



INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES
Autarquia Associada à Universidade de São Paulo

**Aplicação de aprendizado de máquina para melhoria do fluxo de
tratamento de radioterapia**

CAROLINE ZEPPELLINI DOS SANTOS EMILIOZZI

**Dissertação apresentada como parte dos
requisitos para obtenção do Grau de
Mestre em Ciências na Área
de Tecnologia Nuclear - Aplicações**

Orientador:

Prof. Dr. Mário Olímpio de Menezes

São Paulo

2023

INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES
Autarquia Associada à Universidade de São Paulo

Aplicação de aprendizado de máquina para melhoria do fluxo de tratamento de radioterapia

Versão Corrigida

Versão Original disponível no IPEN

CAROLINE ZEPPELLINI DOS SANTOS EMILIOZZI

Dissertação apresentada como parte dos requisitos para obtenção do Grau de Mestre em Ciências na Área de Tecnologia Nuclear - Aplicações

Orientador:

Prof. Dr. Mário de Olímpio de Menezes

São Paulo

2023

Autorizo a reprodução e divulgação total ou parcial deste trabalho, para fins de estudo e pesquisa, desde que citada a fonte.

Como citar:

ZEPPELLINI DOS SANTOS EMILIOZZI, C. ***Aplicação de aprendizado de máquina para melhoria do fluxo de tratamento de radioterapia***. 2023. 181 f. Dissertação (Mestrado em Tecnologia Nuclear), Instituto de Pesquisas Energéticas e Nucleares, IPEN-CNEN, São Paulo. Disponível em: <<http://repositorio.ipen.br/>> (data de consulta no formato: dd/mm/aaaa)

Ficha catalográfica elaborada pelo Sistema de geração automática da Biblioteca IPEN, com os dados fornecidos pelo(a) autor(a).

Zeppellini dos Santos Emiliozzi, Caroline
Aplicação de aprendizado de máquina para melhoria do fluxo
de tratamento de radioterapia / Caroline Zeppellini dos
Santos Emiliozzi; orientador Mário Mário Olímpio de Menezes.
-- São Paulo, 2023.
181 f.

Dissertação (Mestrado) - Programa de Pós-Graduação em
Tecnologia Nuclear (Aplicações) -- Instituto de Pesquisas
Energéticas e Nucleares, São Paulo, 2023.

1. radioterapia. 2. aprendizado de máquina. 3.
programação linear. 4. tempo de tratamento. 5. tempo de
espera. I. Mário Olímpio de Menezes, Mário, orient. II.
Título.

AGRADECIMENTOS

Agradeço primeiramente a Deus por me dar força para encerrar essa jornada tripla, maternidade, trabalho e mestrado.

Agradeço ao IPEN e HCFMUSP por me permitir desenvolver esse estudo.

Ao meu marido e minha filha por me ceder nosso tempo em família para conseguir desenvolver esse projeto.

A Filomena e Vera por cuidar da minha filha quando eu estava realizando meus estudos

Aos meus colegas de trabalho que sempre me incentivaram e me apoiaram quando precisei.

Ao meu orientador Mario pela paciência, compreensão e disponibilidade durante a realização deste trabalho

RESUMO

EMILIOZZI, Caroline Z.D.S. **Aplicação de aprendizado de máquina para melhoria do fluxo de tratamento de radioterapia**, 2023. Dissertação (Mestrado em Tecnologia nuclear - Aplicações) - Instituto de Pesquisas Energéticas e Nucleares-IPEN.

O câncer é o principal problema de saúde pública no mundo. A radioterapia é uma das formas mais comuns e efetivas de tratamento de câncer. Porém, atualmente existe um desequilíbrio entre a demanda de tratamentos e a disponibilidade de equipamentos de radioterapia o que leva a atrasos no início de tratamento, esses atrasos produzem sofrimento psicológico e menor probabilidade de controle da doença. Como há uma grande pressão para a contenção de custos, muitas vezes não é possível resolver o problema da falta de equipamentos com a expansão de centros de tratamento. Por outro lado, existe uma ineficiência nos processos relacionados ao fluxo de trabalho e no agendamento de pacientes para início de tratamento. Neste trabalho buscou-se, através da análise de dados do setor de radioterapia do Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo, estudar meios de otimização do fluxo de trabalho para se obter uma gestão eficaz e eficiente do tempo de espera. Com intuito de fazer previsões do tempo de espera e do tempo de tratamento dos pacientes foram comparados quatro algoritmos de AM (Aprendizado de Máquina) com técnica de regressão (*Support Vector Machine*, *Extreme Gradient Boosting*, *Random forest* e Redes neurais) e para a otimização do agendamento de radioterapia foi proposto um modelo de programação linear inteiro misto. Com base no trabalho realizado, conclui-se que a utilização de AM ajuda entender os problemas encontrados no setor. Foram propostas mudanças na rotina, definidos tempo de espera e de tratamento mais adequados e conseguiu-se que o agendamento automático possibilitasse a diminuição do tempo de espera dos pacientes, com priorização dos pacientes com pior prognóstico.

Palavras-chaves: radioterapia, aprendizado de máquina, ciência de dados, programação linear, tempo de espera e tempo de tratamento

ABSTRACT

EMILIOZZI, Caroline Z.D.S. **Machine learning application to improve the flow of radiotherapy treatment**, 2023. Dissertação (Mestrado em Tecnologia nuclear - Aplicações) - Instituto de Pesquisas Energéticas e Nucleares-IPEN

Cancer is the main public health problem in the world. Radiotherapy (RT) is an importante modality in the treatment of these patients. With this growing global burden, demand for RT has been increasing continuously and supply-demand imbalances have become a major concern, due to the negative impact of treatment delays. Evidence has been published of the negative impact of treatment delays on measures such as tumor progression, persistence of cancer symptoms, psychological distress and decreased cancer control and survival rates. The reason for delays in Radiotherapy is not only due to imbalance between capacity and demand, but also due to inefficiency of workflow, for instance, scheduling problems. Consequently, as there is pressure to contain costs, it is often not possible to solve the problem of the lack of equipment. However, the problem of inefficient processes can be attacked. This work, we analyze the data of electronic health records of radiotherapy department of Hospital das Clínicas de São Paulo to attempt to provide a better understanding of the problem and study ways of optimizing workflow and efficient management of waiting time. In order to make predictions of patient waiting time and treatment time, four machine learning algorithms were compared using regression technique (*Support Vector Machine*, *Extreme Gradient Boosting*, *Random forest* and *Neural networks*) and for the optimization of radiotherapy scheduling, a mixed integer linear programming model was proposed. Based on this work, it is concluded that the use of AM helps to understand the problems of the departament. Changes in routine were proposed, more appropriate waiting and treatment times were defined and automatic scheduling made it possible to reduce patient waiting times, prioritizing patients with the worst prognosis

Keywords: radiotherapy, machine learning, data science, linear programming, waiting time and treatment time

