilidade dos ME por dia da semana.	54
Tabela 11: Salas Cirúrgicas vs Especialidade.	55
Tabela 12: Configuração da Unidade de Saúde.....	58
Tabela 13: Configuração do AGEAS-IQ para o experimento 1.....	59
Tabela 14: Comparação do Caso Base, CB2 e o Experimento 1.	60
Tabela 15: Tempo disponível total do LPrO.	62
Tabela 16: Tempo ocioso dos LPrO para o Caso Base e o Experimento 1.....	63
Tabela 17: Tabela comparativa dos tempos ociosos dos recursos do Caso Base e o Experimento 1.	64
Tabela 18: Comparativa dos tempos ociosos dos recursos do CB 2 e o Experimento 1.	64
Tabela 19: Comparação do Caso Base e CB 2 com o Experimento 2.....	65
Tabela 20: Comparativa dos tempos ociosos dos recursos do Caso Base e o Experimento 2.....	65
Tabela 21: Comparação do Caso Base com o Experimento 3.....	66
Tabela 22: Comparação dos Experimentos 1 e 3 com o Experimento 4.....	68
Tabela 23: Comparação entre a configuração inicial e a mesma configuração com 3 leitos de CTI a menos.	69
Tabela 24: Comparação entre a configuração inicial e a mesma configuração com 3 leitos de Enfermagem a menos.	69
Tabela 25: Comparação entre a configuração inicial e a mesma configuração com 3 leitos de Enfermagem a mais.....	70

1. Introdução

1.1 Motivação

Na atualidade, os hospitais públicos e privados, em quase todas as partes do mundo, apresentam demandas muito maiores às capacidades de atenção que possuem. Assim, é importante a utilização de ferramentas de gestão e otimização para seu gerenciamento, procurando sempre a utilização eficiente de seus escassos recursos.

À medida que os atendimentos na área da saúde requerem maior quantidade de recursos (humanos ou materiais), torna mais complexa a otimização dos serviços. As Unidades Cirúrgicas Eletivas são um claro exemplo disto [1]. Nessas unidades, é fundamental a existência de um grande número de recursos para a realização satisfatória dos atendimentos. Algumas das variáveis envolvidas são: disponibilidade de agenda dos médicos, a grande variedade de procedimentos cirúrgicos, os diferentes tempos para a realização dos procedimentos, as prioridades relativas dos pacientes, a capacidade do centro médico, o tempo de permanência dos pacientes nos diversos ambientes hospitalares (pré-operatório, cirurgia, CTI e enfermaria) e a idade dos pacientes [2].

Devido à falta de recursos suficientes e ao grande número de pacientes, o Sistema de Saúde não consegue atender à demanda por procedimentos cirúrgicos, resulta no surgimento das listas de espera, ou fila. Elas são geralmente organizadas baseando-se em precedência, protegendo assim a prioridade dos que chegaram antes [3]. Particularmente, no ambiente de saúde, a ordenação do atendimento deve considerar a gravidade do problema e o estado de saúde do paciente. A demora excessiva no atendimento pode provocar uma deterioração do estado do enfermo ou até, em alguns casos, a morte.

Diversos estudos têm abordado este problema com o objetivo de tornar mais eficientes os serviços hospitalares [4]. Diferentes métodos de otimização são usados, entre eles: modelos matemáticos de programação inteira [5], programação inteira mista [6–10], programação linear [11–13] e modelos heurísticos como Busca Tabu (*Tabu Search*) [14–16] e algoritmos genéticos [14,17–20]. É

importante mencionar que o problema em questão tem um caráter exponencial (NP-duro) [21], pelo que os tempos de processamento são elevados.

O Sistema de Saúde Público do Brasil ainda não dispõe de ferramenta de planificação que permita o uso eficiente de seus recursos. Esta ferramenta teria um grande impacto, já que, com a redução dos tempos de espera, seria possível melhorar a qualidade de vida dos pacientes, em tempo menor do que o atualmente praticado, e até salvar vidas.

O objetivo deste trabalho é, por tanto, criar um modelo para dar um suporte à administração de procedimento de saúde eletivos, visando a reduzir os tempos de espera na fila e respeitando a prioridade dos pacientes em função das suas condições médicas.

1.2 Objetivos

O objetivo principal deste trabalho é a criação de um modelo, baseado em algoritmos genéticos com inspiração quântica, para a automatização e otimização do planejamento de procedimento cirúrgicos eletivos. Este modelo deverá otimizar, com um custo computacional que possibilite sua utilização, o ordenamento da fila de espera para diminuir o tempo total do atendimento. Deverá também respeitar a prioridade, dada pelo médico ao paciente, de acordo com o estado de saúde do mesmo.

Os objetivos secundários são:

- A simulação de uma Unidade Cirúrgica com a intenção de realizar análises das possíveis configurações de recursos;
- A geração de calendário com a programação de todos os recursos (humanos e materiais) necessários para a realização dos procedimentos.

1.3 Descrição do Trabalho

Este trabalho foi desenvolvido seguindo as seguintes etapas:

- Estudo do ambiente onde se encontra o problema.
- Estudo das diferentes técnicas usadas na solução de problemas de otimização.

- Estudo dos Algoritmos Genéticos na solução de problemas baseados em ordem.
- Estudo dos Algoritmos Genéticos com Inspiração Quântica.
- Geração de base de dados que simule uma lista de espera de Unidade Cirúrgica para procedimentos eletivos.
- Criação de um modelo genérico para o planejamento dos procedimentos cirúrgicos.
- Teste das diferentes configurações do modelo.
- Análises do efeito das diferentes configurações do modelo.

Na primeira etapa foram estudadas as diferentes variáveis que influenciam na alocação das cirurgias em uma Unidade Cirúrgica. É importante mencionar que em esta etapa não foi possível contar com o auxílio de profissionais do setor nem se encontrou bibliografia do âmbito nacional motivo pelo qual foi estudada a configuração exposta por Testi e Tanfani em [27]. Uma melhor compreensão do problema possibilitou a geração de uma solução mais completa. Em seguida, foram estudadas diferentes abordagens usadas na literatura para a solução de problemas semelhantes. No estudo do contexto do problema, se destacou o uso de algoritmos genéticos pela flexibilidade dos mesmos e a possibilidade de fazer uma busca mais extensa dentro do universo de soluções.

Após analisar os diferentes algoritmos genéticos usados na literatura, o uso do Algoritmo Genético com Inspiração Quântica ofereceu uma perspectiva bastante concreta para reduzir o tempo de processamento, uma vez que outros trabalhos [22,23] demonstraram que o uso deste tipo de algoritmos pode trazer uma redução substancial do tempo de processamento, além de melhorar a qualidade da solução.

Após a escolha de Algoritmo Genético com Inspiração Quântica para modelar a solução do problema, estes foram ajustados para sua aplicação em problemas de ordem, onde não é possível que haja mais de um ou ausência de qualquer dos elementos a serem ordenados representados nas soluções geradas (cromossomas). Após selecionar ferramentas necessárias para enfrentar ao problema foi necessário o desenvolvimento de um modelo de simulação de uma Unidade Cirúrgica. Além de simular a lista de procedimentos, também foi necessária, a simulação de todos os recursos necessários em um processo cirúrgico (entenda-se leitos, médicos, agenda de disponibilidade, etc.).

O próximo passo foi a criação de um modelo híbrido com inspiração quântica para a alocação das cirurgias. Para a função de avaliação do modelo

foram feitas análises dos diferentes objetivos que deveriam ser considerados na ordenação dos procedimentos, de forma a torná-la suficientemente flexível. Em outras palavras, como o problema é multiobjectivo, houve a necessidade de se estabelecer pesos entre os objetivos, os quais devem ser inicialmente definidos pelo administrador da unidade de saúde.

Com o modelo definido e a simulação do problema construída, procedeu-se à realização de diferentes experimentos de teste. Assim, diferentes configurações foram implementadas e analisadas para se avaliar o efeito das mesmas nos resultados obtidos.

1.4 Organização da Dissertação

Este trabalho está dividido em mais 5 capítulos, conforme descrito a seguir:

No Capítulo 2 é apresentado o ambiente onde o problema encontra-se imerso. Nele são definidas e detalhadas as principais variáveis consideradas na formulação do modelo.

O terceiro capítulo aborda os conceitos e as ferramentas básicas necessárias para a construção do modelo, visando a uma melhor compreensão do trabalho desenvolvido. Nesse caso, incluiu-se conceitos de Computação Quântica e dos Algoritmos Genéticos com Inspiração Quântica, que são brevemente apresentados.

O Capítulo 4 apresenta o modelo de Algoritmo Genético com Inspiração Quântica desenvolvido para a otimização do planejamento das operações cirúrgicas em Unidades de Saúde. Neste capítulo são detalhadas as diferentes etapas do modelo proposto e é apresentada a função de avaliação utilizada em sua forma genérica.

No quinto capítulo são realizados diferentes testes, em diferentes estudos de casos, com a intenção de mostrar o efeito das distintas configurações do modelo proposto ao atender diferentes critérios de avaliação.

Finalmente, no último capítulo encontram-se as conclusões e os trabalhos futuros.

2. O Problema de Planejamento de Procedimentos Cirúrgicos

2.1 Unidades Cirúrgicas De Saúde

O Brasil, segundo o Instituto Brasileiro de Geografia e Estatística (IBGE), possui uma população superior a 200 milhões de habitantes. O maior país da América do Sul institucionalizou o direito à saúde a todos os cidadãos brasileiros com a promulgação da Constituição Federal em 1988, quando criou o Sistema Único de Saúde (SUS). O SUS é um dos maiores sistemas públicos de saúde do mundo. Ele abrange desde o simples atendimento ambulatorial até o transplante de órgãos, garantindo acesso integral, universal e gratuito para toda a população do país. Garantir um atendimento de qualidade para toda a população é um grande desafio para o sistema Público de Saúde Brasileiro. No entanto, mesmo sendo o terceiro país do mundo que mais gasta em saúde (\$91.7 Bilhões de dólares em 2013) [24], é um dos menos eficazes no uso destes investimentos [25].

A demanda nas Unidades Cirúrgicas no Brasil é muito maior que a oferta nas mesmas [26]. O surgimento de filas de espera é algo inevitável no momento, mas muito ainda pode ser feito para tentar reduzir os tempos de espera e melhorar a qualidade dos atendimentos. Quando o volume de pacientes é muito grande, envolvendo muitas especificidades e requisitos a serem atendidos, é difícil indicar uma solução diferente da trivial (que seria seguir a ordem de chegada dos pacientes). Tal solução, na maioria dos casos, é bem distante da solução ótima.

Para o êxito dos procedimentos cirúrgicos é necessária a convergência de um grande número de recursos, humanos e materiais. Alguns dos recursos precisam ser usados em paralelo (ao mesmo tempo) e outros em série (um em continuidade ao outro). De forma simplificada, espera-se que primeiramente o paciente fará uso do leito pré-operatório, onde serão feitos alguns procedimentos preparatórios para a cirurgia. A seguir, o paciente entrará na sala de cirurgia. Ali deverão estar presentes durante o tempo de cirurgia, pelo menos, um Médico Especialista, um Instrumentalista e um Anestesiologista (as quantidades vão depender da complexidade da operação). Uma vez concluída a intervenção cirúrgica, o

paciente será encaminhado para o Centro de Terapia Intensiva (CTI) e posteriormente para a Enfermagem. Os tempos nestes locais dependem, entre outros fatores, da complexidade da cirurgia. No caso que não seja necessária a permanência do paciente em alguma das etapas predefinidas, o tempo de permanência deverá ser igual a zero. A Figura 1 mostra um diagrama em blocos deste processo.

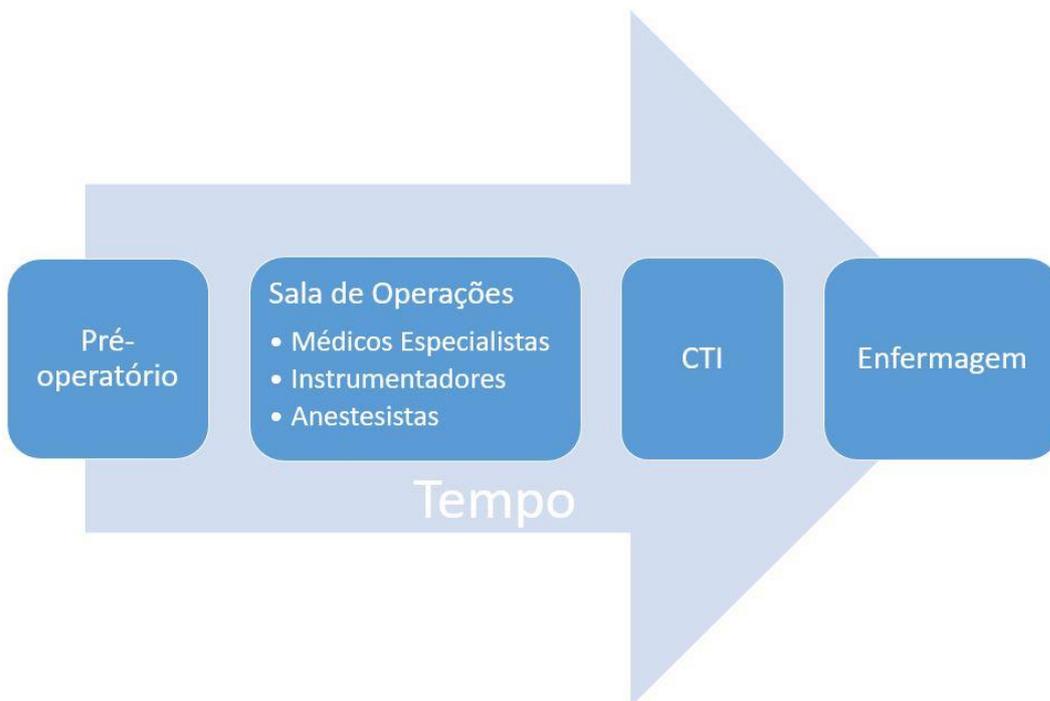


Figura 1: Diagrama simplificado do processo Cirúrgico.

Dentre as dificuldades para se fornecer uma boa qualidade nos atendimentos, está a grande quantidade de atendimentos solicitados, frente aos recursos disponíveis. Os tempos nas diferentes etapas do processo, mesmo coincidindo no tipo de intervenção, podem ser diferentes dependendo das características específicas de cada indivíduo. Isto impossibilita a criação de um padrão para a programação dos atendimentos. As prioridades e riscos dos pacientes representam outro tipo de problema, já que interferem no planejamento das intervenções incluindo restrições nos recursos que podem ser utilizados.

É muito importante que as operações sejam planejadas no menor tempo possível, sem comprometer o uso dos melhores recursos possíveis nem as prioridades dos pacientes. Nos próximos parágrafos serão descritas as

características dos recursos necessários aos procedimentos, assim como os parâmetros que devem ser considerados durante o planejamento do cronograma de atendimento.

2.2 Recursos Materiais e Humanos

Como foi dito na seção anterior, para a realização de um procedimento cirúrgico é necessário o uso de grande número de recursos. Esses atendimentos são divididos por especialidades e os recursos, por sua vez, são divididos em dois grandes grupos: os recursos materiais e os recursos humanos.

Dentro dos recursos materiais encontram-se os leitos nos vários estágios da permanência do paciente na unidade de saúde, a saber: leitos de pré-operatório, do CTI e de Enfermagem, os quais possuem diferentes equipamentos. Dependendo dos equipamentos instalados, os leitos poderão ou não ser usados para alocar um determinado procedimento. Para uma melhor compreensão suponha uma cirurgia de pé. Se o leito do CTI disponível não possui o equipamento para fixar o pé após a intervenção, o paciente não pode ser alocado neste leito específico. Outra condição poderia ser a necessidade de isolamento para um determinado procedimento cirúrgico. Destacam-se, dentre os recursos materiais, as salas de cirúrgicas. Elas, da mesma forma que os leitos antes mencionados, possuem restrições dependentes dos equipamentos instalados.