| | |
|--|-----|
| TABELA 1 - AS PRINCIPAIS CARACTERÍSTICAS DE CADA ALGORITMO DE APRENDIZADO PREDITIVO UTILIZADO NO TRABALHO..... | 12 |
| TABELA 2 - MÉTRICAS USADAS PARA AVALIAR MÉTODOS DE CLASSIFICAÇÃO: VP: VERDADEIROS POSITIVOS; FN: FALSOS NEGATIVOS; FP: FALSOS POSITIVOS; VN: VERDADEIROS NEGATIVOS; P: PRECISÃO; S: SENSIBILIDADE; N: TOTAL DE ELEMENTOS. | 24 |
| TABELA 3 - RESUMO DAS TABELAS GERADAS COM O PROGRAMA EM VBA. | 42 |
| TABELA 4 - RESUMO DAS TABELAS UTILIZADAS PARA A ANÁLISE EXPLORATÓRIA E CRIAÇÃO DOS MODELOS PREDITIVOS..... | 43 |
| TABELA 5 - COMPARAÇÃO DO TEMPO DE ESPERA PADRÃO MÉDIO E O TEMPO REAL MÉDIO POR TÉCNICA..... | 69 |
| TABELA 6- NÚMERO DE CASOS POR GRUPO (FREQ_GRUPO) E NÚMERO DE CASOS QUE RETORNARAM EM CADA GRUPO (FREQ). | 83 |
| TABELA 7- RESULTADOS DA AVALIAÇÃO DE DX2Y..... | 84 |
| TABELA 8 - CORRELAÇÃO ENTRE O TEMPO DE TRATAMENTO E AS VARIÁVEIS PREDITORAS NUMÉRICAS AGRUPADAS PELA TÉCNICA. | 85 |
| TABELA 9 - CORRELAÇÃO ENTRE O TEMPO DE TRATAMENTO E AS VARIÁVEIS PREDITORAS NUMÉRICAS AGRUPADAS PELOS PRINCIPAIS TIPOS DE TRATAMENTO. | 85 |
| TABELA 10 - CORRELAÇÃO ENTE O TEMPO DE TRATAMENTO E AS VARIÁVEIS PREDITORAS NUMÉRICAS AGRUPADAS PELOS PRINCIPAIS GRUPOS DE TRATAMENTO. | 86 |
| TABELA 11 - HIPERPARÂMETROS TESTADOS NO MODELO DE REGRESSÃO COM RF E ALGUMAS CONSIDERAÇÕES SOBRE OS PARÂMETROS..... | 110 |
| TABELA 12 - HIPERPARÂMETROS TESTADOS NO MODELO DE REGRESSÃO COM ÁRVORE DE DECISÃO E ALGUMAS CONSIDERAÇÕES SOBRE OS PARÂMETROS. | 111 |
| TABELA 13 - HIPERPARÂMETROS TESTADOS NO MODELO DE REGRESSÃO COM SVM E ALGUMAS CONSIDERAÇÕES SOBRE OS PARÂMETROS..... | 111 |
| TABELA 14 - HIPERPARÂMETROS TESTADOS NO MODELO DE REGRESSÃO COM XGBOOST E ALGUMAS CONSIDERAÇÕES SOBRE OS PARÂMETROS..... | 112 |
| TABELA 15 - HIPERPARÂMETROS TESTADOS NO MODELO DE REGRESSÃO COM RNA E ALGUMAS CONSIDERAÇÕES SOBRE OS PARÂMETROS..... | 113 |
| TABELA 16 - RESULTADOS DO MODELO DE PREDIÇÃO TEMPO DA ATIVIDADE PRÉ TRATAMENTO..... | 114 |
| TABELA 17 - RESULTADOS DO MODELO DE PREDIÇÃO TEMPO DE TRATAMENTO..... | 121 |
| TABELA 18 - RESULTADOS DO MODELO DE PREVISÃO DE ATRASOS NA AGENDA DIÁRIA COM O PACOTE MLR SEM TÉCNICAS DE BALANCEAMENTO. ACC=PRECISÃO, S=SENSIBILIDADE, E=ESPECIFICIDADE, VVP=VALOR PREDITO POSITIVO E VP= VALOR PREDITO NEGATIVO..... | 125 |
| TABELA 19 - RESULTADOS DO MODELO DE PREVISÃO DE ATRASOS NA AGENDA DIÁRIA COM O PACOTE CARET SEM TÉCNICAS DE BALANCEAMENTO. ACC=PRECISÃO, S=SENSIBILIDADE, E=ESPECIFICIDADE, VVP=VALOR PREDITO POSITIVO E VP= VALOR PREDITO NEGATIVO..... | 125 |
| TABELA 20 - RESULTADOS DO MODELO DE PREVISÃO DE ATRASOS NA AGENDA DIÁRIA COMO ALGORITMO RANDOM FOREST, PACOTE CARET E COM TÉCNICA DE BALANCIAMENTO. ACC=PRECISÃO, S=SENSIBILIDADE, E=ESPECIFICIDADE, VP=VALOR PREDITO POSITIVO E VP=VALOR PREDITO NEGATIVO..... | 127 |
| TABELA 21 - RESULTADOS DO MODELO DE PREVISÃO DE ATRASOS NA AGENDA DIÁRIA COM O ALGORITMO REGRESSÃO LOGÍSTICA, PACOTE MLR E COM TÉCNICAS DE BALANCEAMENTO. ACC=PRECISÃO, S=SENSIBILIDADE, E=ESPECIFICIDADE, VVP=VALOR PREDITO POSITIVO E VP= VALOR PREDITO NEGATIVO. | 127 |

| | |
|--|----|
| FIGURA 1 - FLUXO DE TRABALHO NA RADIOTERAPIA..... | 4 |
| FIGURA 2 - DEFINIÇÕES DOS CINCO “Vs “DE BIG DATA. | 6 |
| FIGURA 3 - CICLO DE VIDA DE UM PROJETO DE CIÊNCIA DE DADOS. | 8 |
| FIGURA 4 - EXEMPLO DE REGRESSÃO LINEAR SIMPLES. | 14 |
| FIGURA 5 - EXEMPLO REGRESSÃO LOGÍSTICA. | 15 |
| FIGURA 6 - ÁRVORE DE DECISÃO APLICADA A UMA TAREFA DE CLASSIFICAÇÃO..... | 16 |
| FIGURA 7 - ILUSTRAÇÃO DO ALGORITMO RANDOM FOREST..... | 18 |
| FIGURA 8 - PRINCÍPIO DE FUNCIONAMENTO DO ALGORITMO GRADIENT BOOSTED TREES. | 19 |
| FIGURA 9 - ARQUITETURA REDES NEURAIS..... | 20 |
| FIGURA 10 - CONSTRUÇÃO DE UM PLANO DE SEPARAÇÃO DO SVM. | 22 |
| FIGURA 11 - EXEMPLO DE UM CLASSIFICADOR COM SVM. | 23 |
| FIGURA 12 - ROTEIRO PARA APLICAÇÃO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA EM ANÁLISE PREDITIVA..... | 45 |
| FIGURA 13 - (A) DISTRIBUIÇÃO DE FREQUÊNCIA DE PACIENTES POR INTERVALOS DE IDADES E (B) GRUPOS DE TRATAMENTOS COM MAIORES NÚMEROS DE CASOS. | 51 |
| FIGURA 14 - EVOLUÇÃO DAS FAIXAS ETÁRIAS AO LONGO DO TEMPO. (A) DISTRIBUIÇÃO DE FREQUÊNCIA DE PACIENTES POR FAIXA ETÁRIA E (B) EVOLUÇÃO DA DISTRIBUIÇÃO DE FREQUÊNCIA POR ANO. | 52 |
| FIGURA 15 - EVOLUÇÃO DO NÚMERO DE CASOS PARA CADA TÉCNICA DE TRATAMENTO ENTRE 2016 E 2020. (A) EVOLUÇÃO DA PORCENTAGEM DE CASOS COM UMA DETERMINADA TÉCNICA ENTRE 2016 E 2020, (B) NÚMERO DE CASOS DE UMA DETERMINADA TÉCNICA POR ANO E (C) DISTRIBUIÇÃO DE CADA TÉCNICA DE TRATAMENTO POR ANO. | 53 |
| FIGURA 16 - AVALIAÇÃO DA SAZONALIDADE DE CHEGADA DE PACIENTES NO DEPARTAMENTO. (A)- NÚMERO DE NOVOS PACIENTES AO LONGO DO TEMPO E (B)- VARIAÇÃO DO NÚMERO DE CASOS POR MÊS. | 55 |
| FIGURA 17 - TOTAIS DE DIAS DE EQUIPAMENTO PARADO PARA MANUTENÇÃO POR ANO. | 57 |
| FIGURA 18 - CORRELAÇÃO ENTRE AS VARIÁVEIS ESTUDADAS PARA PREDIÇÃO DO TEMPO DE ESPERA. | 58 |
| FIGURA 19 - TEMPO DE ATIVIDADE PRÉ-TRATAMENTO (DIAS) POR TÉCNICA DE TRATAMENTO E PELOS PRINCIPAIS GRUPOS DE TRATAMENTO. (A) AVALIAÇÃO PARA AS TÉCNICAS CONVENCIONAIS DESCONSIDERANDO OS PACIENTES DE RADIOCIRURGIA, (B) AVALIAÇÃO PARA AS TÉCNICAS 3D E IMRT PARA OS TRATAMENTOS DE RADIOCIRUGIAS, (C) GRUPOS MAIS FREQUENTES SEM CONSIDERAR METÁSTASES, (D) GRUPOS DE METÁSTASES E TBI, (E) AVALIAÇÃO PARA OS PRINCIPAIS TIPOS DE TRATAMENTO E (F) AVALIAÇÃO PARA AS FAIXAS ETÁRIAS. | 59 |
| FIGURA 20 - HISTOGRAMA COM AS DIFERENÇAS ENTRE O TEMPO DE ESPERA REAL E O TEMPO PREVISTO EM DIAS. | 63 |
| FIGURA 21 - DIFERENÇAS ENTRE O TEMPO DE ESPERA REAL E O TEMPO PREVISTO POR TÉCNICA DE TRATAMENTO. | 64 |
| FIGURA 22 - DIFERENÇA ENTRE O TEMPO DE ESPERA REAL E O TEMPO DE ESPERA PREVISTO POR GRUPO. (A)- BOXPLOT DE TODOS OS GRUPOS, (B)- BOXPLOT COM TESTE ESTATÍSTICO PARA OS GRUPOS MAIS FREQUENTES EXCETO METÁSTASES E TBI E (C) BOXPLOT COM TESTE ESTATÍSTICO PARA OS GRUPOS DE METÁSTASES E TBI. | 66 |
| FIGURA 23 - VARIAÇÃO DO TEMPO PADRÃO NO PERÍODO AVALIADO POR TÉCNICA. | 68 |
| FIGURA 24 - (A) DISTRIBUIÇÃO DOS CASOS DE ATRASOS NO TEMPO DE ESPERA POR TÉCNICA DE TRATAMENTO E (B) DISTRIBUIÇÃO DOS CASOS DE ATRASOS NO TEMPO DE ESPERA POR TIPO DE TRATAMENTO. | 70 |
| FIGURA 25 - AVALIAÇÃO DO TEMPO DE CONTORNO POR GRUPO E TÉCNICA..... | 72 |
| FIGURA 26 - AVALIAÇÃO DO TEMPO DE PLANEJAMENTO POR GRUPO E TÉCNICA. | 72 |
| FIGURA 27 - AVALIAÇÃO COM TESTE ESTATÍSTICO DAS DIFERENÇAS DO TEMPO DE CONTORNO. | 73 |
| FIGURA 28 - AVALIAÇÃO COM TESTE ESTATÍSTICO E AS DIFERENÇAS DO TEMPO DE PLANEJAMENTO..... | 74 |
| FIGURA 29 - MÉDIA DOS DESVIOS ENTRE O TEMPO REAL E O PREVISTO POR GRUPO DE TRATAMENTO EM RELAÇÃO AS ATIVIDADES DE CONTORNO (A), CONFECÇÃO DO PLANO (B) E APROVAÇÃO DO PLANO (C)..... | 75 |
| FIGURA 30 - MÉDIA DOS DESVIOS ENTRE O TEMPO REAL E O PREVISTO POR TÉCNICA DE TRATAMENTO EM RELAÇÃO AS ATIVIDADES DE CONTORNO (A), CONFECÇÃO DO PLANO (B) E APROVAÇÃO DO PLANO (C)..... | 77 |
| FIGURA 31 - (A) INCIDÊNCIA DE CASOS EM ATRASOS AO LONGO DE 2016 A 2020 E (B) PORCENTAGEM DE PACIENTES EM ATRASOS POR MÊS E ANO, S SÃO OS PACIENTES QUE ESTÃO DENTRO DO PRAZO PREVISTO E N SÃO OS PACIENTES QUE NÃO ESTÃO DENTRO DO PRAZO. | 79 |

| | |
|--|-----|
| FIGURA 32 - INCIDÊNCIA DE CASOS EM ATRASO POR FAIXAS DE OCUPAÇÃO E EQUIPAMENTO. | 81 |
| FIGURA 33- PORCENTAGEM DE RETORNOS PARA NOVOS TRATAMENTOS POR GRUPO. | 82 |
| FIGURA 34 - CORRELAÇÃO ENTRE AS VARIÁVEIS ESTUDADAS PARA TÉCNICA 3D. | 86 |
| FIGURA 35 - DISTRIBUIÇÃO DO TEMPO DE TRATAMENTO. (A) TEMPO DE TRATAMENTO POR TÉCNICA PARA OS TRATAMENTOS CONVENCIONAIS, (B) TEMPO DE TRATAMENTO POR TÉCNICA PARA OS TRATAMENTOS ESPECIAIS, (C) TEMPO DE TRATAMENTO PARA OS GRUPOS DE ABDOME, CABEÇA E PESCOÇO, MAMA, SISTEMA NERVOSO CENTRAL, TORAX E PRÓSTATA E (D) TEMPO DE TRATAMENTO PARA OS GRUPOS DE METÁSTASES E TBI. | 88 |
| FIGURA 36 - COMPARAÇÃO DO TEMPO DE TRATAMENTO DOS PRINCIPAIS GRUPOS COM DIFERENTES TÉCNICAS DE TRATAMENTO. (A)- COMPARAÇÃO PARA OS CASOS DE CÂNCER DE MAMA, (B) - COMPARAÇÃO PARA OS CASOS DE CÂNCER DE PRÓSTATA, (C) – COMPARAÇÃO PARA OS CASOS DE CÂNCER DE CABEÇA E PESCOÇO, (D) - COMPARAÇÃO PARA OS CASOS DE CÂNCER DE SISTEMA NERVOSO CENTRAL, (E) - COMPARAÇÃO PARA OS CASOS DE CÂNCER DE METÁSTASE ÓSSEA E (F)- COMPARAÇÃO PARA OS CASOS DE CÂNCER DE METÁSTASE CEREBRAL. | 91 |
| FIGURA 37 - COMPARAÇÃO ENTRE O TEMPO DE TRATAMENTO DA PRIMEIRA SESSÃO E A MÉDIA DO TEMPO DAS OUTRAS SESSÕES. (A) COMPARAÇÃO PARA RADIOCIRURGIA FRACIONADA E (B) COMPARAÇÃO PARA AS MODALIDADES CONVENCIONAIS. | 95 |
| FIGURA 38 - TEMPO DE TRATAMENTO POR TÉCNICA E APARELHO. (A) APARELHO 2100CD, (B) APARELHO 2100CD E (C) APARELHO 6EX. | 98 |
| FIGURA 39 - AVALIAÇÃO DO IMPACTO DE PORTAIS NO TEMPO DE TRATAMENTO. | 100 |
| FIGURA 40 - COMPARAÇÃO DO TEMPO DE TRATAMENTO COM A TÉCNICA 2D PARA OS DIFERENTES EQUIPAMENTOS. (A) DIAS SEM REALIZAÇÃO DE PORTAL DE VERIFICAÇÃO DE POSICIONAMENTO E (B) DIAS COM REALIZAÇÃO DE PORTAL DE VERIFICAÇÃO DE POSICIONAMENTO DESCONSIDERANDO O PRIMEIRO DIA DE TRATAMENTO. | 101 |
| FIGURA 41 - AVALIAÇÃO DA DISTRIBUIÇÃO DE FALTAS NO PERÍODO AVALIADO. | 102 |
| FIGURA 42- REGRESSÃO DO NÚMERO DE CAMPOS E TEMPO DE TRATAMENTO. (A) CASOS CONVENCIONAIS E TÉCNICA 2D, (B) CASOS CONVENCIONAIS E TÉCNICA 3D, (C) CASOS CONVENCIONAIS E TÉCNICA IMRT, (D) CASOS CONVENCIONAIS E TÉCNICA VMAT, (E) CASOS DE RADIOCIRURGIA E TÉCNICA 3D REF, (F) CASOS DE RADIOCIRURGIA E TÉCNICA 3D SRS, (G) CASOS DE RADIOCIRURGIA E TÉCNICA IMRT REF E (H) CASOS DE RADIOCIRURGIA E TÉCNICA IMRT SRS. | 103 |
| FIGURA 43 - REGRESSÃO DA DOSE POR FRAÇÃO E TEMPO DE TRATAMENTO. (A) CASOS CONVENCIONAIS E TÉCNICA 2D. (B) CASOS CONVENCIONAIS E TÉCNICA 3D, (C) CASOS CONVENCIONAIS E TÉCNICA IMRT, (D) CASOS CONVENCIONAIS E TÉCNICA VMAT (E) CASOS DE RADIOCIRURGIA E TÉCNICA 3D REF, (F) CASOS DE RADIOCIRURGIA E TÉCNICA 3D SRS, (G) CASOS DE RADIOCIRURGIA E TÉCNICA IMRT REF E (H) CASOS DE RADIOCIRURGIA E TÉCNICA IMRT SRS. | 106 |
| FIGURA 44 - RESULTADOS DOS MODELOS DE PREDIÇÃO. TEMPO DE ESPERA REAL VERSUS TEMPO DE ESPERA PREDITO EM DIAS. (A) RNA, (B) RF, (C) SVM E (D) XGBOOST. A RETA PRETO REPRESENTA O TEMPO DE ESPERA REAL IGUAL AO TEMPO DE ESPERA PREDITO E A RETA AZUL É O AJUSTE LINEAR DOS DADOS. | 116 |
| FIGURA 45 - COMPARAÇÃO DOS RESÍDUOS DOS MODELOS ESTUDADOS PARA PREDIÇÃO DO TEMPO DE ESPERA. (A) RNA, (B) RF, (C) SVM E (D) XGBOOST. | 117 |
| FIGURA 46 - RESULTADO DO MODELOS DE PREDIÇÃO COM RF COM A INCLUSÃO DAS VARIÁVEIS TEMPO DE CONTORNO E TEMPO DE PLANO. | 118 |
| FIGURA 47 - RESULTADOS DOS MODELOS DE PREDIÇÃO. TEMPO DE TRATAMENTO REAL VERSUS TEMPO DE TRATAMENTO PREDITO EM MINUTOS. (A) RNA, (B) RF, (C) SVM E (D) XGBOOST. | 122 |
| FIGURA 48 - COMPARAÇÃO DOS RESÍDUOS DOS MODELOS ESTUDADOS PARA PREDIÇÃO DO TEMPO DE TRATAMENTO. (A) REDES NEURAIS, (B) RANDOM FOREST, (C) SVM E (D) XGBOOST. | 123 |
| FIGURA 49 - FORMULÁRIO PARA DEFINIÇÃO DOS GRUPOS E PARA DEFINIÇÃO DAS PRIORIDADE DOS GRUPOS. | 129 |
| FIGURA 50 - VARIAÇÃO EM DIAS DO TEMPO DE ESPERA DO AGENDAMENTO AUTOMÁTICO COM TEMPO PADRÃO VERSUS O AGENDAMENTO MANUAL. (A) FREQUÊNCIA DAS VARIAÇÕES DO TEMPO DE ESPERA E (B) VARIAÇÃO DO TEMPO DE ESPERA LEVANDO EM CONSIDERAÇÃO A PRIORIZAÇÃO DO PACIENTE. | 135 |
| FIGURA 51 - VARIAÇÃO DO TEMPO DE ESPERA DO AGENDAMENTO AUTOMÁTICO COM TEMPO PREDITO EM DIAS VERSUS O AGENDAMENTO MANUAL. (A) FREQUÊNCIA DAS VARIAÇÕES DO TEMPO DE ESPERA E (B) VARIAÇÃO DO TEMPO DE ESPERA LEVANDO EM CONSIDERAÇÃO A PRIORIZAÇÃO DO PACIENTE. | 136 |