Os recursos humanos são compostos pelo pessoal médico necessário para a realização das cirurgias. Entre eles encontram-se os cirurgiões ou médicos especialistas, enfermeiros, instrumentadores e anestesistas. No modelo desenvolvido nesta Dissertação, todas as cirurgias necessitarão de pelo menos um profissional de cada tipo, mas, dependendo das características do paciente e da complexidade da intervenção, pode ser necessário o uso de uma quantidade maior.

Os cirurgiões são um recurso crítico, já que apresentam um conhecimento mais específico em uma determinada especialidade. Isto limita bastante as cirurgias em que o especialista pode participar. Na modelagem proposta nesse trabalho definiu-se que estes podem possuir conhecimentos suficientes para realizar intervenções de outras especialidades, mas só se forem de baixa complexidade. Os instrumentadores e anestesistas, por possuir uma especialização mais genérica, podem ser usados em uma maior gama de operações. Eles também

podem ter limitações em determinadas especialidades, mas em menor escala. A Figura 2 resume o exposto acima. Esta temática será ampliada no estudo de caso desenvolvido no Capítulo 5 deste trabalho.

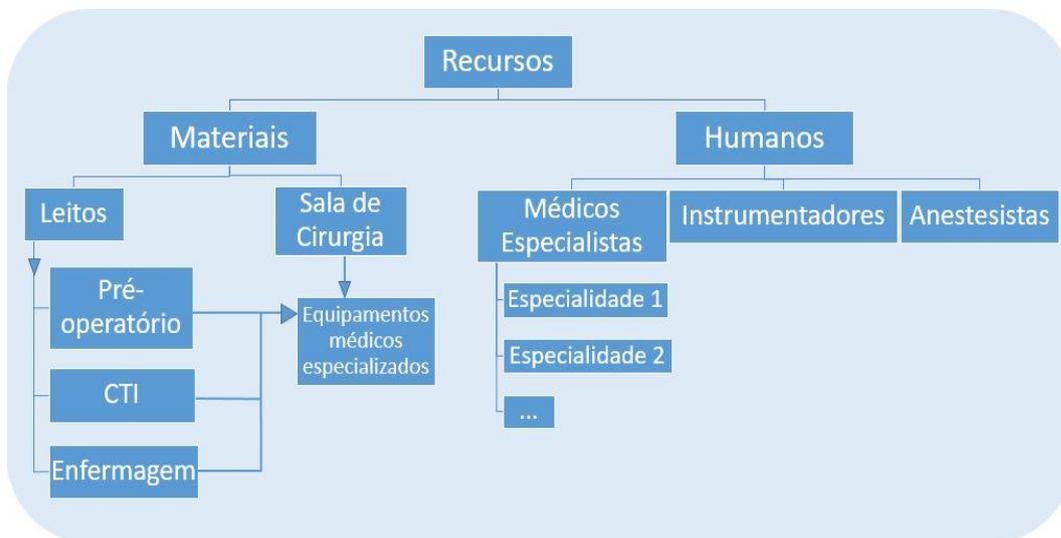


Figura 2: Classificação dos recursos.

É importante mencionar que, por falta de auxílio profissional, a modelagem proposta neste trabalho é uma versão simplificada de todo o processo cirúrgico. Não foi disponibilizado nenhum médico ou administrador de hospital para ajudar na modelagem. As suposições feitas (modelagem) foram fruto de experiências pessoais e observações do pessoal envolvido no trabalho além dos dados apresentados por Testi e Tanfani em [27].

2.3 Prioridade do Paciente

É importante definir que os pacientes podem ser divididos em dois grupos, de acordo com a sua situação de saúde, em eletivos e não eletivos. Os eletivos são aqueles que, logo após o diagnóstico, podem aguardar certo tempo até realizar a operação. Por outro lado, os não eletivos, precisam ser atendidos de forma imediata, pois está implícito um alto risco para sua vida (emergências). Este trabalho destina-se apenas ao planejamento de intervenções cirúrgicas para procedimentos eletivos.

Na atualidade, o planejamento de cirurgias é feito, em um número considerável de unidades de saúde, seguindo a ordem de ingresso à fila. Ou seja, o primeiro da lista de espera é o primeiro a ser alocado, e assim sucessivamente. É fácil notar que, além de não otimizar o tempo total, não leva em consideração o estado médico do paciente. Pode ocorrer o caso (de fato ocorre com muita frequência) em que um paciente precise de uma operação num prazo máximo de uma semana e, por ter pessoas à frente na fila, não é possível realizar tal intervenção. A condição desse paciente pode piorar pelo atraso no atendimento, chegando a colocar em risco sua vida. Se todas as pessoas à sua frente tiveram a mesma condição médica, não há muito o que possa ser feito; entretanto, se não for o caso pode-se evitar correr esse risco. Por esta razão é de vital importância considerar o estado clínico do paciente no planejamento das intervenções. Não foi encontrado, na literatura, nenhum trabalho onde se trate este tópico no âmbito nacional. A seguir descreve-se o sistema de prioridade proposto em [27] e também utilizado neste trabalho.

O sistema é baseado em um estudo realizado no Hospital Villa Scassi de Génova, Itália pela Universidade de Génova. Este trabalho [27] sugere cinco tipos de prioridades, os quais são associados aos tempos de espera máximos recomendados. Os tempos vão de 6 dias até um ano, aproximadamente. A Tabela 1 apresenta a relação entre as prioridades e os tempos de espera recomendados.

Prioridade	Tempo máximo Recomendado [dias]
A	6
B	30
C	90
D	180
E	360

Tabela 1: Prioridade vs. Tempo.

Para determinar o tipo de prioridade de cada paciente são considerados critérios associados ao mesmo. Basicamente, os critérios são: progresso da enfermidade e a existência, ou não, de dor. A Figura 3 ilustra a árvore de decisão em que se apoiam os médicos para determinar a prioridade do paciente.

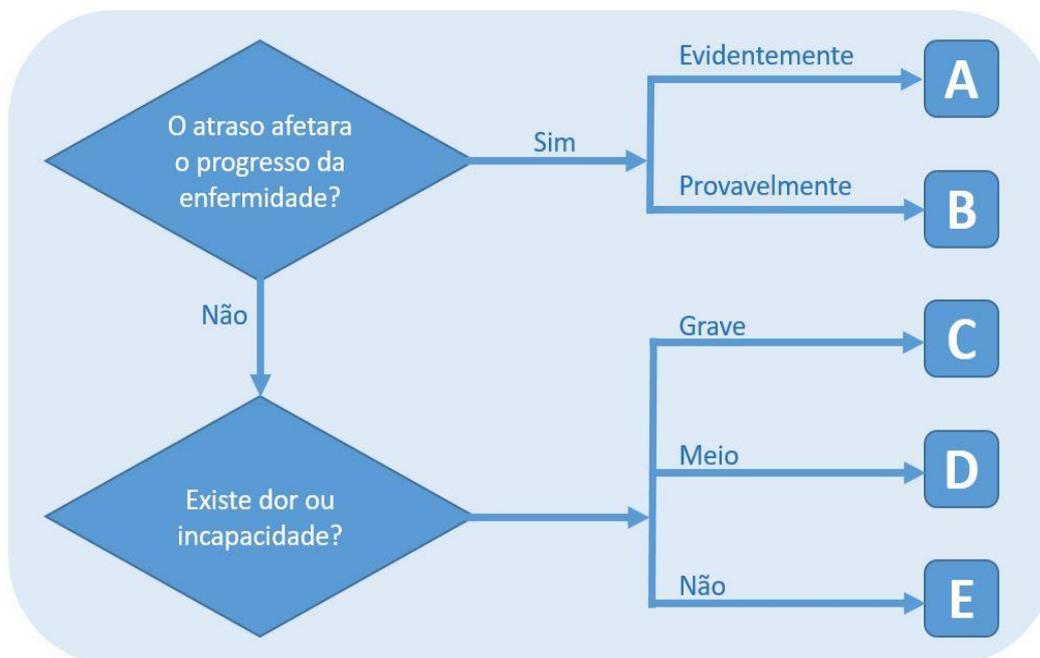


Figura 3: Árvore de decisão para definir a prioridade.

Pode se observar que, seguindo este sistema, pacientes com diferentes cirurgias podem ter a mesma prioridade e pacientes com diferentes prioridades podem precisar da mesma cirurgia. Ou seja, a prioridade é independente do tipo de cirurgia. Este é o modelo de prioridade utilizado nesse trabalho.

3. Algoritmos genéticos de ordem com inspiração quântica

3.1 Algoritmos Genéticos

Os algoritmos genéticos são um paradigma dos algoritmos evolucionários. Neles as soluções geradas são chamadas de indivíduos ou cromossomos. O conjunto de cromossomos é denominado de população. Os indivíduos são modificados, a cada geração, por operadores genéticos que tentam simular os processos naturais de combinação e mutação genética. Além destes operadores existe o conceito de elitismo, o qual define quais indivíduos devem sobreviver e pertencer à próxima geração, simulando o princípio de seleção natural. Dado que os indivíduos com melhores avaliações têm mais possibilidades de sobreviver, a população deve evoluir gradualmente. Estes algoritmos são chamados de Algoritmos Genéticos “clássicos” por ser os mais usados na literatura [28].

A seguir são apresentados os operadores genéticos “clássicos” usados neste trabalho. Em seguida, fazemos um pequeno resumo dos principais aspectos da computação quântica para, finalmente, entrar nos tópicos relacionados aos Algoritmos Genéticos com Inspiração Quântica.

3.1.1 Operador cruzamento

O operador cruzamento, também chamado de *crossover*, tenta simular a reprodução natural dos seres vivos. Mediante seu uso, são gerados novos indivíduos (filhos) a partir de características genéticas presentes em indivíduos já existentes (pais). No caso específico de um problema de ordem, os indivíduos gerados por esse operador devem cumprir com os requisitos de que não possuam elementos repetidos e que todos os elementos da lista original estejam presentes. Ou seja, será necessário um operador de *crossover* baseado em ordem. Na literatura destacam-se dois diferentes tipos, o *crossover* de dois pontos baseado em ordem e o uniforme. Nesse trabalho foi implementado o *crossover* uniforme baseado em ordem [29], pois o de dois pontos não era compatível com algumas características do modelo desenvolvido.

A seguir descreve-se a implementação deste operador:

1. Gere uma máscara de bits aleatória do mesmo tamanho que os elementos do indivíduo;
2. Copie para o filho 1 os elementos do pai 1 referentes àquelas posições, onde a máscara de bits possui o bit um;
3. Faça uma lista dos elementos do pai 1 referentes aos zeros da máscara de bits;
4. Permute esta lista de forma que os elementos apareçam na mesma ordem que no pai 2;
5. Coloque os elementos nos espaços do filho 1 na ordem gerada no passo anterior;
6. Repita o processo para gerar o filho 2, substituindo o pai 1 pelo 2 e vice-versa.

Para uma melhor compreensão é apresentado um exemplo na Figura 4:

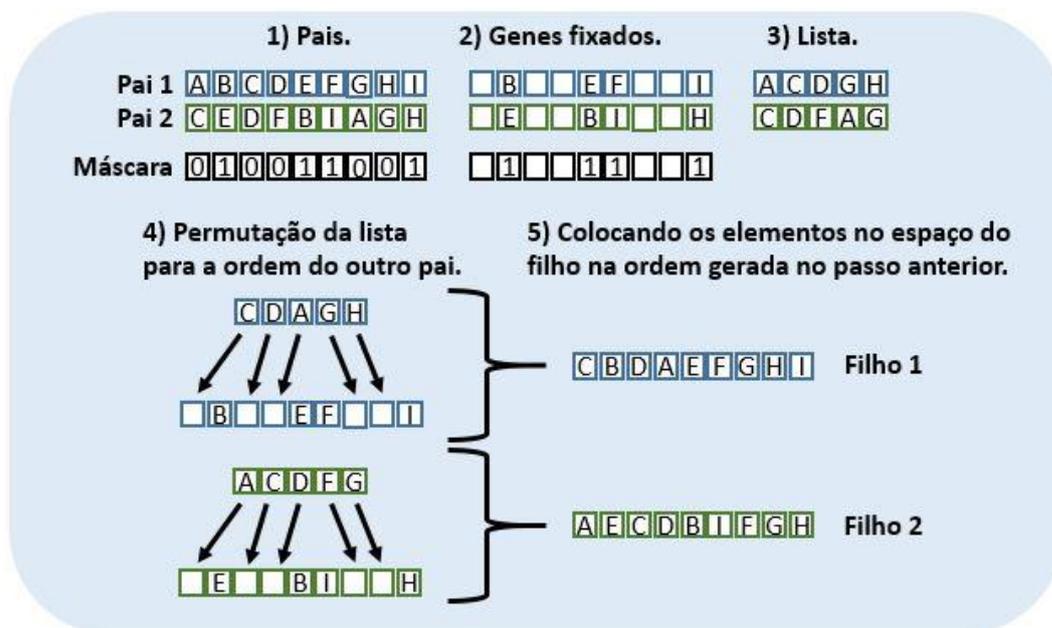


Figura 4: Crossover Uniforme Baseado em Ordem.

O operador *crossover* possui um parâmetro, chamado taxa de *crossover* (T_{cross}), o qual define se o operador será executado ou não. Ele é definido no intervalo de $[0,1]$. A seguir apresenta-se o passo a passo deste processo:

1. É definido o parâmetro taxa de crossover;
2. São selecionados dois indivíduos (pais) da população clássica;
3. É gerado um número aleatório entre 0 e 1;
4. Se o número gerado é menor que a T_{cross} então é usado o operador crossover para a geração de dois novos indivíduos (filhos);
5. Caso contrário, os pais são diretamente copiados para a nova população;
6. O processo se repete até alcançar o número de indivíduos necessários para a atualização da população.

O método de seleção usado neste trabalho para o passo 2 é denominado seleção por torneio. Este método baseia-se na seleção aleatória de indivíduos e na comparação de suas aptidões para seu uso na reprodução. O torneio, neste trabalho, é realizado entre dois cromossomos (indivíduos); o indivíduo com a maior aptidão é selecionado para a reprodução.

3.1.2 Elitismo

O elitismo busca que os melhores indivíduos de uma geração sejam mantidos na próxima geração, simulando o conceito da sobrevivência dos mais aptos exposto por Darwin na teoria da evolução. Associa-se também uma taxa de elitismo, a qual define quantos, dos melhores indivíduos, serão mantidos na nova geração.

3.2 Computação quântica

A computação quântica é um paradigma de computação que teve sua inspiração na mecânica quântica. Em mecânica quântica, é possível que uma partícula esteja em dois ou mais estados ao mesmo tempo [30]. A propriedade de estar simultaneamente em vários estados é nomeada superposição. Os dispositivos quanticamente inspirados são exponencialmente mais eficientes que os dispositivos clássicos já que, graças à superposição, todo o espaço de busca de um problema é considerado simultaneamente. Alguns trabalhos [27,30] demonstram que o uso de sistemas clássicos inspirados neste fenômeno pode produzir um ganho substancial em relação ao tempo de processamento e à qualidade da solução.

3.2.1 O Qbit.

Na computação clássica, a menor unidade de armazenamento é denominada bit, o qual pode apresentar apenas dois valores (ou estados base): “0” ou “1”. Se o valor de um bit é “1”, por exemplo, em qualquer momento que se faça uma observação, este valor será mantido.

O equivalente na computação quântica é o bit quântico (Qbit). A diferença em relação ao bit clássico é que o seu estado pode mudar a cada observação [30]. O Qbit pode representar o estado 0, o estado 1 ou uma superposição de ambos estados. Não é possível conhecer a priori o valor medido de um Qbit, mas é possível estimar a probabilidade de se observar um determinado estado após um processo de medida.

Definindo $|\Psi\rangle$ como a superposição de estados, um Qbit pode ser representado pela soma linear dos estados base, conforme equação a seguir:

$$|\Psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (1)$$

sendo α e β números reais que indicam as amplitudes de probabilidade dos estados correspondentes. Tais amplitudes devem cumprir a condição de normalização $|\alpha|^2 + |\beta|^2 = 1$ [31]. O número $|\alpha|^2$ será a probabilidade do estado “0” ser observado e $|\beta|^2$ a probabilidade do estado “1” ser observado.