FIGURA 52 - VARIAÇÃO DO TEMPO DE ESPERA DO AGENDAMENTO AUTOMÁTICO COM TEMPO PREDITO EM DIAS E POSSIBILIDADE DE MUDANÇA DE HORÁRIO DOS PACIENTES JÁ AGENDADOS VERSUS O AGENDAMENTO MANUAL. (A) FREQUÊNCIA DAS VARIAÇÕES DO TEMPO DE ESPERA E (B) VARIAÇÃO DO TEMPO DE ESPERA LEVANDO EM CONSIDERAÇÃO A PRIORIZAÇÃO DO PACIENTE.....137

Sumário

| | |
|--|-----------|
| 1 INTRODUÇÃO | 1 |
| 1.1 Objetivos Gerais | 5 |
| 1.2 Objetivos Secundários | 5 |
| 2 FUNDAMENTOS TEÓRICOS | 6 |
| 2.1 Big Data | 6 |
| 2.2 Ciência de Dados | 7 |
| 2.2.1 Etapas de um projeto de ciência de dados | 8 |
| 2.3 Aprendizado de Máquina | 9 |
| 2.3.1 Regressão Linear | 13 |
| 2.3.2 Regressão Logística | 14 |
| 2.3.3 Árvore de Decisão (AD) | 15 |
| 2.3.4 Random Forest (RF) | 16 |
| 2.3.5 Extreme Gradient Boosting (XGBoost) | 18 |
| 2.3.6 Redes Neurais Artificiais (RNA) | 19 |
| 2.3.7 Máquinas de Vetores de Suporte (SVM) | 22 |
| 2.4 Métricas de validação dos algoritmos | 24 |
| 2.5 Pesquisa Operacional | 26 |
| 2.5.1 Projeto de Pesquisa Operacional | 27 |
| 2.5.2 Programação Linear (PL) | 28 |
| 3 REVISÃO LITERATURA | 31 |
| 3.1 Tempo de Espera | 31 |
| 3.2 Otimização de Agendamento | 33 |
| 4 MATERIAIS E MÉTODOS | 37 |
| 4.1 Local de estudo | 37 |
| 4.2 Comissão de Ética | 39 |
| 4.3 Descrição do Problema | 39 |
| 4.3.1 Tempo de espera | 39 |
| 4.3.2 Tempo de tratamento | 39 |
| 4.3.3 Agendamento | 40 |
| 4.4 Coleta de dados e período de estudo | 41 |
| 4.5 Análises Estatísticas | 45 |
| 5 RESULTADOS E DISCUSSÕES | 48 |

| | |
|--|------------|
| 5.1 Pré-Processamento | 48 |
| 5.2 Análise Exploratória | 49 |
| 5.3 Tempo de realização da etapa pré-tratamento | 57 |
| 5.3 Tempo de Tratamento..... | 84 |
| 5.4 Modelo de Previsão de Tempo de Espera..... | 109 |
| 5.5 Modelo de Previsão de Tempo de Tratamento | 120 |
| 5.6 Modelo de Previsão de Atrasos..... | 124 |
| 5.7 Agendamento | 129 |
| 5.7.1 Priorização..... | 129 |
| 5.7.2 Formulação do Modelo | 130 |
| 5.7.3 Verificação do modelo..... | 134 |
| 6 CONCLUSÕES | 138 |
| REFERÊNCIAS BIBLIOGRÁFICAS | 140 |
| APÊNDICE A – Lista dos CIDs que compõe cada Grupo..... | 145 |
| APÊNDICE B – Dicionário das variáveis estudadas | 146 |
| APÊNDICE C- Tempo de Espera ideal levando em consideração as variáveis: grupo, se o paciente é pediátrico, se o paciente é convênio e a técnica de tratamento. O IC(95%) é o tempo de espera em dias que deveria ser fornecido para o paciente para que 95% dos pacientes não ultrapassem o tempo de espera previsto e o IC(68%) é o tempo de espera em dias que deveria ser fornecido para o paciente para que 95% dos pacientes não ultrapassem o tempo de espera previsto. | 153 |
| APÊNDICE D- Regiões que compõem cada grupo de prioridade. | 157 |
| APÊNDICE E – Tempo de tratamento de referência | 159 |
| ANEXO 1..... | 181 |

1 INTRODUÇÃO

Câncer, também chamado de neoplasia ou tumor maligno, é um termo para definir o rápido surgimento de células anormais que crescem além de seus limites. Estas podem invadir partes adjuntas ou se espalhar para outros órgãos ¹. Segundo Ferlay et al, apenas em 2020, eram esperados mais de 19 milhões de novos casos de câncer no mundo, sendo mais comum os casos de câncer de mama, pulmão e próstata. Dez milhões de pessoas morreram neste mesmo ano, tornando a doença líder em causa de mortes no mundo ².

No Brasil, estima-se 704 mil novos casos de câncer por ano entre 2023 e 2025 e os mais comuns são câncer de pele não-melanoma, mama e próstata ³. Aproximadamente 260 mil mortes ocorreram devido ao câncer em 2020 no Brasil ⁴. As estimativas sobre os futuros casos de câncer são difíceis de se prever já que diversos fatores podem influenciar, como índice de desenvolvimento e perfil de idade populacional do país. Mesmo assim, para os próximos 50 anos, a estimativa é que o número de novos casos por ano quase dobre, chegando a 34 milhões em 2070 ⁵. Quimioterapia, cirurgia e radioterapia ainda são os tipos de tratamento mais comuns disponíveis atualmente ⁶.

O princípio básico da radioterapia (RT) é a utilização da radiação ionizante para formar íons que, através de mecanismos biológicos, são capazes de destruir as células tumorais ou danificá-las ao ponto de serem incapazes de continuarem a se reproduzir ⁷. Existem duas modalidades de tratamentos de radioterapia a braquiterapia e a teleterapia. A diferença entre essas duas modalidades é o posicionamento da fonte de radiação em relação ao paciente, na braquiterapia a fonte é colocada em contato direto com o local onde se deseja entregar a radiação e na teleterapia é colocada externamente a uma certa distância. Dentro da teleterapia, que é o foco desse trabalho, existem também diferentes técnicas de planejamento de tratamento, sendo elas ⁸:

- 2D ou 2d - radioterapia convencional em duas dimensões, na qual o planejamento é realizado em imagens de radiografia convencional. Essa técnica não necessita de um sistema computacional de planejamento.

- 3D - radioterapia conformacional, na qual se utiliza tomografia computadorizada e sistema computacional no planejamento do tratamento.

- Intensidade modulada (IMRT) – evolução da radioterapia 3D capaz de modular o feixe de radiação por meio da movimentação de lâminas do sistema de colimação de múltiplas folhas (MLC).

- Arcoterapia Volumétrica Modulada (VMAT) - forma avançada de IMRT em que o feixe é entregue em arco. Nessa técnica há alteração de três parâmetros durante o tratamento: a velocidade de rotação do gantry do equipamento, o formato do campo com o uso do colimador multifolhas e a taxa de dose empregada.

Além disso, existem também técnicas de tratamento de teleterapia especiais, ou seja, entregam a dose de tratamento de uma maneira não convencional, como por exemplo ⁸:

- Intraoperatória (RT-IO): administração de radiação diretamente no tumor alvo, enquanto o mesmo está exposto durante a cirurgia.

- Radiocirurgia: radioterapia com dose alta de tratamento e entregue em poucas aplicações. Na região cranial é conhecida como Radiocirurgia estereotática (SRS) (1 a 5 aplicações) e nas outras regiões como Radiocirurgia Estereotática Corpórea (SBRT) (1 a 8 aplicações). A radiocirurgia entregue em mais de uma aplicação é chamada de radiocirurgia fracionada (REF).

- Irradiação de Corpo Inteiro (TBI): irradiação de todo o corpo do paciente com grandes campos de radiação em *setup* de tratamento não convencional (grande distância da fonte até a superfície do paciente).

- Irradiação de pele total (TSI): irradiação de toda a pele do paciente. Assim como no TBI, utiliza-se um *setup* de tratamento não convencional.

Um estudo estima que a radioterapia é recomendada, em média, para 52,3% de casos de câncer como parte do tratamento oncológico ⁹. Este tratamento sozinho é capaz de proporcionar até mais 5 anos de sobrevida a 2,4% de todos os pacientes de câncer ¹⁰. Com dados tão relevantes sobre esse tratamento oncológico, é evidente a necessidade de se otimizar os tratamentos de radioterapia.

Com esse crescimento global de novos casos, a demanda por RT tem aumentado e existe uma grande preocupação de ocasionar um desequilíbrio

entre oferta e demanda. A razão para isso é que atrasos no início do tratamento com a radioterapia podem afetar o resultado, permitindo tanto a proliferação local de células clonogênicas quanto a disseminação do câncer além do volume de tratamento. Além disso, estudos mostram que atrasos estão associados a sofrimento psicológico e menor probabilidade de controle da doença, devido à possibilidade de aumento do tamanho do tumor durante o tempo de espera e, portanto, a piora do prognóstico ¹¹.

O motivo dos atrasos na radioterapia não se deve apenas ao desequilíbrio entre capacidade e demanda, mas também à ineficiência do fluxo de trabalho. Como há uma grande pressão para a contenção de custos, muitas vezes não é possível resolver o problema da falta de equipamentos com a expansão de centros de tratamento. Entretanto, o problema de ineficiência de agendamento de pacientes para início de tratamento pode ser atacado e a aplicação de métodos e técnicas da inteligência artificial (IA) pode ajudar nesse problema.

A radioterapia é um dos campos da saúde que se beneficiarão muito com a inteligência artificial, uma vez que é uma área que já utiliza computação na maioria dos processos e os dados já estão armazenados. A implementação de soluções de IA tem o potencial de transformar a área oncológica trazendo uma melhora da qualidade do tratamento para os pacientes com câncer ¹². Essas melhorias são extremamente importantes, principalmente em ambientes de saúde com poucos recursos. A IA pode ter aplicações particularmente transformadoras na oncologia, dada a natureza multifacetada e altamente técnica desse campo da medicina. Como exemplo disso, tem-se o fluxo de trabalho da radioterapia que é um processo complexo que consiste em várias etapas (simulação de tomografia computadorizada (CT), planejamento e entrega do tratamento e garantia da qualidade).

A IA tem sido proposta como ferramenta para aumentar a qualidade, padronização e aceleração dessas etapas levando a um processo mais seguro e preciso ¹³. Muitos trabalhos da literatura mostram que a inteligência artificial tem sido utilizada para automatizar e melhorar vários aspectos da ciência médica. Na radioterapia, por exemplo, a automatização do processo de planejamento demonstrou melhorar sua eficiência e trazer consistência na qualidade do plano ^{14 15 16}. Outra motivação para aplicar a IA, além da realização dos processos com

mais agilidade, é a diminuição do risco de erros. Em suma, a IA pode ajudar a otimizar os fluxos de trabalho e melhorar a qualidade e a eficiência do atendimento ao paciente.

O processo global de radioterapia inicia-se com o diagnóstico e termina na consulta de seguimento (*follow up*) do paciente. Durante todo este processo, são várias as etapas, os meios técnicos e os recursos humanos necessários à realização do tratamento. Essas etapas podem ser divididas em pré-simulação, pré-tratamento e de tratamento. O fluxo de trabalho depende de uma equipe multidisciplinar e, portanto, a comunicação e registro de dados são fundamentais para garantir um serviço de qualidade e com segurança. Na figura 1, é mostrado o fluxo de trabalho resumido do setor de radioterapia para melhor entendimento da complexidade da rotina. Após a realização de todas as atividades pré-tratamento, o paciente está apto a iniciar seu tratamento.

FIGURA 1 - FLUXO DE TRABALHO NA RADIOTERAPIA.



Fonte: Próprio autor.

1.1 Objetivos Gerais

Nesse trabalho buscou-se, através da análise de dados, estudar meios de otimização do fluxo de pacientes e da gestão eficaz e eficiente do tempo de espera e propor um algoritmo de agendamento de radioterapia, utilizando a abordagem de aprendizado de máquina para diminuição de atrasos e maximização do número de pacientes atendidos.

1.2 Objetivos Secundários

Como objetivos secundários, temos:

- avaliação dos fatores que impactam o tempo de espera dos pacientes e o tempo de tratamento, além de avaliar o impacto de recidivas com o aumento do tempo de espera;
- avaliação dos fatores que impactam a extensão do horário de trabalho após o horário comercial;
- avaliação dos fatores que impactam a otimização do agendamento, como por exemplo, agendar consecutivamente pacientes que tratam a mesma região e utilizar tempo de sessão personalizado ao invés de tempo de sessão fixo.

2 FUNDAMENTOS TEÓRICOS

Estudos de desenvolvimento de modelos de otimização para o tratamento de pacientes de radioterapia têm atraído atenção científica e o problema de agendamento, especificamente, vem recebendo atenção em diversos setores da saúde ¹⁷. Nesse tópico, os conceitos fundamentais são apresentados para o entendimento do projeto

2.1 Big Data

A evolução na era digital levou à confluência entre saúde e tecnologia, e com isso um vasto volume de dados foram gerados. Do ponto de vista tecnológico, o elemento principal associado a ascensão do *Big Data* é a Dataficação, ou seja, a tendência de registrar qualquer fenômeno em dados ¹⁸.

O *Big Data* é o fenômeno em que dados são produzidos em vários formatos e armazenados por uma grande quantidade de dispositivos e equipamentos e esse vasto volumes de dados não pode ser gerenciado usando tecnologias convencionais. Sua definição formal, apresentada por Douglas Laney, é um conjunto de três “Vs”, que representam dados produzidos com volume, velocidade e variedade. Para dois “Vs” a mais, aparecem outras definições: veracidade e valor ^{19 20}. A Figura 2 explica cada um dos “Vs”.

FIGURA 2 - DEFINIÇÕES DOS CINCO “Vs” DE BIG DATA.



Fonte: Próprio autor.

2.2 Ciência de Dados

A expressão *Data Science* surgiu nos anos 1960, porém a ciência de dados é uma ciência nova, e por isso, por vezes controversa e mal compreendida²¹. Foi em 2001 que Cleveland usou o termo como uma extensão da estatística com foco em análise de dados e a partir de 2014 com a ascensão do *Big data* emergiu como centro de atenção dos pesquisadores.

Embora não tenhamos uma definição muito precisa de ciência de dados, poderíamos dizer que a ciência de dados é uma prática interdisciplinar que se baseia em métodos de engenharia de dados, estatística descritiva, mineração de dados, aprendizado de máquina e análise preditiva. Assim como a pesquisa operacional, a ciência de dados se concentra na implementação de decisões baseadas em dados²², ou seja, busca transformar dados em conhecimento e *insights*.