Expandindo o conceito, para 2 Qbit tem-se a seguinte representação:

$$|\Psi\rangle_2 = \delta_1|00\rangle + \delta_2|01\rangle + \delta_3|10\rangle + \delta_4|11\rangle \quad (2)$$

Cumprindo que:

$$\sum_{j=1}^4 |\delta_j|^2 = 1 \quad (3)$$

Pode-se constatar que, para 2 Qbit, 4 possíveis estados podem ser observados, ou seja, 4 estados são representados simultaneamente por seus valores de probabilidade. Em termos gerais, m Qbit são representados pela equação:

$$|\Psi\rangle_m = \sum_{j=1}^{2^m} \delta_j |S_j\rangle \quad \text{desde que} \quad \sum_{j=1}^{2^m} |\delta_j|^2 = 1 \quad (4)$$

Onde $|\delta_j|^2$ é a probabilidade do estado S_j ser observado. Um sistema quântico de m Qbit pode representar 2^m estados simultaneamente [32], mas

depois de uma observação somente o estado observado é mantido. Os outros estados deixam de existir até uma próxima observação.

3.2.2 O Q-Gate

Seguindo a analogia com a computação clássica, na quântica também são usadas portas lógicas para modificar o conteúdo dos Qbits. Essas portas são chamadas de portas quânticas, ou Q-Gate. Basicamente, as Q-Gates são matrizes de rotação que, aplicadas sobre um bit quântico, obtêm-se como resultado um novo bit quântico rotacionado por um ângulo θ . A equação a seguir representa esta operação.

$$\begin{bmatrix} \alpha' \\ \beta' \end{bmatrix} = \begin{bmatrix} \cos(\theta) & -\text{sen}(\theta) \\ \text{sen}(\theta) & \cos(\theta) \end{bmatrix} \begin{bmatrix} \alpha \\ \beta \end{bmatrix} \quad (5)$$

Onde α e β são as amplitudes de probabilidade dos estados correspondentes do Qbit inicial, α' e β' do resultante e θ é o ângulo de rotação. Na Figura 5 é apresentado geometricamente o efeito da matriz de rotação.

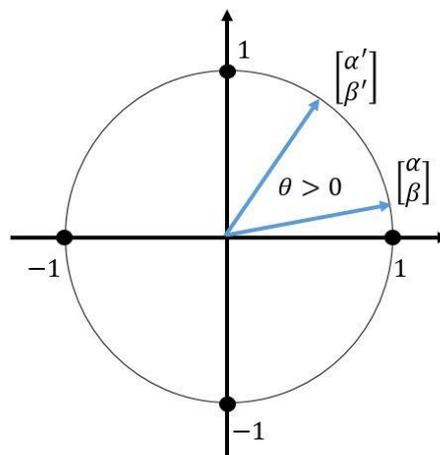


Figura 5: Interpretação geométrica da matriz de rotação.

Pode-se observar, no caso representado, que a rotação no sentido anti-horário faz com que $\alpha > \alpha'$, ou seja, a modificação faz com que a probabilidade

de se observar o estado associado a α aumente. No caso de $\theta < 0$, a rotação será no sentido horário e ocorrerá o efeito contrário ($\alpha < \alpha'$ e $\beta > \beta'$).

3.3 Algoritmos Genéticos com inspiração quântica

Em [30], Zhang e Gexiang definem as condições para que um algoritmo seja considerado quanticamente inspirado. Segundo sua definição, o algoritmo deve ser considerado evolucionário, onde os indivíduos quânticos são representados por bits quânticos e devem ser atualizados por portas quânticas.

Os algoritmos evolutivos geram uma sequência de soluções ao longo das iterações (denominadas gerações), visando a fazer com que o valor da função objetivo melhore à medida que a sequência de soluções progride [33].

Considerando os requisitos definidos por Zhang e Gexiang o pseudocódigo geral do algoritmo evolucionário com inspiração quântica (AEIQ) é apresentado na Figura 6.

início

Inicializa $Q(t)$: População Quântica

enquanto ($t \leq Max_Ger$)

Gera $P(t)$: Observa n vezes cada indivíduo quântico em $Q(t)$.

Avalia $P(t)$.

Atualiza $Q(t)$ usando os melhores indivíduos de $P(t)$.

$t \leftarrow t + 1$

fim enquanto

fim

Figura 6: Pseudocódigo do AEIQ.

Diversos trabalhos têm usado AEIQ na solução de problemas de otimização [22,23,27,30,34–37]. Igualmente aos algoritmos genéticos “clássicos”, o tipo de representação de seus indivíduos dependerá do tipo de problema a ser solucionado. Em [23] é usado um AEIQ com representação binária na solução de problemas de otimização combinatória.

A representação binária não é a mais adequada quando se deseja proceder a uma otimização numérica. Em [22] é apresentado um modelo com inspiração quântica que utiliza representação baseada em números reais. Essa representação é chamada de representação real. Nela, as variáveis deixam de ser discretas (0 ou 1) e passam a ser contínuas, sendo representadas por uma distribuição de probabilidade uniforme. A Figura 7 mostra a representação gráfica de uma variável que pode tomar valores entre -1 e 1. É importante destacar que um indivíduo ou cromossomo pode ser composto por mais de uma variável e que, essas variáveis, são chamadas de genes.

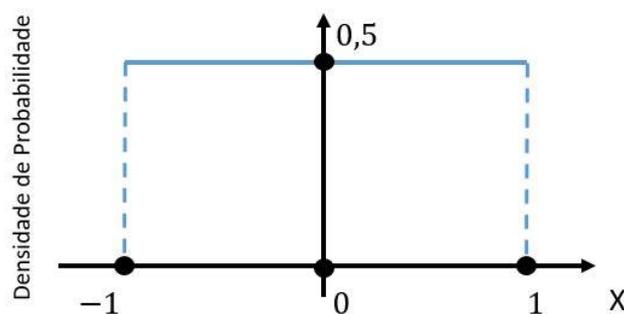


Figura 7: Representação do gene quântico real.

Para a representação numérica do gene são usados os valores do centro (μ) e a largura (σ) da distribuição. Pode se observar que nesta nova representação a atualização dos indivíduos quânticos, usando a Q-Gate, não é adequada. Vargas, em [22], propõe outro método de atualização que produz a redução do universo de busca movimentando o centro da distribuição e reduzindo a largura da mesma, a partir dos valores dos melhores indivíduos usados na atualização.

O problema tratado neste trabalho é a determinação da melhor ordem de atendimento em uma fila de espera. Este tipo de problemas, conforme já mencionado, é denominado problema de ordem e o algoritmo deve garantir que as soluções geradas (indivíduos) não possuam elementos (genes) repetidos. Se, por exemplo, a fila é de 4 pessoas, o cromossomo é formado por 4 genes, podendo ser representados por valores discretos 1,2,3 ou 4; entretanto, estes valores não podem se repetir num mesmo cromossomo. As representações propostas em [22,23] não cumprem com este requisito. Em [34] é proposto um novo algoritmo genético de ordem com inspiração quântica. Por ser o mais adequado na solução do problema

tratado nessa Dissertação, este modelo é apresentado mais detalhadamente nas sub-seções seguintes.

3.4 AEIQ para problemas de ordem

Como foi mostrado na Figura 6, os AEIQ possuem os seguintes processos:

- Inicialização da população quântica
- Observação dos indivíduos quânticos
- Avaliação da solução
- Atualização dos indivíduos quânticos.

Além destes processos, é também de vital importância a forma de representação do indivíduo quântico.

A principal contribuição do trabalho de Silveira [33] é exatamente a definição de uma representação (juntamente com o modo de observação do indivíduo quântico) específica para problemas de ordem. Em seguida, serão apresentados alguns dos principais conceitos propostos em [33].

3.4.1 Representação do Indivíduo Quântico

O indivíduo quântico proposto por [33] é representado por um vetor de dimensão n . Cada elemento do vetor n é composto por m Qbits, podendo representar 2^m estados. Seja U o conjunto finito dos possíveis estados a serem observados; cada elemento de n pode assumir um elemento de U com certa probabilidade. A soma destas probabilidades deve ser igual a 1.

No caso particular dos problemas de ordem, o número Qbits de cada elemento do vetor n é igual à quantidade de elementos do conjunto U . Por exemplo, se o conjunto U tiver 3 elementos, ele vai ser representado por 3Qbit, onde apenas os estados $|001\rangle$, $|010\rangle$ e $|100\rangle$ serão considerados. Isto é equivalente a dizer que só estes estados terão probabilidade não nula. Uma possível notação seria:

$$|\Psi\rangle_3 = \delta_1|001\rangle + \delta_2|010\rangle + \delta_3|100\rangle \text{ cumprindo que } \sum_{j=1}^3 |\delta_j|^2 = 1 \quad (6)$$

O estado $|001\rangle$ representa a escolha do primeiro elemento de U , $|010\rangle$ do segundo e $|100\rangle$ do terceiro. Em uma notação mais simples, e que foi adotada em

[33], o indivíduo quântico é uma matriz real de dimensão $n \times m$, onde os coeficientes de cada linha representam a probabilidade de observação de cada estado do mQbit. A representação do exemplo anterior, supondo um indivíduo de n elementos, seria é apresentada a seguir:

$$Q = \begin{bmatrix} |\delta_{11}|^2 & |\delta_{12}|^2 & |\delta_{13}|^2 \\ \vdots & \ddots & \vdots \\ |\delta_{n1}|^2 & |\delta_{n2}|^2 & |\delta_{n3}|^2 \end{bmatrix} \text{ cumprindo que } \sum_{j=1}^3 |\delta_{jn}|^2 = 1 \quad (7)$$

Generalizando:

$$Q = \begin{bmatrix} q_{11} & \cdots & q_{1m} \\ \vdots & \ddots & \vdots \\ q_{n1} & \cdots & q_{nm} \end{bmatrix} \text{ onde } q_{ij} \in [0,1] \text{ e } \sum_{j=1}^m q_{ij} = 1, \forall i \in \{1, \dots, n\} \quad (8)$$

onde n é o número de elementos do indivíduo quântico e m o número de Qbits usados na representação. É interessante observar que $q_{ij} = |\delta_{ij}|^2$ considerando que o mQbit da i -ésima linha é representado por: $|\Psi\rangle_{im} = \delta_{i1}|00 \dots 01\rangle + \delta_{i2}|00 \dots 10\rangle + \dots + \delta_{im-1}|01 \dots 00\rangle + \delta_{im}|10 \dots 00\rangle$ [33].

3.4.2 Inicialização do Indivíduo Quântico

Após a definição da representação do indivíduo quântico, o próximo passo é a inicialização da população. A inicialização consiste na atribuição dos valores iniciais de probabilidade dos possíveis estados para cada elemento do indivíduo (q_{ij}). Qualquer conjunto de valores que satisfaçam às condições $q_{ij} \in [0,1]$ e $\sum_{j=1}^m q_{ij} = 1, \forall i \in \{1, \dots, n\}$ podem ser usados para iniciar um indivíduo quântico.

Pode-se demonstrar facilmente que a escolha dos valores iniciais dos indivíduos tem um forte impacto na observação dos indivíduos. Suponha um indivíduo de dimensão 2×3 ($n=2, m=3$). O mesmo pode ser representado pela seguinte matriz:

$$Q = \begin{bmatrix} q_{11} & q_{12} & q_{13} \\ q_{21} & q_{22} & q_{23} \end{bmatrix} \quad (9)$$

Suponha que os valores iniciais sejam os seguintes:

$$Q = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix} \quad (10)$$

Qualquer observação feita neste indivíduo produzirá sempre a solução $x = (2,3)$, ou seja, apenas uma solução do espaço de busca será gerada. É interessante (se não dispor de informação a priori que possibilite direcionar a busca para um certo setor do espaço de solução) que todo o espaço de busca seja explorado. Uma boa forma de conseguir isso é garantir que qualquer elemento do espaço de busca tenha igual probabilidade de ser observado. Nesse caso, atendendo esse requisito de equanimidade, para o exemplo anterior a matriz Q seria:

$$Q = \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ 1/3 & 1/3 & 1/3 \end{bmatrix} \quad (11)$$

Na falta de informações específicas sobre o problema que se deseja resolver, esta forma de inicialização parece ser a mais indicada [33].

Generalizando a ideia anterior:

$$q_{ij} = \frac{1}{m}, \forall i \in \{1, \dots, n\}, \forall j \in \{1, \dots, m\} \quad (12)$$

3.4.3 Observação do Indivíduo Quântico

O processo de observação é um processo aleatório, visando garantir que cada vez que seja realizado, uma solução diferente poderá ser gerada [33]. É importante observar que, nos problemas de ordem, as soluções geradas têm que conter todos os elementos do conjunto U e podem aparecer só uma vez. Dito com outras palavras, as soluções têm que ser permutações do conjunto U . Em [33] o autor denomina este tipo de problemas como Problema de Permutações.

É fácil notar que, como cada linha da matriz está associada a cada elemento do vetor de solução X , para garantir que todos os elementos do conjunto U estejam nas soluções geradas, os indivíduos quânticos devem ser representados

por matrizes quadradas ($n = m$). A outra condição, que limita os elementos do vetor U a aparecerem na solução só uma vez, é cumprida se, após a observação do elemento, a probabilidade de ele ser selecionado nas restantes linhas é anulada. Deve ser considerado, entretanto, que, com esta modificação, a condição $\sum_{j=1}^m q_{ij} = 1, \forall i \in \{1, \dots, n\}$ pode deixar de ser válida. Logo, é necessária a atualização de todos os coeficientes nas restantes linhas do indivíduo quântico. A atualização é mostrada a seguir:

$$q_{ij}' = \frac{q_{ij}}{1 - q_{ip}}, \forall i \in \{r + 1, \dots, n\} \quad (13)$$

onde q_{ip} é a probabilidade que tinha o elemento selecionado na linha r . Os elementos são selecionados do seguinte modo: sorteia-se um número $r_1 \in (0,1]$; o k -ésimo elemento do conjunto U é selecionado se:

$$\begin{aligned} q_{i1} > r_1 & \quad \text{Para } k = 1 \\ \sum_{j=1}^k q_{ij} > r_1 \text{ e } \sum_{j=1}^{k-1} q_{ij} \leq r_1 & \quad \text{Para } k > 1 \end{aligned} \quad (14)$$

A explicação, passo a passo, do processo é apresentada mediante um exemplo, para uma melhor compreensão. Supondo o conjunto $U = \{1,2,3,4\}$ e o indivíduo quântico inicializado do seguinte modo:

$$Q = \begin{bmatrix} 1/4 & 1/4 & 1/4 & 1/4 \\ 1/4 & 1/4 & 1/4 & 1/4 \\ 1/4 & 1/4 & 1/4 & 1/4 \\ 1/4 & 1/4 & 1/4 & 1/4 \end{bmatrix} = \begin{bmatrix} 0,25 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0,25 \\ 0,25 & 0,25 & 0,25 & 0,25 \end{bmatrix} \quad (15)$$

1. É sorteado o número $r_1 = 0,62$.
2. A condição $\sum_{j=1}^k q_{1j} > r_1$ e $\sum_{j=1}^{k-1} q_{1j} \leq r_1$ se cumpre para $k=3$, logo é selecionado o 3º elemento de U .
3. São atualizados os coeficientes das linhas seguintes.

$$\begin{aligned}
 Q &= \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0,25/1-0,25 & 0,25/1-0,25 & 0 & 0,25/1-0,25 \\ 0,25/1-0,25 & 0,25/1-0,25 & 0 & 0,25/1-0,25 \\ 0,25/1-0,25 & 0,25/1-0,25 & 0 & 0,25/1-0,25 \end{bmatrix} \\
 &= \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \\ 0,33 & 0,33 & 0 & 0,33 \end{bmatrix} \quad (16)
 \end{aligned}$$

4. Um novo número é sorteado $r_2 = 0,58$.
5. O 2º elemento de U é selecionado.
6. Os coeficientes de Q são atualizados.

$$\begin{aligned}
 Q &= \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 0,33/1-0,33 & 0 & 0 & 0,33/1-0,33 \\ 0,33/1-0,33 & 0 & 0 & 0,33/1-0,33 \end{bmatrix} \\
 &= \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 0,5 & 0 & 0 & 0,5 \\ 0,5 & 0 & 0 & 0,5 \end{bmatrix} \quad (17)
 \end{aligned}$$

7. Um novo número é sorteado $r_3 = 0,73$.
8. O 4º elemento de U é selecionado
9. Os coeficientes de Q são atualizados

$$Q = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \end{bmatrix} \quad (18)$$

10. Logo, o 1º elemento de U é selecionado.
11. Finalmente a solução gerada é $S_1 = [3,2,4,1]$.

3.4.4 Atualização do Indivíduo Quântico

A atualização de um indivíduo quântico tem como objetivo a modificação do mesmo para tentar gerar soluções melhores na próxima observação. Esta é a característica evolucionária do algoritmo: tentar obter ao longo das gerações uma

sequência de soluções cada vez melhores [33]. A ideia é usar as melhores soluções da geração anterior e aumentar a probabilidade de obter soluções ainda melhores no próximo processo de observação. Deste modo, a busca vai se direcionando para a área do espaço que produzem melhores soluções.