A partir de problemas podemos desenvolver perguntas e realizar investigações com ciência de dados para responder às perguntas e solucionar os problemas, ou seja, o dado é transformado em informação por meio de etapas que permitem analisar tendências e prever comportamentos futuros para tomar boas decisões.

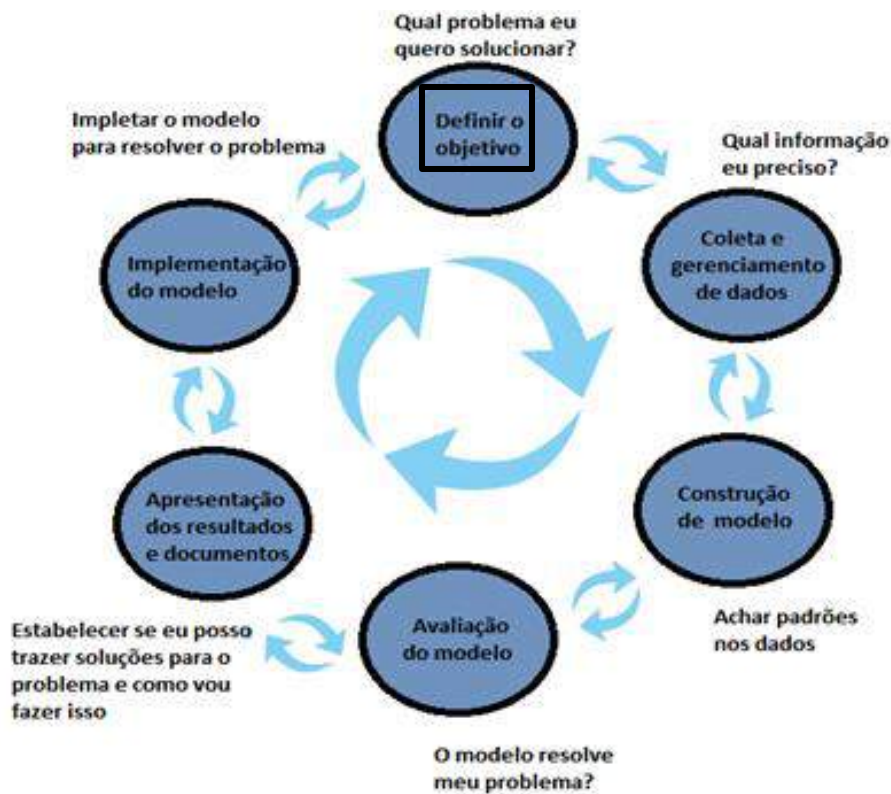
O setor de saúde gera um grande volume de dados clínicos, como os registros eletrônicos de saúde de pacientes, prescrições, relatórios clínicos, etc. Portanto, uma imensa oportunidade para analisá-los e estudá-los utilizando ciência de dados. O conhecimento adquirido dos dados pode auxiliar na tomada de decisões estratégicas possibilitando uma melhora na qualidade dos cuidados de saúde além de ajudar a construir uma visão abrangente de pacientes¹⁹.

O cientista de dados é responsável por orientar um projeto de ciência de dados em todo seu percurso, e o sucesso do projeto depende de se ter objetivos quantificáveis, boa metodologia, ações interdisciplinares e um fluxo de trabalho repetitivo. É um esforço colaborativo que se baseia em diferentes tipos de profissionais envolvidos, de habilidades e de ferramentas .

2.2.1 Etapas de um projeto de ciência de dados

Para o desenvolvimento de um projeto de ciência de dados, o ambiente ideal é aquele que incentiva *feedbacks* e interações entre o cientista de dados e as partes interessadas. A Figura 3, ilustra o ciclo de vida de um projeto ²².

FIGURA 3 - CICLO DE VIDA DE UM PROJETO DE CIÊNCIA DE DADOS.



Fonte : Adaptado de ²².

A primeira tarefa de um projeto de ciência de dados é definir uma meta mensurável e quantificável. Depois tem-se a etapa de coleta e gerenciamento dos dados, essa etapa tende a ser a mais demorada. Nesse estágio os dados são explorados e visualizados, ocorre a limpeza dos dados para corrigir erros e realizam-se transformações nas variáveis, se necessário. A visualização por gráficos e tabelas vai propiciar uma compreensão mais clara e intuitiva dos dados, além de ajudar a compreender quais variáveis são de fato importantes para o processo.

Na etapa de modelagem ocorre a extração de informações úteis dos dados buscando alcançar os objetivos propostos. Há utilização de estatística e de aprendizado de máquina. Os principais objetivos de um modelo são:

- Classificação: decidir se algo pertence a uma categoria ou outra;
- Pontuação: prever ou estimar um valor numérico, como um preço ou probabilidade;
- Ordenação: aprender a ordenar itens por preferências;
- Agrupamento: agrupamento de itens em grupos mais semelhantes;
- Relacionamento: encontrar correlações ou potenciais causas e efeitos vistos no dados e;
- Caracterização: plotagem e geração de relatórios a partir de dados.

Parte do trabalho da ciência de dados é realizar previsões, e para isto existem métodos estatísticos que podem ser aplicados. Em geral, podemos dividir as situações em problemas de regressão ou classificação.

Uma vez que o modelo é proposto, é preciso determinar se os objetivos foram alcançados e, com a implementação do modelo, novos problemas e perguntas podem surgir e um outro projeto de acompanhamento pode ser necessário.

2.3 Aprendizado de Máquina

O aprendizado de máquina é um subcampo da IA por meio da qual a máquina aprende uma tarefa para a qual não se tem um algoritmo pré-estabelecido, ou seja, para a qual não existe uma sequência de instruções (passos) que devem ser executados, para transformar uma entrada no resultado esperado ²³. As tarefas podem ser divididas em duas categorias: preditivas e descritivas. Para as preditivas, a meta é encontrar uma função, a partir dos dados de treinamento, que possa ser utilizada para prever um rótulo ou um valor que caracterize um novo exemplo, com base nos valores de seus atributos de entrada. Para as tarefas descritivas, a meta consiste na exploração ou descrição de um conjunto de dados. Uma tarefa descritiva de agrupamento de dados, por

exemplo, tem por meta encontrar grupos de objetos semelhantes nos conjuntos de dados.

Um exemplo de tarefas preditivas é dizer se um *e-mail* é *spam* ou não. Há uma entrada: um *e-mail*, que na forma mais simples, é uma sequência de caracteres; há também a saída desejada: um rótulo (sim/não) que indique se o *e-mail* é *spam* ou não. Mas não se tem um algoritmo, isto é, não se sabe como transformar a entrada em saída. O que é considerado *spam* muda ao longo do tempo e também de indivíduo para indivíduo. Para tarefas deste tipo, quando não se tem um algoritmo definido, a abordagem é “aprender a partir dos dados”. No caso do *e-mail*, coletam-se milhares de mensagens, algumas das quais são sabidamente *spam* e então aprende-se destas mensagens quais constituem *spam*. Em outras palavras, queremos que o computador (máquina) extraia automaticamente o algoritmo para esta tarefa, ou seja, queremos que a máquina aprenda uma tarefa para a qual não temos um algoritmo pré-estabelecido.²⁴

Para análises preditivas, a resposta à perguntas como: por onde começar? quais dados usar? e como obter essas informações dos dados? está no aprendizado de máquina ²³.

Nas tarefas de aprendizado de máquina, como citado anteriormente, podemos ter exemplos dos tipos de saída esperados; no caso do *e-mail*, temos mensagens que sabidamente são *spam*, isto é, estão rotuladas como tal, e mensagens que sabidamente não são *spam*, isto é, estão rotuladas como não sendo *spam*. Esta classe de tarefas de aprendizado de máquina é chamada de aprendizado supervisionado, onde os exemplos servem para “treinar” a máquina ²⁵. Dentro do aprendizado supervisionado, classificação e regressão são dois tipos de aplicação com a finalidade de prever valores de uma função objetivo, dado um valor de entrada ainda não conhecido.

A tarefa de regressão consiste em aproximar uma função contínua a partir de um conjunto de exemplos compostos de pontos. Já o objetivo da tarefa de classificação é construir um classificador que possa determinar corretamente as classes de novos exemplos ainda não rotulados, dado um conjunto de classes e um conjunto de exemplos de treinamento. Há também tarefas chamadas de aprendizado não supervisionado, onde a máquina deve aprender por si só quais são as saídas esperadas, sem ter nenhum exemplo para o aprendizado, ou seja,

não se tem uma variável de resposta que é usada para supervisionar o modelo. Um exemplo dessa modalidade é a análise de *cluster*. Nessa subárea temos pouca ou nenhuma ideia de como serão os resultados encontrados.

Outra abordagem de máquina de aprendizagem é o aprendizado por reforço. Nessa abordagem, há um conjunto de ações que podem ser selecionadas em cada estado, e cada ação é associada a uma probabilidade de seleção. Quando um agente seleciona uma ação e a executa, o agente recebe uma avaliação ou um sinal de reforço do ambiente. O sinal de reforço é então usado para mudar as probabilidades de seleção para ensaios futuros. A Tabela 1 mostra alguns algoritmos típicos de aprendizado de máquina, para tarefas de aprendizado supervisionado e não supervisionado e suas características.

TABELA 1 - AS PRINCIPAIS CARACTERÍSTICAS DE CADA ALGORITMO DE APRENDIZADO PREDITIVO UTILIZADO NO TRABALHO.

| ALGORITMO | DESCRIÇÃO | APLICAÇÃO | VANTAGENS | DESVANTAGENS |
|----------------------------|--|---------------------------|--|---|
| Regressão Linear | <ul style="list-style-type: none"> * Melhor linha de ajuste para todos os pontos dos dados * Previsão numérica | Regressão | <ul style="list-style-type: none"> * Funciona com qualquer conjunto de dados * Fornece informação sobre relevância da variável * Fácil de entender * Modelo explicativo * Rápido | <ul style="list-style-type: none"> * Não captura relações não lineares * Sensível a <i>outliers</i> * Tendência de <i>overfit</i> * Não captura relações mais complexas |
| Regressão Logística | <ul style="list-style-type: none"> * Adaptação da regressão linear para problemas de classificação. * Utiliza função logística. * Previsão categórica. * Preve variáveis binárias (1 ou 0) | Classificação | <ul style="list-style-type: none"> * Fácil de entender * Rápido | <ul style="list-style-type: none"> * Tendência de <i>overfit</i> * Não captura relações mais complexas |
| Árvore de Decisão | <ul style="list-style-type: none"> * Usa o método de ramificações e combina os resultados possíveis em um gráfico | Regressão e Classificação | <ul style="list-style-type: none"> * Fácil interpretação | <ul style="list-style-type: none"> * Geralmente muito simples para relações muito complexas * Crescimento excessivo da árvore para poucas observações consequentemente resultado pobre * Sujeito a <i>Overfitting</i> |
| Random Forest | <ul style="list-style-type: none"> * Gera várias árvores de decisão e usa o voto da maioria para decidir a classe final para o modelo de classificação e usa a média de predição para a predição final de regressão | Regressão e Classificação | <ul style="list-style-type: none"> * Leva em conta interações de variáveis não lineares * Alta <i>performance</i> * Boa precisão | <ul style="list-style-type: none"> * Difícil de interpretar os resultados * <i>Overfitting</i> pode ocorrer * Necessário escolher o número de árvores * Pode ser lento para treinar |
| XGBOOST | <ul style="list-style-type: none"> * Funciona parecido com o Random Forest porém mais preciso pois foca no erro cometido pelas árvores de decisão anteriores e tenta corrigir os erros | Regressão e Classificação | <ul style="list-style-type: none"> * Alta <i>performance</i> * Lida bem com dados faltantes * Alta precisão * Relativamente rápido para treinar * Existem parâmetros para evitar <i>overfitting</i> | <ul style="list-style-type: none"> * As associações encontradas são complexas e difíceis de entender * Difícil de interpretar os resultados * Depende muito dos dados de treinamento * Mais parâmetros para definir no modelo * Sujeito a <i>overfitting</i> se parâmetros não forem adequados |
| Rede Neural | <ul style="list-style-type: none"> * Imita o comportamento do cérebro * Pode apresentar camadas | Regressão e Classificação | <ul style="list-style-type: none"> * Lida com tarefas extremamente complexas * O melhor para reconhecimento de imagens * Boa precisão * Adaptável para muitos tipos de problemas | <ul style="list-style-type: none"> * Lento para treinar * Exige muito poder computacional * Difícil de interpretar os resultados * Requer grande quantidade de dados de treinamento * Mais parâmetros para definir no modelo |
| SVM | <ul style="list-style-type: none"> * Encontra um hiperplano que melhor separa os <i>outputs</i> | Regressão e Classificação | <ul style="list-style-type: none"> * Facilmente adaptável * Robusto em relação a <i>overfitting</i> * Trabalha com problemas não lineares * Não tendencioso por <i>outliers</i> * Poucos parâmetros para ajustar o modelo . Opção Kernel * É mais efetivo quando tem mais colunas do que linhas na base de dados | <ul style="list-style-type: none"> * Difícil de interpretar os resultados * Demora para convergir * Difícil de escolher os valores dos parâmetros do modelo * Não funciona bem em bases de dados grandes |

Fonte: Próprio autor.

O uso de modelos preditivos de aprendizado de máquina tem o potencial de auxiliar na tomada de decisão nos diversos momentos da atenção à saúde, especialmente no diagnóstico, intervenção e acompanhamento de problemas de saúde ²⁶.

O aumento da complexidade dos problemas a serem tratados computacionalmente, assim como o volume de dados gerados por diferentes atividades têm favorecido a expansão dessa área ²⁶.

2.3.1 Regressão Linear

Os modelos preditivos de regressão linear visam verificar se existe uma relação entre duas ou mais variáveis. O problema, portanto, encontra-se na predição de valores contínuos para a variável de interesse ²⁷.

Dado um conjunto com n observações e $(m+1)$ variáveis, cujos valores são representados por $(y_i, x_{i1}, x_{i2}, \dots, x_{im})$, $i = 1, 2, \dots, n$, o modelo de regressão linear estabelece uma relação entre a variável resposta ou de interesse (y) e as variáveis explicativas ou preditoras $(x_{i1}, x_{i2}, \dots, x_{im})$, da seguinte forma:

$$\hat{y}_i = a_0 + a_1 x_{i1} + a_2 x_{i2} + \dots + a_m x_{im} + e_1 \quad \text{EQUAÇÃO 1}$$

Onde a_0, \dots, a_m são chamados de coeficientes e representam o aumento/decréscimo médio esperado para quaisquer mudanças na respectiva variável preditora, independentemente das restantes preditoras, e e_1 é o erro ou parte não capturada pelo modelo, independente e identicamente distribuído.


A estimação dos coeficientes a_0, \dots, a_m é realizada de forma a minimizar a soma dos quadrados das diferenças entre cada ponto observado e o seu valor estimado pela reta. Esta diferença é conhecida como resíduo. Em outras palavras, minimizar o erro quadrático médio (MSE), dado por:

$$\sum_{i=1}^n [y_i - (a_0 + a_1 x_{i1} + a_2 x_{i2} + \dots + a_m x_{im})]^2 \quad \text{EQUAÇÃO 2}$$

Sendo, n , o número de observações de treinamento utilizadas na elaboração do modelo. A Figura 4 apresenta um exemplo de ajuste do modelo

de regressão linear simples para alguns dados com uma linha representando a tendência geral.

FIGURA 4 - EXEMPLO DE REGRESSÃO LINEAR SIMPLS.



Fonte: Próprio autor.

2.3.2 Regressão Logística

O modelo de regressão logística utiliza a curva logística para representar a relação entre a variável categórica de interesse e as variáveis predictoras. Este modelo estabelece uma relação entre a probabilidade de ocorrência das variáveis. A Figura 5 apresenta um exemplo da curva logística. Em aprendizado de máquina, a regressão logística é utilizada para tarefas de classificação, ou seja, em que a variável de interesse é categórica. Nesse caso, a variável de interesse assume valores 0 ou 1, onde 1 geralmente é utilizado para indicar a ocorrência do evento de interesse ²⁸. Uma nomenclatura bastante utilizada para os valores 0 e 1 é classe negativa e classe positiva, respectivamente.