O processo de atualização é descrito a seguir: supondo uma população quântica de n indivíduos quânticos, são selecionadas as n observações da geração anterior que tiveram melhores avaliações. Para que fique mais claro, as observações serão chamadas de indivíduos clássicos. A atualização de cada indivíduo quântico é baseada em um indivíduo clássico. A atualização é descrita pela seguinte equação:

$$Q^{t+1} = (1 - \varepsilon) * Q^t + \varepsilon * E^t \quad (19)$$

Onde Q^t é o indivíduo quântico original, Q^{t+1} é o indivíduo quântico atualizado, E^t é o indivíduo clássico selecionado para a atualização do indivíduo quântico e ε seria a taxa de atualização com domínio $(0,1]$.

Através do exemplo a seguir, é possível compreender melhor o procedimento. Seja o indivíduo quântico Q_1 representado pela matriz:

$$Q_1^t = \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ 1/3 & 1/3 & 1/3 \\ 1/3 & 1/3 & 1/3 \end{bmatrix} \quad (20)$$

Seja o indivíduo clássico E_1 selecionado para a atualização de Q_1 , representado pela matriz:

$$E_1^t = \begin{bmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \quad (21)$$

Logo,

$$Q_1^{t+1} = (1 - \varepsilon) * \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ 1/3 & 1/3 & 1/3 \\ 1/3 & 1/3 & 1/3 \end{bmatrix} + \varepsilon * \begin{bmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \quad (22)$$

$$Q_1^{t+1} = \begin{bmatrix} (1 - \varepsilon)/3 & (1 - \varepsilon)/3 & (1 + 2\varepsilon)/3 \\ (1 + 2\varepsilon)/3 & (1 - \varepsilon)/3 & (1 - \varepsilon)/3 \\ (1 - \varepsilon)/3 & (1 + 2\varepsilon)/3 & (1 - \varepsilon)/3 \end{bmatrix} \quad (23)$$

Pode-se observar que a probabilidade de se observar E^t no próximo processo de observação é maior. Também é importante observar que a condição $\sum_{j=1}^m q_{ij} = 1, \forall i \in \{1, \dots, n\}$ continua sendo válida.

Deve ser notado que, à medida que o valor de ε aumenta, maior é a probabilidade de observar E_1^t em Q_1^{t+1} , chegando ao caso extremo onde $\varepsilon = 1$. Nesse caso, só E_1^t poderá ser observado em Q_1^{t+1} . Logo, a seleção do parâmetro ε tem uma grande influência na evolução do algoritmo. Parâmetros muito altos podem provocar que os indivíduos quânticos, depois de várias gerações (atualizações), gerem sempre a mesma solução (indivíduo quântico saturado). No entanto, valores muito pequenos podem atentar contra o tempo de convergência do algoritmo. O Luciano em [34] faz uma análise da influência deste parâmetro na evolução do algoritmo e propõe critérios para eliminar os efeitos negativos da mesma.

No próximo capítulo, será apresentado o modelo proposto neste trabalho com base no algoritmo exposto neste capítulo. O mesmo será adaptado ao problema de planejamento dos processos cirúrgicos em uma Unida de Saúde. Como já foi dito, este é um problema de ordem sem repetições onde todos os elementos têm que aparecer na solução.

4. Algoritmo Evolutivo com Inspiração Quântica para a Área da Saúde AEIQ-AS

4.1 Introdução.

Como foi mencionado na Introdução, o problema em questão é um problema multiobjetivo. Como o nome indica, são problemas que apresentam dois ou mais objetivos, para os quais se deseja alcançar os melhores resultados. Casos esses objetivos sejam conflitantes (uma solução boa para um determinado objetivo é ruim para outro) o problema não possui uma solução ótima, já que não existe uma solução que seja a melhor com respeito a todos os objetivos.

Existe, entretanto, um conjunto de soluções que não podem ser comparadas entre si. Este tipo de soluções são denominadas soluções não dominadas ou soluções da fronteira de Pareto [38]. A decisão por uma das soluções dependerá do critério do tomador de decisões (usuário), o qual terá em conta a relação de compromisso entre os diferentes objetivos.

O modelo proposto neste trabalho baseia-se no modelo híbrido desenvolvido por Silveira [34], o qual utiliza algoritmos genéticos com inspiração quântica, para problemas de ordem, com algoritmos genéticos clássicos. Nesse algoritmo, a observação dos indivíduos quânticos, exposta na Seção 3.3.3, torna-se custosa computacionalmente à medida que aumenta a dimensão da matriz. Por tal razão, decidiu-se fazer uma pequena alteração no algoritmo, evoluindo por algumas gerações os indivíduos clássicos, diminuindo assim o tempo total de processamento. Deste modo, utiliza-se o potencial da representação com inspiração quântica, onde todo o espaço de busca é considerado simultaneamente, sem comprometer o tempo de processamento.

Na Figura 8, é apresentado o diagrama em bloco do AEIQ-AS:

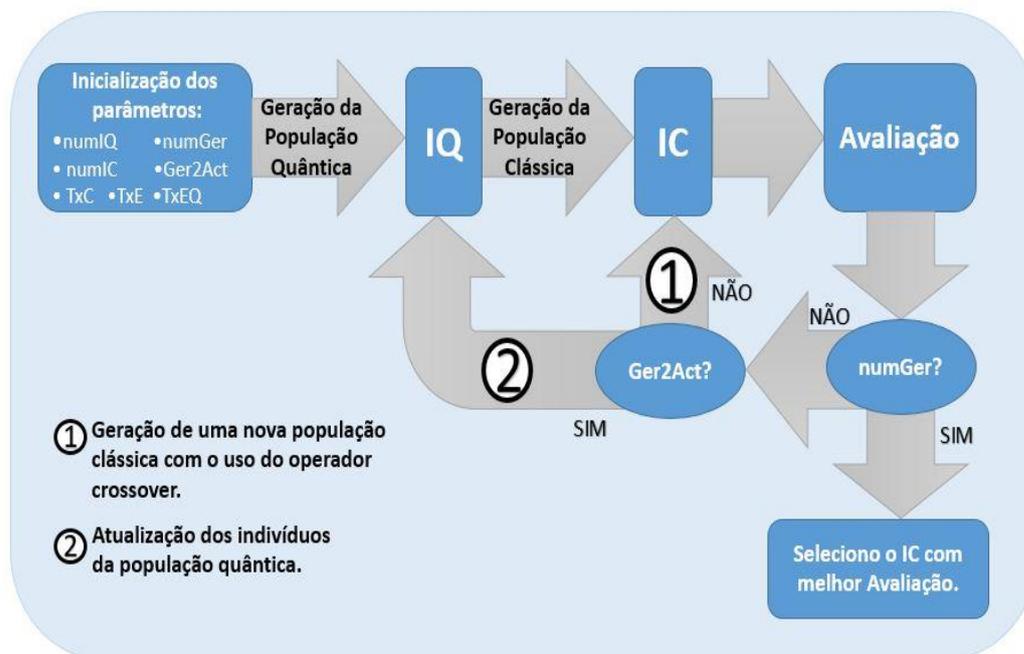


Figura 8: Diagrama em bloco do AEIQ-AS.

A descrição da Figura 8 pode ser feita a partir da definição dos seguintes parâmetros pelo usuário: o número de indivíduos quânticos que formarão a população quântica (numIQ), o tamanho da população clássica (numIC), o número de gerações (numGer), o número de gerações da evolução do algoritmo genético clássico antes de atualizar a população quântica (Ger2Act), a taxa de crossover (TxC) e as taxas de elitismo (TxE e TxEQ). Após a inicialização destes parâmetros, é gerada a população quântica. Logo, mediante a observação dos indivíduos quânticos, é gerada a população clássica. Todos os cromossomas clássicos são avaliados usando a função de avaliação definida. Se o número máximo de gerações ainda não foi alcançado, é verificado se já transcorreram as gerações necessárias para atualizar os indivíduos quânticos. Caso afirmativo, é atualizada a população quântica e são gerados os novos indivíduos clássicos da próxima geração. Caso negativo, novos indivíduos clássicos são gerados com o uso do operador crossover sobre os indivíduos da população anterior. Em ambos casos, à nova população gerada são adicionados os k melhores indivíduos da população anterior. O valor de k vai depender da taxa de elitismo (TxEQ no

primeiro caso e TxE no segundo). O ciclo é repetido até atingir o número máximo de gerações, momento em que o indivíduo com a melhor avaliação é selecionado como solução do problema. Mesmo sendo um problema multiobjectivo, a função de avaliação será única onde os objetivos serão ponderados. Todos estes processos são explicados em detalhe no decorrer deste capítulo. A Figura 9 mostra o pseudocódigo do modelo do AEIQ-AS.

```

início
  Inicializa População Quântica ( $Q(t)$ ).
  Gera População Clássica ( $P(t)$ ): Observa  $n$  vezes cada indivíduo quântico em  $Q(t)$ .
  enquanto ( $t \leq Max\_Ger$ )
    Avalia  $P(t)$ .
    se ( $NumGerA$ )então:
      Atualiza  $Q(t + 1)$  usando os melhores indivíduos de  $P(t)$ .
      Gera uma nova  $P(t + 1)$ : Observa  $n$  vezes cada indivíduo quântico em  $Q(t + 1)$ .
    senão
      Gera uma nova  $P(t + 1)$  usando o operador crossover clássico com base no parâmetro  $T_{cross}$ .
    fim se
    Com base no parâmetro  $T_{elit}$  mantem os  $k$  melhores indivíduos de  $P(t)$  em  $P(t + 1)$ .
     $t \leftarrow t + 1$ .
  fim enquanto
fim

```

Figura 9: Pseudocódigo do modelo proposto.

4.2 Geração da população Quântica

A população quântica é formada por um número determinado de indivíduos quânticos ou cromossomos, os quais, conforme descrito no capítulo anterior, são formados por uma matriz quadrada de ordem n , onde n é o número de elementos na lista de espera. Cada linha representa um *gene* do cromossomo e nas colunas temos a probabilidade de o *gene* tomar o valor correspondente ao número da coluna. A matriz, neste problema específico, deve ser quadrada, já que todos os elementos da lista devem estar presentes nas soluções geradas. A seguir é apresentado, a título de exemplo, um cromossomo para uma lista de 3 elementos.

$$Q = \begin{bmatrix} q_{11} & q_{12} & q_{13} \\ q_{21} & q_{22} & q_{23} \\ q_{31} & q_{32} & q_{33} \end{bmatrix}$$

Figura 10: Exemplo de um Cromossomo com três elementos.

Os indivíduos da população quântica são inicializados de modo que todos os elementos da lista tenham a mesma probabilidade de serem observados. Continuando com o exemplo anterior teríamos:

$$Q = \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ 1/3 & 1/3 & 1/3 \\ 1/3 & 1/3 & 1/3 \end{bmatrix}$$

Figura 11: Inicialização do Cromossomo da Figura 10.

Todos os indivíduos quânticos serão gerados, inicialmente, seguindo esta lógica. O tamanho da população quântica é definido pelo usuário. A população será atualizada no decorrer do algoritmo com a intenção de incrementar as probabilidades de serem observadas as características que geram soluções melhores.

4.3 Geração e atualização da População Clássica

A população clássica é composta por indivíduos clássicos, onde cada indivíduo clássico representa uma possível solução do problema. Neste caso, cada indivíduo clássico é uma lista com permutações da lista de espera original.

A população clássica, inicialmente, é gerada pela observação dos indivíduos quânticos. A cada geração é criada uma nova população clássica com o uso do operador crossover (Seção 3.1.1). Esta nova população pode conter indivíduos da geração anterior. Estes indivíduos podem ser mantidos por duas razões: devido ao elitismo (Seção 3.1.1) que define o percentual, de melhores indivíduos, que serão mantidos na população seguinte; e devido ao operador de crossover, o qual pode resultar na cópia direta dos pais para a nova geração em função da taxa definida de crossover.

Após a atualização dos indivíduos quânticos, uma nova população clássica é criada pela observação dos mesmos. Neste caso também é mantido um percentual da população anterior definido pelo parâmetro taxa de elitismo quântico (TxEQ).

4.3.1 Observação da População Quântica

Para a observação dos indivíduos da população quântica foram utilizados dois critérios diferentes. Eles são excludentes, e representam duas formas diferentes de abordar o problema em questão e as soluções geradas.

Em ambos critérios, cada indivíduo quântico vai ser observado n vezes, sendo n a relação entre o número de indivíduos clássicos (IC), que compõem a população clássica, e o número de indivíduos quânticos (IQ). Logo,

$$IC = n * IQ \quad (23)$$

O primeiro critério usado é o mesmo descrito na Seção 3.3.3. Seguindo esse procedimento, as soluções geradas podem ter qualquer ordem. Ou seja, o primeiro elemento da lista pode, perfeitamente, ser colocado na última posição da solução. É responsabilidade da função de avaliação punir, de alguma forma, este fenômeno.

O outro critério já garante que, nas soluções geradas, seja respeitada a prioridade do paciente. Tendo em consideração o estado de saúde do paciente, deseja-se que nenhum paciente com prioridade menor possa ser colocado à frente (na solução) de outro com prioridade maior. Dito com outras palavras e tomando como referência os estados definidos na Seção 2.3 (vide Figura 3), nenhum paciente com prioridade B, por exemplo, pode ser alocado antes de outro com prioridade A. É importante deixar claro que, neste caso, a alocação refere-se apenas à posição na lista e não à data em que poderá ser alocado no calendário de operações. É possível, por diferentes causas, que, no momento de posicionar um paciente no calendário, ele consiga uma data de atendimento mais próxima do que outro paciente que já estava no calendário. Este critério tem a vantagem de reduzir o espaço de busca com a adição desta restrição; por outro lado, este critério tem a desvantagem de tornar o algoritmo menos flexível.

O funcionamento deste último critério é bem simples. O primeiro passo consiste em calcular o número de pacientes com os diferentes estados de saúde. Por exemplo, supondo que há uma lista de 50 pacientes com: 5 no estado A, 10 no estado B, 10 no estado C, 10 no estado D e 5 no estado E. Logo, os 5 pacientes com estado A só podem estar nas primeiras 5 posições da lista, os 10 do estado B nas seguintes 10 e assim sucessivamente. Para realizar isto, é calculada a probabilidade acumulada das posições correspondentes aos estados e limitado o valor de r (ver Seção 3.3.3) a este valor; r é o valor aleatório gerado para a determinação do elemento a seleccionar. Deste modo só podem ser observadas as posições correspondentes aos estados. Seguindo com o exemplo, a matriz Q mostra um possível indivíduo quântico. A dimensão de Q , por ter 50 pacientes na lista, é de 50x50:

$$Q = \begin{bmatrix} \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \dots & \frac{1}{50} \\ \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \dots & \frac{1}{50} \\ \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \dots & \frac{1}{50} \\ \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \dots & \frac{1}{50} \\ \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \dots & \frac{1}{50} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \dots & \frac{1}{50} \\ \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \frac{1}{50} & \dots & \frac{1}{50} \end{bmatrix} \quad (24)$$

Como os 5 pacientes com estado A só podem estar nas 5 primeiras posições da lista, é calculada a probabilidade acumulada até a coluna 5. Esta probabilidade é $5 * \frac{1}{50} = 0.1$. Logo, é limitado o valor de $r = (0,0.1]$. Deste modo só é possível observar as 5 primeiras posições do indivíduo quântico. Se $r = 0.05$, por exemplo, é seleccionado o elemento 3. Em seguida são recalculadas as probabilidades de cada elemento e calculada a nova probabilidade acumulada para limitar novamente o valor de r . Baseando-nos nas equações apresentadas na Seção 3.3.3, a nova probabilidade acumulada é $4 * \frac{\frac{1}{50}}{1 - \frac{1}{50}} \approx 0,082$. O valor de r agora é limitado ao intervalo $(0,0.082]$. É gerado aleatoriamente um novo valor de r nessa faixa e seleccionado o elemento correspondente. A operação é repetida até observar os 5 primeiros elementos. A seguir, se devem observar os 10

No calendário (Figura 12) são alocadas todas as cirurgias seguindo a ordem apresentado na lista. Dada uma lista, seleciona-se o primeiro paciente para a primeira cirurgia; esta cirurgia é alocada no primeiro espaço de tempo onde se consiga a coincidência de todos os recursos necessários. Após ter alocado o primeiro procedimento, passa-se para o segundo paciente e assim sucessivamente. Deve ser destacado que os recursos devem ser compartilhados e, à medida que se vai avançando na alocação dos pacientes da lista, torna-se mais difícil conseguir a alocação dos mesmos. Caso não se consiga alocar uma determinada cirurgia em um determinado dia, passa-se para o dia seguinte. Este processo se repete até conseguir alocar a operação. A busca feita pelo algoritmo começa sempre no dia 1 para todas as cirurgias. É possível que um paciente, mesmo sendo o primeiro na fila, seja alocado, no calendário, em um tempo posterior a outra que se encontra numa posição posterior. Isto vai depender da disponibilidade dos recursos. Após ter preenchido o calendário com a alocação de todos os elementos da lista é calculada a aptidão da solução mediante a função de avaliação.

A função de avaliação é uma expressão matemática encarregada de avaliar o desempenho de cada indivíduo da população, premiando ou penalizando os diferentes critérios de uma determinada solução. Buscando a otimização (maximização ou minimização, segundo o problema) dessa função, o algoritmo evolui através das gerações para conseguir soluções melhores.

Os objetivos a serem atingidos pelas soluções geradas neste problema são: a redução do tempo total de alocação de todas as operações e o aumento na qualidade dos serviços fornecido aos pacientes. O primeiro objetivo é bem simples de representar. Após realizar a alocação de todos os pacientes, o tempo total é calculado. Matematicamente este objetivo é representado pela seguinte equação:

$$T_{cir} = T_f - T_i \quad (25)$$

Onde T_{cir} é o tempo total em dias necessário para que todas as operações sejam realizadas, T_i e T_f são o dia em que o primeiro paciente entra no calendário e o dia que o último paciente sai do mesmo, respectivamente.

O outro objetivo deverá ser subdividido em várias partes. É importante, para uma boa qualidade do serviço, diminuir o número de pacientes operados fora do prazo. Em caso de impossibilidade de realizar todas as operações no prazo, é importante reduzir o tempo médio que o paciente aguardará após o vencimento do seu prazo para ser atendido. A função de avaliação inclui as penalizações dessas situações. Outro aspecto importante, diretamente ligado à qualidade do serviço, é o corpo da área de saúde que realiza a cirurgia. Lembrando que os médicos possuem especialização em determinadas áreas, uma cirurgia realizada por um médico especialista na área do problema do paciente deverá oferecer menos riscos ao mesmo. Logo, é importante que, mediante a função de avaliação, as operações feitas por médicos não especialistas sejam penalizadas.

Existem três graus de especialização: no primeiro, o médico é o especialista principal dessa área; no segundo, o médico tem capacidade para fazer a cirurgia, porém com pouca prática nesse tipo específico de cirurgia; já no terceiro, o conhecimento do médico nessa especialidade só lhe permite realizar cirurgias de baixa complexidade. Assim, faz sentido não punir, em igual medida, as operações feitas por um médico de segundo grau na especialidade e as feitas por um de terceiro grau. As penalizações são descritas na Equação 26, a seguir:

$$p = k_1 * NFP + k_2 * T_{NFP} + k_3 * NOE_2 + k_4 * NOE_3 \quad (26)$$

onde NFP é o número de operações feitas fora do prazo; T_{NFP} é o tempo médio fora do prazo de tais operações; NOE_2 e NOE_3 são o número de operações feitas por especialistas de segundo e terceiro grau, respectivamente. Os parâmetros k_1, k_2, k_3 e k_4 são constantes de penalização e deverão ser indicadas pelo usuário. Deve-se indicar, a priori, que $k_2 > k_3$ devido ao grau de especialidade e $k_1 > k_2$ já que tem uma maior influência negativa a quantidade de operações feitas fora do prazo do que o tempo médio de atraso.

Após serem definidas as penalizações, e tendo em conta que o problema é de minimização, a função de avaliação é definida segundo a expressão (5):

$$f_a = k_0 * T_{Cir} + k_1 * NFP + k_2 * T_{NFP} + k_3 * NOE_2 + k_4 * NOE_3 \quad (27)$$

4.5 Atualização da população Quântica

A atualização da população quântica consiste na atualização de todos os indivíduos que a compõem. Esse processo já foi descrito na Seção 3.3.4. Como foi exposto, a intenção é aumentar a probabilidade de serem observados aqueles indivíduos, ou partes deles, que apresentam maior aptidão.

No modelo proposto foi acrescentada uma pequena modificação. São selecionados os k melhores indivíduos clássicos (IC) da população onde k , neste caso, é igual ao número de indivíduos quânticos menos um. Neste modelo é mantido um indivíduo quântico sem atualizar durante todo o processo. O objetivo é adicionar material genético que possibilite fugir de um mínimo local se for necessário. Antes de usar os indivíduos clássicos para a atualização, eles são embaralhados com a intenção de diminuir a probabilidade de usar o mesmo IC, empregado em atualizações anteriores, para atualizar o mesmo IQ.

A taxa de atualização ε (Equação 19) é um dos parâmetros a definir. Ela depende do tamanho da lista de espera. Em 3.4.4 se discute o intervalo de valores que esta taxa pode ter, além de descrever o que pode ocorrer caso ela seja muito grande ou muito pequena. Evidentemente, esta classificação dependerá do valor que se tome por referência. Normalmente, as listas de espera, nas unidades de saúde, são da ordem de milhares. Isto implica que a probabilidade inicial nos elementos dos indivíduos quânticos deva ser muito pequena ($1/\text{número de elementos da lista}$). Logo, este será o valor que se tomará como referência para definir o valor da taxa de atualização. Na Seção 5.3.1, se aborda novamente este tema no estudo de caso.

5. Estudo de Caso

5.1 Introdução

Para o estudo de caso foi criada uma base de dados que tenta simular o cenário real de uma Unidade Cirúrgica. Nela se encontra, além da lista de procedimentos cirúrgicos a serem programados, a disponibilidade de todos os recursos (materiais e humanos) envolvidos no processo.

Uma vez gerada a base de dados, foram feitos vários testes para analisar a influência, dos diferentes critérios de avaliação expostos na Seção 4.4, no resultado final. Também foi alterado o número de recursos disponíveis para determinar o impacto dos mesmos na redução do tempo total dos atendimentos. Tendo em conta que alguns recursos tem um custo financeiro, estas análises podem indicar priorização de investimentos em uma ou mais etapas envolvidas.

A seguir será detalhada a base de dados gerada e, logo depois, os resultados obtidos são apresentados.

5.2 Base de Dados

A base de dados é composta por uma lista de 2000 procedimentos com diferentes tipos de cirurgias, complexidade e tempo de uso dos diferentes recursos. A Unidade de Saúde simulada, conta com 10 salas de cirurgia, 10 leitos pré-operatórios, 15 leitos de CTI e 25 leitos em enfermaria. Conta também com 30 médicos especialistas, 10 instrumentistas e 10 anestesistas.

Os códigos para a geração da base de dados foram feitos no sistema MatLab (versão R2016B) e possibilita alterar facilmente qualquer valor da mesma. Este código também representa um aporte deste trabalho, já que possibilita a simulação, bastante próxima à realidade, de uma Unidade de Saúde. Nas seções seguintes serão detalhados todos os aspectos da base de dados.

5.2.1 Lista de espera

Como já foi dito na introdução, a lista de espera é composta por 2000 elementos. As cirurgias encontram-se divididas em 15 especialidades e, dentro de cada especialidade, temos diferentes tipos de cirurgias. Foram geradas no total 200 tipos diferentes de cirurgias. A Tabela 2 mostra os percentuais dos tipos de cirurgia, por especialidade, usados na simulação. Lembrando que todos os valores podem ser modificados no código facilmente.

Especialidade	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Percentual [%]	10	5	12	5	15	10	8	5	5	2	3	10	5	3	2

Tabela 2: Percentual de Tipo de cirurgia por especialidade

Primeiramente foi gerada uma matriz, denominada *Caraterísticas das Cirurgias (CC)*, tendo por colunas: o tipo de cirurgia com a complexidade e tempo de duração da mesma. Possui também, a quantidade de médicos especialistas, instrumentistas e anestesistas necessários para sua realização. A atribuição da quantidade de pessoal necessário na cirurgia segue a seguinte lógica:

- **Médicos Especialistas:** Se a complexidade não é alta e o tempo é menor ou igual a duas horas, o procedimento só exige um médico Especialista. Em qualquer outro caso, serão necessários dois médicos.
- **Instrumentistas:** Se a complexidade é baixa e o tempo é menor ou igual a duas horas, somente será alocado um Instrumentador. Em qualquer outro caso, serão necessários dois instrumentadores.
- **Anestesistas:** Se a complexidade é baixa e o tempo é igual a 1 hora só precisará de um médico Anestesista. Em qualquer outro caso, serão necessários dois médicos anestesistas.

A lógica descrita acima pode ser modificada de acordo com o protocolo de cada Unidade de Saúde.

A complexidade pode ser: alta, média ou baixa e os tempos estão no intervalo de 1 hora até 5 horas de duração. As Tabelas 3, e 4 mostram os percentuais do total destes valores. Estes percentuais podem ser ajustados facilmente.

Complexidade	Percentual [%]
Alta	30
Meia	50
Baixa	20

Tabela 3: Percentual de Tipo de cirurgia para cada Complexidade.

Tempo de Cirurgia [h]	Percentual [%]
1	15
2	20
3	25
4	25
5	15

Tabela 4: Percentual de Tipo de cirurgia para cada Tempo.

A Tabela 5 mostra um exemplo da matriz *Caraterísticas das Cirurgias (CC)*:

Tipo de Operação	Especialidade	Complexidade	Tempo	Med. Esp.	Inst.	Anestesista
1	1	Alta	5	2	2	2
2	5	Baixa	2	1	1	2
3	10	Alta	4	2	2	2
4	8	Meia	1	1	2	2
5	2	Baixa	3	2	2	2
...
200	8	Alta	5	2	2	2

Tabela 5: Exemplo da Matriz CC.

Após construir a matriz CC, é criada outra matriz denominada *Características dos Pacientes (CP)*. Para isso, é gerada uma lista com os 2000 pacientes e suas idades. As idades estão entre 5 e 75 anos e são geradas aleatoriamente, seguindo uma distribuição discreta crescente. A probabilidade de ser selecionada uma idade é diretamente proporcional a ela, ou seja, aumenta à

medida que aumenta a idade. Em seguida é gerada aleatoriamente um tipo de operação, dentre as 200 possíveis, para cada paciente e a prioridade do paciente, de acordo a sua condição médica. Este sistema de prioridade foi explicado na Seção 2.3. A Tabela 6 mostra os diferentes percentuais do total destas prioridades.

Prioridade	A	B	C	D	E
Percentual [%]	10	25	30	25	10

Tabela 6: Percentual do total de procedimentos para cada Prioridade.

Só resta, para completar a matriz *CP*, a data de entrada e os tempos nos leitos de pré-operatório (de 1 até 4 horas), CTI (de 0 até 48 horas) e enfermaria (de 24 até 96 horas).

Os períodos de tempos nos diferentes leitos seguem a seguinte lógica:

Tempo de uso dos leitos Pré-operatórios (TPreO):

- Se a complexidade é baixa, o tempo de cirurgia é menor do que 3 horas e a idade está entre 16 e 55 anos, então TPreO = 1 hora.
- Se a complexidade é média, o tempo de cirurgia é maior do que 2 horas e o paciente tem menos de 16 ou mais de 55 anos, então TPreO = 3 horas.
- Se a complexidade é alta, o tempo de cirurgia é menor ou igual a 3 horas, então TPreO = 3 horas.
- Se a complexidade é alta, o tempo de cirurgia é maior do que 3 horas, então TPreO = 4 horas.
- Em qualquer outro caso, TPreO = 2 horas.

Tempo de uso dos leitos do CTI (TCTI) e de Enfermaria (TE):

- Se a complexidade é baixa, o tempo de cirurgia é menor do que 3 horas e a idade está entre 16 e 55 anos, então TCTI=0 horas e TE=24 horas.
- Se a complexidade é média, o tempo de cirurgia é maior do que 2 horas e a idade está entre 16 e 55 anos, então TCTI=24 horas e TE=48 horas.
- Se a complexidade é média, o tempo de cirurgia é maior do que 2 horas e o paciente tem menos de 16 ou mais de 55 anos, então TCTI=24 horas e TE=72 horas.
- Se a complexidade é alta, o tempo de cirurgia é maior do que 2 horas e a idade entre 16 e 55 anos, então TCTI=48 horas e TE=72 horas.

- Se a complexidade é alta, o tempo de cirurgia é maior do que 2 horas e o paciente tem menos de 16 ou mais de 55 anos, então TCTI=48 horas e TE=96 horas.
- Em qualquer outro caso, TCTI=8 horas e TE=24 horas.

A data de entrada é gerada com o seguinte procedimento: foi definido um número máximo de entradas por dia (no caso 30). Esse seria o número de entradas no dia 1, logo foram gerados números aleatórios entre 1 e o máximo de entradas definido por dia, até que a soma de todos os números gerados fossem 2000. Caso a soma com o último número aleatório fosse superior a 2000, a diferença era descontada do valor de entradas do primeiro dia, para garantir que a soma fosse sempre 2000. Um exemplo pode ser dado, considerando que há uma fila de espera com 10 operações e o número máximo de entradas por dia são 3, então tem-se 3 no primeiro dia e geramos aleatoriamente os números 2, 2, 2 e 3. Como a total é igual a 12, a diferença com o número total de operações (2) é descontada do primeiro dia e a distribuição de pacientes passa a ser 1,2,2,2 e 3, respectivamente por dia, totalizando 5 dias. Depois de se fazer esta distribuição de entradas de pacientes, elas são embaralhadas e anexadas na matriz CP. Em seguida, a matriz é organizada de forma cronológica, tomando como referência a data de entrada. A Tabela 7 mostra um exemplo dessa matriz.

Num. Op.	Data Ent.	Prioridade	Tipo Op.	Idade	TPreO	TCTI	TE
1	1	A	20	23	2	-	24
2	1	B	18	31	3	8	48
3	1	E	168	45	1	8	24
4	2	C	62	67	2	24	72
...
2000	132	A	147	57	4	24	96

Tabela 7: Exemplo da Matriz CP.

5.2.2 Recursos Humanos

Como já foi exposto em seções anteriores, dentre os recursos humanos encontram-se os Médicos Especialistas (ME), os Instrumentadores (I) e os Anestesistas (A). Os ME apresentam diferentes graus de conhecimentos nas diferentes especialidades. Os Instrumentadores e Anestesistas, por sua vez, também apresentam certo grau de especialização nas diferentes especialidades, mas são mais flexíveis. Enquanto os ME só são especialistas principais de uma especialidade, aqueles são especialistas em várias especialidades. Esta distribuição será representada nas matrizes de especialização dos diferentes profissionais. A Tabela 8 mostra a relação entre os ME e as diferentes especialidades.

ME/Esp.	1	2	3	4	5	6	7	8	9	10	11	...	15
1	1	0	2	0	0	0	3	0	0	2	0	...	0
2	0	1	3	0	0	0	2	0	3	2	0	...	0
3	0	3	1	0	0	0	0	0	0	3	2	...	0
4	0	0	0	1	0	2	0	0	0	0	0	...	2
...
30	0	2	0	3	2	0	0	2	2	0	2	...	1

Tabela 8: Médico Especialista vs Especialidade.

Observando a Tabela 8, nas linhas tem-se os diferentes ME e nas colunas as especialidades. O número 1, no corpo da Tabela, indica que o médico é o especialista principal dessa especialidade, o 2 que o médico tem capacidade para fazer a cirurgia, porém com pouca prática nesse tipo de cirurgia, e o número 3 que o conhecimento do médico nessa especialidade só lhe permite realizar cirurgias de meia ou baixa complexidade. Pode-se observar que há dois ME principais por especialidade para um total de 30. A matriz foi gerada de modo que existam dois especialistas principais por especialidade, 40% da matriz tenha grau 2 e 15% seja 3.

Para a criação das matrizes de especialização dos Instrumentadores e dos Anestesistas foi usada a mesma lógica, mas considerando o fato de possuir mais especialidades com grau 1. A Tabela 9 mostra um exemplo para os

Instrumentadores. A matriz dos Anestesiistas não foi representada por ser similar à de Instrumentadores.

I/Esp.	1	2	3	4	5	6	7	8	9	...	15
1	1	2	1	1	1	1	2	1	3	...	1
2	1	2	1	1	2	1	1	1	1	...	1
3	1	1	1	2	2	1	1	1	2	...	1
4	3	1	1	1	2	1	2	2	1	...	1
...
10	2	1	1	1	2	1	3	1	1	...	1

Tabela 9: Instrumentistas vs Especialidade.

Pode-se observar que os Instrumentadores e os Anestesiistas podem realizar a maior parte dos tipos de cirurgia. Tanto a matriz dos Instrumentadores como a dos Anestesiistas foi gerada de modo que o 20% seja grau 2 e o 5% seja 3.

Além destas matrizes, também foi criada uma matriz de disponibilidade, onde se limita alguns médicos especialistas a trabalhar certos dias da semana. Por exemplo, os especialistas principais das especialidades 3,5 e 6 trabalham todos os dias, enquanto os médicos especialistas das outras especialidades trabalham apenas um dia na semana. A matriz de disponibilidade é apresentada a seguir na Tabela 10. O número “1” indica que o médico trabalha nesse dia e o “0”, caso contrário.

Dia\ME	1	2	3	4	5	6	7	...	30
Segunda	1	0	1	0	1	1	0	...	0
Terça	0	1	1	0	1	1	0	...	0
Quarta	0	0	1	1	1	1	0	...	0
Quinta	0	0	1	0	1	1	1	...	0
Sexta	0	0	1	0	1	1	0	...	0
Sábado	0	0	1	0	1	1	0	...	1

Tabela 10: Disponibilidade dos ME por dia da semana.

É importante dizer que as cirurgias só podem ser feitas nos dias de semana das 8 horas até às 20 horas e aos sábados até às 16 horas.

5.2.3 Recursos Materiais

Como já foi dito, dentro dos recursos materiais encontram-se os leitos pré-operatórios, os leitos de CTI, os leitos de enfermagem e as salas cirúrgicas. Estes, como os recursos humanos, possuem restrições.

No caso dos recursos materiais, não existe um grau de “adequação”, simplesmente poderá ou não ser alocado nele um determinado procedimento. Logo, a matriz de disponibilidade, indica com o valor “1” no caso que o recurso possa ser usado e “0” no caso contrário. A matriz tem nas linhas o recurso e nas colunas as diferentes especialidades. A seguir é apresentado um exemplo da matriz de disponibilidade das salas de cirurgias.

SC\Esp.	1	2	3	4	5	6	7	8	9	...	15
1	0	0	1	0	1	1	0	1	0	...	1
2	1	0	1	1	0	1	1	0	1	...	1
...
5	0	1	1	1	0	1	0	1	1	...	1

Tabela 11: Salas Cirúrgicas vs Especialidade.

A matriz de disponibilidade das salas de cirurgias foi gerada de modo que o 80% tem valor “1”. As matrizes de disponibilidade dos leitos pré-operatório, CTI e enfermagem seguem a mesma lógica, onde o 90%, 90% e 95% tem valor “1” respectivamente.

5.2.4 Calendário

Foi gerado também um calendário com os dias divididos em intervalos de uma hora. O calendário começa no dia 1/1/2017 e vai até 31/12/2018. Foi tomado um prazo de dois anos por ser tempo suficiente para alocar todas as cirurgias da simulação proposta. Este período pode ser alterado no código. Nesse calendário

desempenho como ponto de partida do modelo desenvolvido. Este planejamento será chamado de Caso Base no resto do trabalho.

Nos dois primeiros experimentos, foi tomado como critério de avaliação, no modelo proposto, somente o tempo total de alocação de todas as cirurgias. Isso é equivalente a dizer que na Equação 28 o único coeficiente diferente de zero é k_0 . A intenção é conhecer a capacidade de minimização, do tempo total para alocação dos pacientes pelo modelo, considerando o tempo gasto no Caso Base. Foram usados, separadamente (um para cada experimento), os dois critérios de observação abordados na Seção 4.3.1, a Observação com Ordem e a Observação sem Ordem. A equação 27 é repetida na 28 para facilitar a compreensão da calibração da função de avaliação do modelo desenvolvido.

$$f_a = k_0 * T_{Cir} + k_1 * NFP + k_2 * T_{NFP} + k_3 * NOE_2 + k_4 * NOE_3 \quad (28)$$

Um terceiro experimento é executado considerando somente o aporte do número de cirurgias fora do prazo ($k_0 = k_2 = k_3 = k_4 = 0, k_1 = 1$) na função de avaliação (Equação 28). Por ser esta uma característica crítica, no momento de fazer o planejamento das cirurgias, decidiu-se evoluir o modelo tomando somente seu aporte para avaliar qual seria seu menor valor.

Os resultados obtidos nestes experimentos foram comparados com o Caso Base e com um outro critério de ajuste da lista de espera de cirurgias usado por Testi e Tanfani em [27]. Neste critério, se reorganiza a lista original considerando a data de entrada do paciente na lista e a condição médica do mesmo (ver Seção 2.3). Para fazer isto, é calculado um índice denominado NAWD (Need Adjusted Waiting Day) ou ajuste necessário do tempo de espera. Seu valor é determinado pela Equação 29:

$$NAWD_i = P_i * te_i \quad P_i \in \{1,2,4,12,48\} \quad (29)$$

Onde te_i é o tempo que o paciente permanece na fila e P_i é um fator associado aos estados dos pacientes abordados na Seção 2.3. O valor “1” corresponde à categoria E, o “2” corresponde à D, e assim sucessivamente. Após ter se calculado este índice para cada paciente, a lista é organizada do maior valor de NAWD ao menor. Esta solução será chamada de Caso Base 2 (CB2). Não foi

usado um critério brasileiro de ordenamento de listas de espera por não ter sido encontrado na literatura.

Outro experimento propõe uma configuração da função de avaliação, que tenta alcançar uma proporção entre todos os objetivos de interesse. O resultado do uso desta função é comparado com os experimentos anteriores. É importante mencionar que a proporção atribuída a cada objetivo é definida a partir da opinião dos autores deste trabalho, e não de um especialista no tema.

Finalmente, partindo da configuração base da unidade cirúrgica gerada na base de dados, são acrescentados e reduzidos alguns dos recursos materiais com a intenção de ver seu efeito no tempo total de alocação de todas as cirurgias. Esta informação poderia ser muito importante para o administrador de uma unidade de saúde, já que define os pontos críticos do processo. Considerando, por exemplo, que o hospital possua uma verba para empregar em algum ponto da cadeia de recursos visando reduzir o tempo de fila. Inicialmente poderia se acreditar que aumentando o número de salas de cirurgia, poderia se diminuir o tempo total de atendimento aos pacientes da fila, mas, após se realizar a simulação, pode se verificar que o aumento dos leitos de CTI é que provocaria a redução do tempo desejada. Com esta análise pode-se avaliar o potencial de investimento com relação à proporção de tempo que cada investimento poderia trazer quando aplicado a algum dos pontos do processo de atendimento dos pacientes.

Estão resumidamente, na Tabela 12, as características principais da base de dados. A seguir, serão apresentados todos os resultados obtidos.

Descrição	Quantidade
Cirurgias	2000
Leitos Pré-operatórios	10
Salas de Cirurgias	10
Médicos Especialistas	30 (2 por especialidade)
Instrumentalistas	10
Anestesistas	10
Leitos de CTI	15
Leitos de Enfermagem	25

Tabela 12: Configuração da Unidade de Saúde.

Experimento 1:

No primeiro experimento foi usada a Observação sem Ordem (ver Seção 4.3.1), tomado como critério de avaliação somente o tempo total de alocação das cirurgias. Isto é equivalente a dizer que as constantes k_1 , k_2 , k_3 e k_4 da função de avaliação apresentada na Seção 4.4 (Equação 28) tem valor. Mesmo não tendo em conta, na hora de medir a aptidão das soluções, o resto dos parâmetros da função de avaliação foi calculado. Após testar diferentes configurações identificou-se que o parâmetro mais sensível é a taxa de atualização do indivíduo quântico (ϵ). Como foi mencionado na Seção 3.4.4, valores muito grandes provocam a saturação do indivíduo e muito pequenos fazem com que o algoritmo não evolua. No problema em questão, dado que a lista é composta por 2000 elementos, as probabilidades iniciais de serem observados os elementos da lista no indivíduo quântico são muito pequenas (1/2000) (ver Seção 4.2). Logo, a taxa de atualização tem que ser da ordem do centésimo de milésimo. Este valor, em comparação com as probabilidades mencionadas, não é pequeno.

Foram testadas diferentes configurações do algoritmo, alterando-se seus parâmetros. Na Tabela 13 se apresenta a configuração que obteve os melhores resultados, a maioria das siglas podem se conferir na Seção 4.1.

Parâmetro	Valor
numIQ	5
numIC	20
TxC	0,9
TxE	50%
TxEQ	10%
Ger2Act	5
ϵ (ver Seção 3.4.4)	$1 * 10^{-5}$
numGer	50
k_0	1
k_1, k_2, k_3, k_4	0

Tabela 13: Configuração do AEIQ-AS para o experimento 1.

O uso de um número menor de indivíduos quânticos (numIQ) ou clássicos (numIC) tem como consequência a não convergência do algoritmo em algumas execuções. Um número maior, por sua parte, não aportava nenhuma melhoria, e sim aumentava consideravelmente o tempo de execução. A taxa de crossover não foi um parâmetro crítico, sendo testados diferentes valores entre 0,7 e 0,9, e obtendo se sempre os mesmos resultados. Com um porcentual menor da taxa de elitismo (TxE), o algoritmo exigia mais gerações para convergir. A taxa de elitismo quântico (TxEQ) foi mantida em todos os experimentos. O objetivo em se manter a taxa é para que uma maior quantidade de indivíduos clássicos observados seja mantida na nova população clássica após a atualização da população quântica. O número gerações necessárias para atualizar a população quântica (Ger2Act) foi variado no intervalo entre 2 e 5. Quanto menor é o valor do parâmetro Ger2Act, maior é o tempo de computação do algoritmo. Foram testadas diferentes número de gerações (50,100,200). Após vários experimentos o número de gerações foi fixado em 50, já que o algoritmo sempre consegue convergir antes desse valor. Um número maior de gerações só produz um aumento no tempo total de processamento. Todos os indivíduos começam a tender à mesma solução levando o desvio padrão da população clássica a valores vem próximos de zero. Isto também traz como consequência a saturação dos indivíduos quânticos.

A Tabela 14 compara o Caso Base e CB2 com o resultado obtido no Experimento 1:

	$T_{Cir}[h]$	NFP	$T_{NFP}[D]$	NOE_2	NOE_3
Caso Base	6349	1066	78,81	1037	244
CB2	6181	1004	37,58	1118	258
Exp.1	5317	1049	78,53	1083	253

Tabela 14: Comparação do Caso Base, CB2 e o Experimento 1.

Lembrando que:

- T_{Cir} é o tempo total de alocação de todas as cirurgias;
- NFP é o número de operações fora do prazo;
- T_{NFP} é o tempo meio das operações fora do prazo;

- NOE_2 é o número de operações feitas por médicos especialistas de grau dois;
- NOE_3 é o número de operações feitas por médicos especialistas de grau três.

O modelo AEIQ-AS conseguiu reduzir o tempo total de alocação das cirurgias, tomando como referência o Caso Base em **1032 horas**, o que equivale a uma redução de **16,25%**. Estas horas são equivalente a 43 dias. Mesmo sem ter sido considerada na avaliação, a solução gerada apresenta uma diminuição no número de operações fora do prazo (17 cirurgias). Pode se apreciar também, em todos os casos, que uma grande parte das cirurgias são feitas por médicos de graus dois e três ($\approx 64,5\%$). Em comparação com a solução CB2, o Experimento 1 diminuiu o tempo total em 36 dias. No entanto, a solução CB2 apresenta um tempo médio de operações fora do prazo bem menor (52% menor), além de ter 45 menos operações fora do prazo menos. A curva da evolução, do melhor indivíduo por geração, do algoritmo é apresentada na Figura 14.

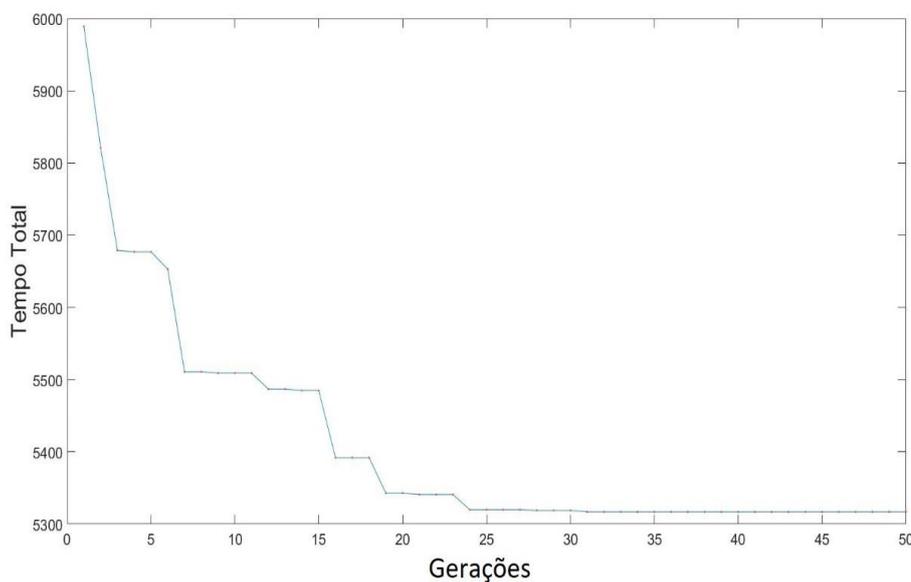


Figura 14: Curva de Evolução do melhor indivíduo no Experimento 1.

A Figura 15 mostra os valores médios e o desvio padrão, por gerações, da população clássica.

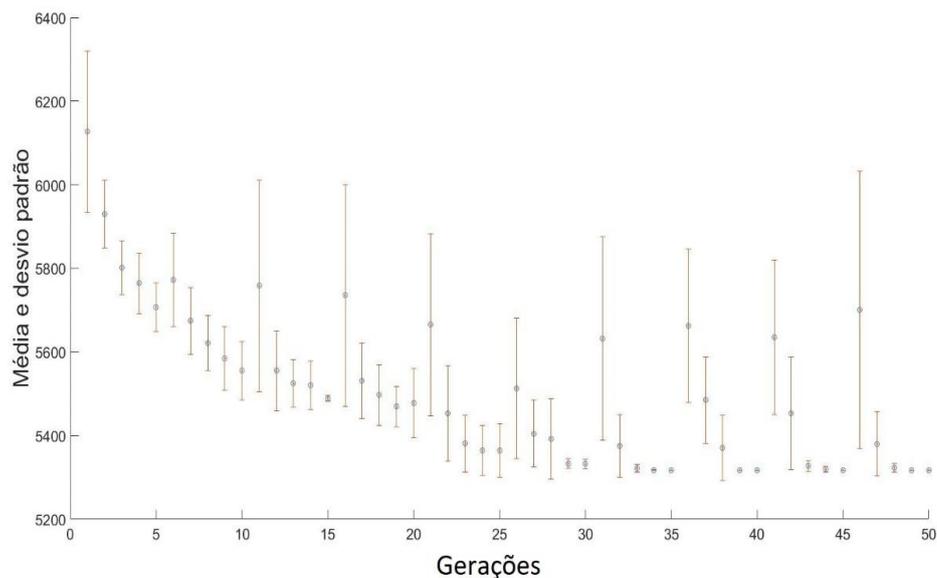


Figura 15: Valores médios e desvio padrão por geração.

Outra análise importante, é a avaliação dos tempos ociosos dos recursos materiais da solução. Ou seja, a quantidade de tempo em que os recursos ficam vazios. O tempo ocioso é calculado para cada tipo recurso separadamente. Este tempo será calculado como igual à diferença entre o tempo em que podem ser usados todos os recursos do mesmo tipo dado um tempo de alocação e o tempo calculado pela soma dos tempos necessários desses recursos para todos os procedimentos. No caso dos leitos pré-operatório, por exemplo, a soma dos tempos necessários de uso, desse tipo de leito, para os 2000 procedimentos é igual a 4871. Este valor é independente da ordem da lista. O tempo em que podem ser usados os recursos é calculado multiplicando a quantidade de semanas pelo tempo por semana e pela quantidade de leitos. O tempo em que podem ser usados os recursos é influenciado pelo ordenamento da lista já que depende do tempo total de alocação.

A Tabela 15 mostra este cálculo para o Caso Base e para o Experimento 1.

	Semanas	Tempo X Semana [h]	LPrO	Tempo total disponível [h]
Caso Base	37	68	10	25160
Exp. 1	31	68	10	21080

Tabela 15: Tempo disponível total do LPrO.

Lembrando que os LPrO podem ser usados de segunda a sexta das 8 horas da manhã até as 20 horas (12h) e aos sábados até as 16 horas. Se multiplicamos 12 por 5 dias e adicionamos as 8 horas do sábado resulta nas 68 horas por semana.

Tanto o tempo em que podem ser usados os recursos do Caso Base, como o do Experimento 1, é um pouco maior que o apresentado na Tabela 15. Para ser mais exato, o Caso Base demora 37 semanas, 5 dias e 13 horas para conseguir atender todos os pacientes. Logo, ao tempo total disponível (conforme Tabela 15), são adicionados as 480 horas ($4\text{dias} \times 12\text{horas} \times 10\text{leitos}$) correspondentes aos dias. São tomados só 4 dias dos 5 já que o primeiro dia é domingo e este tipo de leitos não estão disponíveis. Das 13 horas restantes são tomadas em consideração 5 ($13 - 8 = 5$) já que os leitos só estão disponíveis a partir das 8 horas da manhã. Cinco horas por 10 leitos totaliza 50 horas. Dessa forma, o tempo total disponível é 25213 horas. O tempo consumido pela alocação dos pacientes feita pelo Experimento 1 é 31 semanas, 4 dias e 13 horas. Seguindo o mesmo procedimento usado no Caso Base, o tempo total disponível dos LPrO é 21121 horas. A Tabela 16 mostra o valor do tempo ocioso dos LPrO:

	Tempo total disponível [h]	Tempo de uso dos LPrO [h]	Tempo do LPrO vazio [h]
Caso Base	25690	4871	20819
Exp. 1	21490	4871	16619

Tabela 16: Tempo ocioso dos LPrO para o Caso Base e o Experimento 1.

O Experimento 1 tem uma redução no tempo ocioso dos LPrO de 4200 horas, valor que representa uma melhoria de 20% aproximadamente.

As mesmas análises foram feitas para o resto dos recursos materiais. Os resultados obtidos são apresentados na Tabela 17.

	Tempo total disponível [h]		Tempo de uso [h]	Tempo vazio [h]		Diff.	[%]
	CB	Exp. 1	[h]	CB	Exp. 1		
	SO	25690	21490	6072	19618	15418	4200
LCTI	94755	79275	40984	53771	38291	15480	28,79
LE	157925	132125	94584	63341	37541	25800	40,43

Tabela 17: Tabela comparativa dos tempos ociosos dos recursos do Caso Base e o Experimento 1.

Pode se observar que os tempos são bem maiores nos leitos de CTI e enfermagem, tanto para o CB como para o Exp.1. Isto se deve ao fato de que eles estão disponíveis 24 horas por dia. O tempo ocioso de todos os recursos foi reduzido em mais de um 20% no Experimento 1. Destaca-se a redução, no Experimento 1, do tempo em que os leitos de enfermaria estão vazios. Este teve uma melhoria de mais de **40%** em relação com o Caso Base. A Tabela 18 mostra a comparação dos mesmos parâmetros com CB 2.

	Tempo total disponível [h]		Tempo de uso [h]	Tempo vazio [h]		Dif. [h]	[%]
	CB 2	Exp. 1	[h]	CB 2	Exp. 1		
	LPrO	25010	21490	4871	20139	16619	3520
SO	25010	21490	6072	18938	15418	3520	18,59
LCTI	92235	79275	40984	51251	38291	12960	25,29
LE	153725	132125	94584	59141	37541	21600	36,52

Tabela 18: Comparativa dos tempos ociosos dos recursos do CB 2 e o Experimento 1.

Experimento 2:

No experimento 2 foi usado Observação com Ordem apresentada na Seção 4.3.1. A intenção era limitar o espaço de busca introduzindo uma restrição no momento de se gerar as soluções. Foi usada a mesma configuração do Experimento 1, mudando só o tipo de observação do indivíduo quântico. A Tabela 19 mostra a comparação deste experimento com o Caso Base e o CB2.

	$T_{Cir}[h]$	NFP	$T_{NFP}[D]$	NOE_2	NOE_3
Caso Base	6349	1066	78,81	1037	244
CB2	6181	1004	37,58	1118	258
Exp.2	5655	1034	38,7	1086	263

Tabela 19: Comparação do Caso Base e CB 2 com o Experimento 2.

Tomando como referência o Caso Base, o Experimento 2 apresenta uma redução no tempo total de alocação de todas as Cirurgias, além de ter menor quantidade de operações fora do prazo. Destaca-se a redução do tempo médio das operações fora do prazo (mais de um 50%). Em comparação com o CB 2, consegue manter bem próximo o tempo médio das operações fora de prazo apresentando uma redução no tempo total de alocação de todas as cirurgias. A Tabela 20 mostra a redução, com respeito ao Caso Base, nos tempos em que os recursos materiais estão sem uso.

	Tempo total disponível [h]		Tempo de uso [h]		Tempo vazio [h]		Dif. [%]
	CB	Exp. 2	CB	Exp. 2	CB	Exp. 2	
	LPrO	25690	22870	4871	20819	17999	
SO	25690	22870	6072	19618	16798	2820	14,37
LCTI	94755	84345	40984	53771	43361	10410	19,36
LE	157925	140575	94584	63341	45991	17350	27,39

Tabela 20: Comparativa dos tempos ociosos dos recursos do Caso Base e o Experimento 2.

Experimento 3:

No Experimento 3 foi mantida a configuração usada no Experimento 1, exceto pelos valores de k_0 e k_1 , que foram alterados para zero e um, respectivamente. O objetivo é tomar como critério de avaliação o número de cirurgias fora do prazo, e que o modelo AEIQ-AS determine o melhor valor para este parâmetro. Também foi preciso mudar o número de gerações para 100, pois

com as 50 gerações usadas nos experimentos anteriores, o modelo nem sempre convergia. A Tabela 21 mostra o resultado obtido.

Parâmetro	T_{Cir} [h]	NFP	T_{NFP} [D]	NOE_2	NOE_3
Caso Base	6349	1066	78,81	1037	244
Exp.3	5655	927	77,53	1062	291
Melhora [%]	-	13%	-	-	-

Tabela 21: Comparação do Caso Base com o Experimento 3.

O algoritmo conseguiu diminuir o número de operações fora do prazo em **13%** em comparação ao Caso Base. Este também reduz o tempo total em 694 horas. A Figura 16 mostra a curva de evolução do melhor indivíduo.

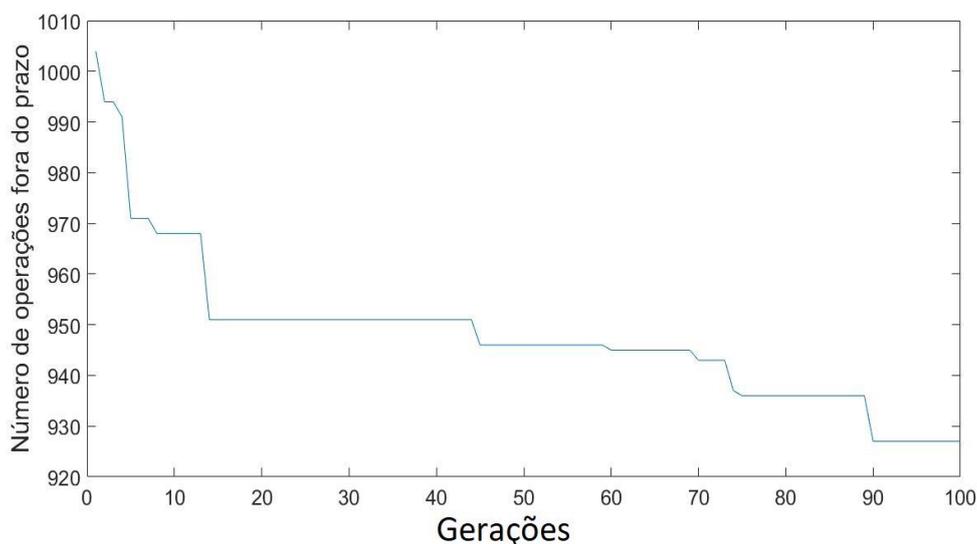


Figura 16: Curva de Evolução do melhor indivíduo no Experimento 3.

Mesmo sem ter sido considerado para a avaliação, foram calculados os parâmetros restantes da função de avaliação (Equação 28). O objetivo foi ver o comportamento dos outros parâmetros da função de avaliação na medida que o modelo evoluía. A Figura 17, por exemplo, mostra o tempo total do melhor indivíduo a cada geração.

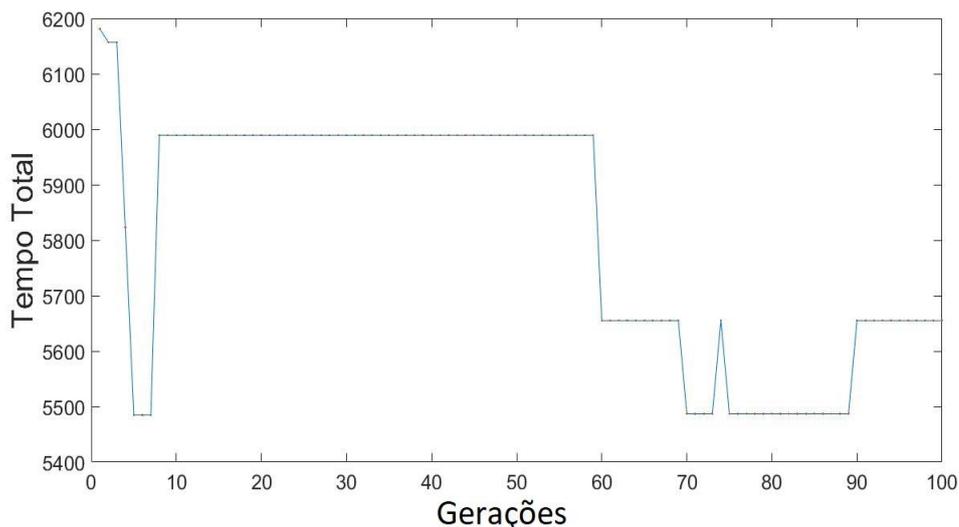


Figura 17: Tempo total do melhor indivíduo, por geração, do Experimento 3.

Pode se observar, misturando as figuras 16 e 17, que existem combinações dos parâmetros Tempo total (T_{Cir}) e número de operações fora do prazo (NFP) mais interessantes, mesmo sendo maior este último. Por exemplo, a geração 80, apresenta um tempo total de 5487 horas (gráfico da Figura 17) e 936 operações fora do prazo (gráfico da Figura 16). Esta poderia ser uma melhor combinação dependendo do critério do usuário.

Experimento 4:

Após ter visto, por separado, os melhores resultados obtidos pelo modelo AEIQ-AS para os parâmetros de maior interesse da função de avaliação, foi feita uma análise de como poderia se encontrar um equilíbrio entre eles. O critério usado foi que um dia a mais na alocação das cirurgias era equivalente a 10 operações fora do prazo. Visto de outro modo, só vale a pena se atrasar um dia no tempo total da alocação das cirurgias, se reduzir o número de operações fora do prazo em 10. O tempo médio de operações fora de prazo também é importante, mas, a partir dos testes realizados, foi visto que varia numa faixa pequena. Isto implica que este tempo não tenha um impacto significativo no resultado final. Os melhores valores deste índice são para listas próximas à lista organizada a partir do parâmetro NAWD, as quais apresentam valores de tempo total de alocação e

número de operações fora do prazo maiores. Dado que a maioria das operações foram feitas por médicos com segundo e terceiro grau de especialização, decidiu-se dar um peso baixo para eles. Finalmente a função de avaliação, calibrada com todos estes critérios, é apresentada na Equação 30.

$$f = 1 * T_{Cir} + 2,4 * NFP + 2 * T_{NFP} + 0,5 * NOE_2 + 0,2 * NOE_3 \quad (30)$$

Os resultados obtidos foram comparados com o Experimento 1 e o Experimento 3. Os mesmos são apresentados na Tabela 22.

	$T_{Cir}[h]$	NFP	$T_{NFP}[D]$	NOE_2	NOE_3
Experimento 1	5317	1049	78,53	1083	253
Experimento 3	5655	927	77,53	1062	291
Experimento 4	5319	962	81,67	1049	280

Tabela 22: Comparação dos Experimentos 1 e 3 com o Experimento 4.

Pode se observar como o algoritmo, usando os pesos da função de avaliação apresentados na Equação 30, conseguiu diminuir o número de operações fora do prazo, aumentando apenas duas horas do tempo total de alocação de todas as cirurgias.

Experimento 5:

No Experimento 5, foram testadas diferentes configurações da Unidade de Saúde. Mais especificamente foi alterado, para mais e para menos, o número unidades de cada recurso material em um 30%. O objetivo é observar seu efeito no resultado final. Em todos os casos foi calculado o tempo total para alocar todas as cirurgias, seguindo a lista inicial e a lista ordenada a partir do índice NAWD. Também foi executado o modelo AGEAS-IQ, com os mesmos parâmetros do Experimento 1.

O primeiro teste feito foi aumentar o número de leitos pré-operatórios. Aos 10 iniciais, adiciona se outros 3. A seguir foram feitos de novo todos os cálculos agora com três leitos pré-operatórios a menos (7 no total). Verificou-se, em ambos

casos, que estas mudanças não afetam, os resultados já obtidos anteriormente. Ou seja, o modelo converge aos mesmos resultados obtidos no Experimento 1. A mesma análise foi feita com as salas de cirurgias e, de igual modo, sua variação, não teve nenhum impacto no resultado final.

No caso dos leitos de CTI o aumento foi de cinco leitos e não produz nenhum efeito, mas, a diminuição, piorou o resultado obtido em relação aos experimentos anteriores. A Tabela 23 ilustra a comparação entre o Caso Base, CB2 e o Experimento 1, com os mesmos parâmetros calculados com esta nova configuração da unidade de saúde.

	$T_{Cir}[h]$	NFP	$T_{NFP}[D]$	NOE_2	NOE_3
Caso Base	6349	1066	78,81	1037	244
Lista inicial CTI-5	6853	1116	97,30	1074	282
CB2	6181	1004	37,58	1118	258
Lista NAWD CTI-5	6853	1257	48,52	1074	257
Experimento 1	5317	1049	78,53	1083	253
AEIQ-AS CTI-5	6183	1083	96,94	1069	248

Tabela 23: Comparação entre a configuração inicial e a mesma configuração com 5 leitos de CTI a menos.

A diminuição dos leitos de enfermaria (8 leitos a menos), por sua vez, teve como consequência os resultados apresentados na Tabela 24.

	$T_{Cir}[h]$	NFP	$T_{NFP}[D]$	NOE_2	NOE_3
Caso Base	6349	1066	78,81	1037	244
Lista inicial Emf-8	7021	1209	103,47	1117	259
CB2	6181	1004	37,58	1118	258
Lista NAWD Emf -8	7021	1403	51,74	1117	257
Experimento 1	5317	1049	78,53	1083	253
AEIQ-AS Emf -8	6543	1188	102,64	1099	260

Tabela 24: Comparação entre a configuração inicial e a mesma configuração com 8 leitos de Enfermagem a menos.

Como pode se apreciar na Tabela 24, esta mudança (redução dos leitos de enfermaria) afeta negativamente os resultados obtidos em experimentos anteriores.

O aumento dos leitos de enfermagem também teve um efeito nos resultados finais. Os mesmos são apresentados na Tabela 25.

	$T_{Cir}[h]$	NFP	$T_{NFP}[D]$	NOE_2	NOE_3
Caso Base	6349	1066	78,81	1037	244
Lista inicial Emf+8	6181	1029	74,56	1053	260
CB2	6181	1004	37,58	1118	258
Lista NAWD Emf +8	6181	965	35,6	1045	260
Experimento 1	5317	1049	78,53	1083	253
AEIQ-AS Emf +8	5317	995	74,20	1093	262

Tabela 25: Comparação entre a configuração inicial e a mesma configuração com 8 leitos de Enfermagem a mais.

Com esta modificação se conseguiu reduzir, como pode-se constatar na Tabela 25, o tempo total de alocação da fila de pacientes original, além de diminuir o número de operações fora de prazo. O tempo de total da fila organizada a partir do parâmetro NAWD foi mantida, mas obteve um número de operações fora de prazo menor. O resultado obtido pelo modelo AEIQ-AS também apresenta uma redução no número de operações fora de prazo com respeito aos obtidos no Experimento 1.

Após destes testes poderia-se concluir, neste caso em particular, que os leitos de CTI e Enfermagem são o ponto crítico no processo de alocação das cirurgias, dada a configuração inicial.

5.4 Conclusões

Foram feitos vários testes que mostram a flexibilidade do algoritmo proposto neste trabalho. Foi tomado como caso base o ordenamento original da fila. Também foi implementado o ordenamento da lista de espera a partir do índice NAWD proposto em [27] para comparar os resultados obtidos pelo modelo desenvolvido. Em todos os experimentos feitos, o modelo conseguiu melhorar o

tempo de espera na fila, otimizando o resultado em relação ao Caso Base. O melhor resultado foi obtido no Experimento 4, onde se conseguiu um equilíbrio entre os principais pesos dados aos objetivos para se alocar as cirurgias. O Experimento 4 consegue diminuir o tempo total de alocação em 16,22% e o número de operações fora do prazo em 9,76% simultaneamente. A simulação da Unidade de Saúde, usando a ferramenta desenvolvida, possibilitou conhecer o efeito que produziriam as variações nas quantidades dos diferentes recursos materiais.

6. Conclusões e Trabalhos Futuros

6.1 Conclusões

Em cumprimento do objetivo principal deste trabalho, foi criado um modelo, baseado em algoritmos genético com inspiração quântica, para a automatização e otimização do planejamento de procedimentos cirúrgicos eletivos. O modelo otimiza o ordenamento da fila de espera e conseguiu reduzir o tempo total do atendimento em 1032 horas, o que corresponde ao 16,25% do tempo inicialmente alocado simplesmente fazendo a alocação cronológica da fila. Também reduz o tempo em que os recursos materiais estão ociosos em mais de 20% alcançando 40,43% no caso dos leitos de enfermaria.

O modelo AEIQ-AS conseguiu convergir sempre em um número reduzido de gerações e, por ser quanticamente inspirado, precisa de uma população, tanto quântica como clássica, relativamente pequena. Possui um tempo de execução relativamente pequeno (40 horas no caso de estudo) o que permite sua execução uma vez por semana possibilitando cobrir espaços criados no calendário por diferentes motivos.

Foram realizados vários testes mostrando a flexibilidade do algoritmo para alcançar o objetivo do usuário, tendo em consideração seus critérios no momento de designar pesos aos diferentes parâmetros da função de avaliação. Os parâmetros da função de avaliação são conflitantes, e cada Unidade de Saúde deverá definir suas prioridades. Uma possível configuração de pesos é apresentada no Experimento 4. Este experimento conseguiu obter, simultaneamente, uma redução do tempo total de 1030 horas e uma redução do número de operações fora do prazo em 99 operações. Estes valores são próximos dos conseguidos pelo modelo nos experimentos 1 e 3, onde se usa como critério de avaliação, separadamente, o tempo máximo de alocação e o número de operações fora do prazo.

A observação dos indivíduos quânticos utilizando o critério de Observação com ordem (Seção 4.3.1) conseguiu reduzir o tempo máximo de alocação das cirurgias em apenas 10,93%. Isto pode ser resultado da redução do espaço de busca pela restrição imposta para gerar possíveis soluções. Mesmo não

alcançando valores de tempo de alocação próximos aos obtidos com o uso do critério de *Observação sem ordem*, é importante destacar que os resultados apresentam um tempo médio de operações fora prazo bem menor. Estes resultados (com uso do critério de *Observação com ordem*) são muito próximos ao alcançado pela lista reorganizada a partir do índice NAWD proposto em [27].

Além do antes exposto, foi criada uma ferramenta que permite a simulação, de modo simplificado, de uma Unidade Cirúrgica de Saúde. Esta simulação possibilita a realização de uma análise das possíveis configurações de recursos da unidade de saúde e seu impacto no serviço. Representando, assim, uma boa ferramenta para o planejamento dos investimentos já que possibilita detectar os recursos críticos em um determinado processo.

Finalmente, em resposta a um dos objetivos secundários, o algoritmo desenvolvido gera um calendário (schedule) com o planejamento de todos os recursos envolvidos no processo cirúrgico. A partir dele pode se determinar o horário de trabalho de todo o pessoal médico envolvido no processo, assim como o planejamento temporal dos recursos materiais.

Todas estas funcionalidades são facilmente adequadas para o planejamento de outros processos de uma Unidade de Saúde.

6.2 Trabalhos Futuros

As seguintes oportunidades de trabalhos futuros podem ser destacadas a partir deste trabalho:

Usar o algoritmo proposto num entorno real ou agregar a visão de um especialista na administração de Unidades de Saúde.

A criação de uma interface mais amigável do software de modelagem e de otimização, permitindo que o usuário final não precise de qualquer conhecimento a respeito de programação de softwares ou mesmo conhecimento na área de inteligência computacional para seu uso.

A implementação de um modelo baseado em Lógica Fuzzy para fornecer um apoio aos profissionais de saúde encarregados de gerar as prioridades dos pacientes a partir de seu estado de saúde. Além disso, na modelagem da unidade de Saúde, o estabelecimento dos tempos nos diferentes leitos e a quantidade de

recursos humanos necessário para cada procedimento cirúrgico também poderiam se beneficiar da Lógica Fuzzy.

7. Referências bibliográficas

- [1] P. Santibáñez, M. Begen, and D. Atkins, “Surgical block scheduling in a system of hospitals: an application to resource and wait list management in a British Columbia health authority.,” *Health Care Manag. Sci.*, vol. 10, no. 3, pp. 269–282, Sep. 2007.
- [2] F. Dexter and A. Macario, “Changing Allocations of Operating Room Time From a System Based on Historical Utilization to One Where the Aim is to Schedule as Many Surgical Cases as Possible,” *Anesth. Analg.*, vol. 94, no. 5, pp. 1272–1279, May 2002.
- [3] S. Milgram, H. J. Liberty, R. Toledo, and J. Wackenhut, “Response to intrusion into waiting lines.,” *J. Pers. Soc. Psychol.*, vol. 51, no. 4, pp. 683–689, 1986.
- [4] B. Cardoen, E. Demeulemeester, and J. Beliën, “Operating room planning and scheduling: A literature review,” *Eur. J. Oper. Res.*, vol. 201, no. 3, pp. 921–932, Mar. 2010.
- [5] J. M. Molina Pariente, J. M. Framinan Torres, and T. Gomez Cia, “Policies and decision models for solving elective case Operating Room scheduling,” in *2009 International Conference on Computers & Industrial Engineering*, 2009, pp. 112–117.
- [6] M. Lamiri, X. Xie, A. Dolgui, and F. Grimaud, “A stochastic model for operating room planning with elective and emergency demand for surgery,” *Eur. J. Oper. Res.*, vol. 185, no. 3, pp. 1026–1037, Mar. 2008.
- [7] J. Beliën, E. Demeulemeester, and B. Cardoen, “A decision support system for cyclic master surgery scheduling with multiple objectives,” *J. Sched.*, vol. 12, no. 2, pp. 147–161, Apr. 2009.
- [8] B. Cardoen, E. Demeulemeester, and J. Beliën, “Optimizing a multiple objective surgical case sequencing problem,” *Int. J. Prod. Econ.*, vol. 119, no. 2, pp. 354–366, Jun. 2009.
- [9] D.-N. Pham and A. Klinkert, “Surgical case scheduling as a generalized job shop scheduling problem,” *Eur. J. Oper. Res.*, vol. 185, no. 3, pp. 1011–1025, Mar. 2008.
- [10] H. Saadouli, B. Jerbi, A. Dammak, L. Masmoudi, and A. Bouaziz, “A stochastic optimization and simulation approach for scheduling operating

- rooms and recovery beds in an orthopedic surgery department,” *Comput. Ind. Eng.*, vol. 80, pp. 72–79, Feb. 2015.
- [11] B. Pérez Gladish, M. Arenas Parra, A. Bilbao Terol, and M. V. Rodríguez Uría, “Management of surgical waiting lists through a Possibilistic Linear Multiobjective Programming problem,” *Appl. Math. Comput.*, vol. 167, no. 1, pp. 477–495, Aug. 2005.
- [12] M. D. Basson and T. Butler, “Evaluation of operating room suite efficiency in the Veterans Health Administration system by using data-envelopment analysis,” *Am. J. Surg.*, vol. 192, no. 5, pp. 649–656, Nov. 2006.
- [13] L. O’Neill and F. Dexter, “Tactical Increases in Operating Room Block Time Based on Financial Data and Market Growth Estimates from Data Envelopment Analysis,” *Anesth. Analg.*, vol. 104, no. 2, pp. 355–368, Feb. 2007.
- [14] H. Fei, N. Meskens, and C. Chu, “An operating theatre planning and scheduling problem in the case of a ‘block scheduling’ strategy,” in *2006 International Conference on Service Systems and Service Management*, 2006, pp. 422–428.
- [15] V. N. Hsu, R. de Matta, and C.-Y. Lee, “Scheduling patients in an ambulatory surgical center,” *Nav. Res. Logist.*, vol. 50, no. 3, pp. 218–238, Apr. 2003.
- [16] F. Liang, Y. Guo, and R. Y. K. Fung, “Simulation-Based Optimization for Surgery Scheduling in Operation Theatre Management Using Response Surface Method,” *J. Med. Syst.*, vol. 39, no. 11, p. 159, Nov. 2015.
- [17] B. Roland, C. Martinelly, and F. Riane, “Operating Theatre Optimization : A Resource-Constrained Based Solving Approach,” in *2006 International Conference on Service Systems and Service Management*, 2006, pp. 443–448.
- [18] D. Conforti, F. Guerriero, and R. Guido, “A multi-objective block scheduling model for the management of surgical operating rooms: New solution approaches via genetic algorithms,” in *2010 IEEE Workshop on Health Care Management (WHCM)*, 2010, pp. 1–5.
- [19] I. Marques, M. E. Captivo, and M. Vaz Pato, “Scheduling elective surgeries in a Portuguese hospital using a genetic heuristic,” *Oper. Res. Heal. Care*, vol. 3, no. 2, pp. 59–72, Jun. 2014.

- [20] I. Marques and M. E. Captivo, “Bicriteria elective surgery scheduling using an evolutionary algorithm,” *Oper. Res. Heal. Care*, vol. 7, pp. 14–26, Dec. 2015.
- [21] A. Guinet and S. Chaabane, “Operating theatre planning,” *Int. J. Prod. Econ.*, vol. 85, no. 1, pp. 69–81, Jul. 2003.
- [22] A. Vargas, M. A. Pacheco, and M. Vellazco, “Algoritmos Evolutivos com Inspiração Quântica para Problemas com Representação Numérica,” 2007.
- [23] Kuk-Hyun Han and Jong-Hwan Kim, “Quantum-inspired evolutionary algorithm for a class of combinatorial optimization,” *IEEE Trans. Evol. Comput.*, vol. 6, no. 6, pp. 580–593, Dec. 2002.
- [24] “Bloomberg Best (and Worst).” [Online]. Available: <https://www.bloomberg.com/graphics/best-and-worst/#most-govt-health-care-spending-in-the-americas-countries>. [Accessed: 15-Dec-2017].
- [25] “Bloomberg Best (and Worst).” [Online]. Available: <https://www.bloomberg.com/graphics/best-and-worst/#most-efficient-health-care-2014-countries>. [Accessed: 14-Dec-2017].
- [26] P. G. da S. Ferreira, “Demanda reprimida de cirurgias na região metropolitana de Manaus: estudo transversal de base populacional,” Universidade Federal do Amazonas, 2017.
- [27] A. Testi, E. Tanfani, R. Valente, G. L. Ansaldo, and G. C. Torre, “Prioritizing surgical waiting lists,” *J. Eval. Clin. Pract.*, vol. 14, no. 1, pp. 59–64, Jan. 2008.
- [28] I. Rejer, “Genetic algorithm with aggressive mutation for feature selection in BCI feature space,” *Pattern Anal. Appl.*, vol. 18, no. 3, pp. 485–492, Aug. 2015.
- [29] S. N. Chaurasia, S. Sundar, and A. Singh, “Hybrid metaheuristic approaches for the single machine total stepwise tardiness problem with release dates,” *Oper. Res.*, vol. 17, no. 1, pp. 275–295, Apr. 2017.
- [30] G. Zhang and Gexiang, “Quantum-inspired evolutionary algorithms: a survey and empirical study,” *J. Heuristics*, vol. 17, no. 3, pp. 303–351, Jun. 2011.
- [31] A. Glassner, “Quantum computing. 3,” *IEEE Comput. Graph. Appl.*, vol. 21, no. 6, pp. 72–82, 2001.
- [32] C. H. Bennett and D. P. DiVincenzo, “Quantum information and

- computation,” *Nature*, vol. 404, no. 6775, pp. 247–255, Mar. 2000.
- [33] L. Reis da Silveira, R. Tanscheit, and M. Vellasco, “Algoritmo Genético de Ordem com Inspiração Quântica,” 2014.
- [34] L. R. da Silveira, R. Tanscheit, and M. Vellasco, “Quantum inspired evolutionary algorithm for ordering problems,” *Expert Syst. Appl.*, vol. 67, pp. 71–83, Jan. 2017.
- [35] Y. Moriyama, I. Iimura, T. Ohno, and S. Nakayama, “An Experimental Study on Optimization in Permutation Spaces by Quantum-Inspired Evolutionary Algorithm Using Quantum Bit Representation,” *J. Signal Process.*, vol. 19, no. 6, pp. 227–234, Nov. 2015.
- [36] D. Konar, S. Bhattacharyya, K. Sharma, S. Sharma, and S. R. Pradhan, “An improved Hybrid Quantum-Inspired Genetic Algorithm (HQIGA) for scheduling of real-time task in multiprocessor system,” *Appl. Soft Comput.*, vol. 53, pp. 296–307, Apr. 2017.
- [37] M. R. Singh and S. S. Mahapatra, “A quantum behaved particle swarm optimization for flexible job shop scheduling,” *Comput. Ind. Eng.*, vol. 93, pp. 36–44, Mar. 2016.
- [38] E. M. Kasprzak and K. E. Lewis, “Pareto analysis in multiobjective optimization using the collinearity theorem and scaling method,” *Struct. Multidiscip. Optim.*, vol. 22, no. 3, pp. 208–218, Oct. 2001.