De forma simplificada, o modelo logístico pode ser definido da seguinte maneira:

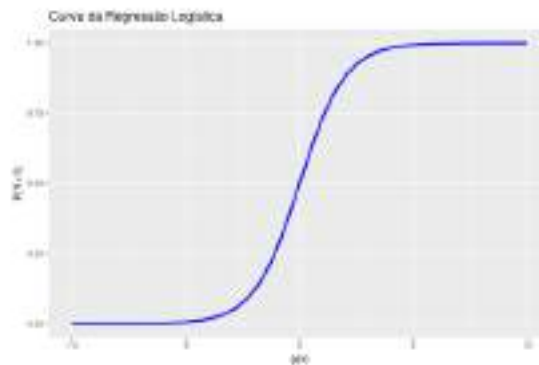
$$\hat{y} = f(Z) = P(y = 1|Z) = \frac{1}{1+e^{-Z}} \quad \text{EQUAÇÃO 3}$$

Onde $P(y = 1|Z)$ é a probabilidade de ocorrência da classe positiva dado o valor de Z.

$$Z = \ln\left(\frac{p}{1-p}\right) \quad \text{EQUAÇÃO 4}$$

Onde p indica a probabilidade de ocorrência do evento de interesse.

FIGURA 5 - EXEMPLO REGRESSÃO LOGÍSTICA.



Fonte: Retirada de ²⁸.

Nessa regressão, encontra-se uma combinação de coeficientes que maximiza a probabilidade de ocorrência do evento de interesse. Dessa forma, um modelo de regressão logística utilizado para a classificação binária de uma variável de interesse irá prever a probabilidade de pertencer à classe positiva. Tem-se, portanto, que y^{\wedge} é dado por:

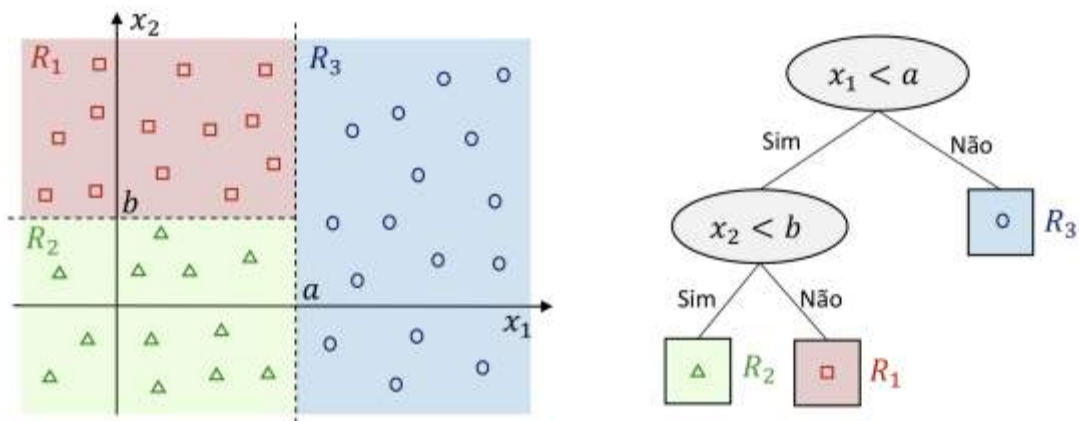
$$y^{\wedge} = \begin{cases} 0, & \text{se } Prob(y = 1|X) < 0,5 \\ 1, & \text{se } Prob(y = 1|X) \geq 0,5 \end{cases} \quad \text{EQUAÇÃO 5}$$

Onde X é o vetor das variáveis preditoras.

2.3.3 Árvore de Decisão (AD)

A árvore de decisão é utilizada para classificação e regressão, o algoritmo de árvore de decisão proporciona uma grande facilidade de interpretação. Uma árvore de decisão é uma estrutura hierárquica, na qual cada nó interno representa uma decisão em um dos atributos do conjunto de dados, e cada ramo representa uma tomada de decisão. Nessa árvore, as folhas representam o rótulo da classe predita. A Figura 6 apresenta um exemplo de árvore de decisão, onde as variáveis x_1 e x_2 representam os atributos do conjunto de dados (variáveis preditoras) e os símbolos \square , \circ e Δ indicam os rótulos de classe observados na amostra ²⁸.

FIGURA 6 - ÁRVORE DE DECISÃO APLICADA A UMA TAREFA DE CLASSIFICAÇÃO.



Fonte: Retirado de ²⁹.

Uma vez construída a árvore, dado um conjunto de atributos preditores para os quais se deseja conhecer o valor da classe, tais atributos são testados por meio da árvore de decisão, onde um caminho é traçado a partir da raiz até um nó da folha, o qual irá representar a classe predita. O processo de dividir o conjunto de dados D em partições, por meio de um atributo que virá a ser um nó da árvore, busca gerar subdivisões de D em que, idealmente, cada partição tenha mais dados pertencentes a uma mesma classe. Na busca por otimizar esse resultado, o critério de seleção do atributo que irá particionar os dados será o atributo que resulta em um maior número de partições que se aproximam do objetivo proposto. Dizemos então que este atributo tem uma maior capacidade de resumir D ^{28 29}.

2.3.4 Random Forest (RF)

O algoritmo de *random forest* é utilizado para tarefas de regressão e classificação. Trata-se de um *ensemble* de árvores de decisão que são construídas com base na estratégia de *bagging* (seleção aleatória com repetição).

O algoritmo de *random forest* consiste na construção de diversas árvores de decisão. O vetor de testes, $x = (x_1, x_2, x_3, \dots, x_n)$, será classificado por cada uma dessas árvores. Ao final, irá ocorrer uma votação para decidir qual será a

classe mais adequada para a entrada, prevalecendo a classe indicada pela maioria das árvores de decisão que compõe a floresta.

Leo Breiman e Adele Cutler ³⁰ descrevem a construção de cada uma das árvores de decisão com o seguinte sumário: Considera-se que existem N vetores de entrada e cada um possui M atributos.

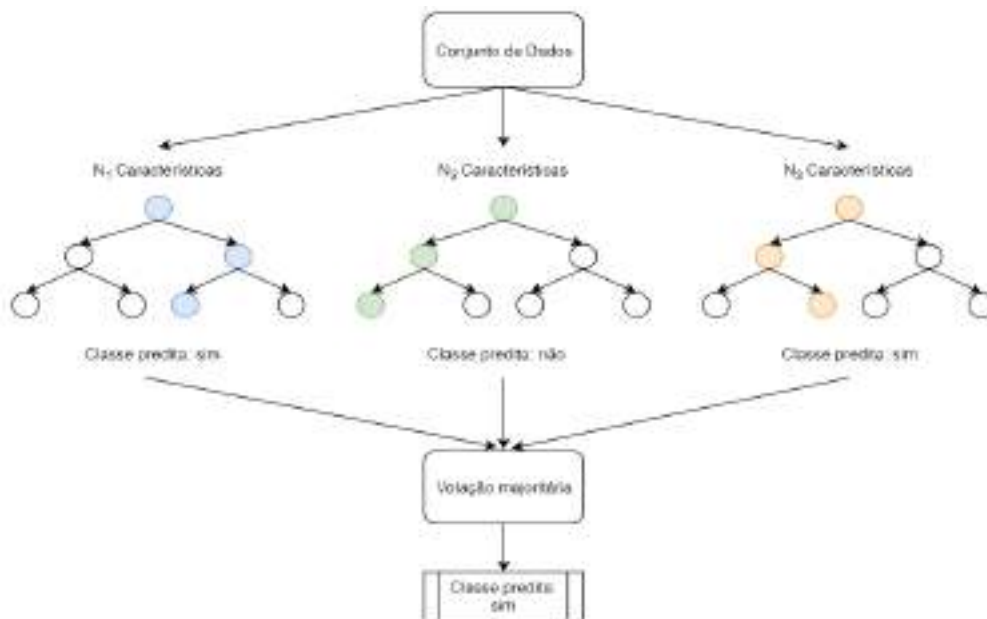
1. Para o treinamento de uma nova árvore, é realizada uma reamostragem de tamanho N no conjunto de dados original (N é normalmente dado como \sqrt{m} , onde m é o número de variáveis preditoras). Ou seja, a partir da matriz primária são geradas diversas outras para treinar cada uma das árvores.

2. A cada divisão de um nó, um número $m \ll M$ é escolhido, tal que “ m ” variáveis são selecionadas aleatoriamente a partir de M , e a melhor divisão dessas variáveis será utilizada para dividir o nó. O valor de “ m ” será constante durante todo o treinamento.

3. Cada árvore cresce até o maior tamanho possível, sem que sofra nenhum tipo de “poda”.

Na ocasião da predição para uma determinada instância, as N árvores fazem a predição, e a média dos valores preditos é a predição final. Para os problemas de classificação, a classe majoritariamente predita é considerada a classe da instância.

FIGURA 7 - ILUSTRAÇÃO DO ALGORITMO RANDOM FOREST.



Fonte: Retirada de 28.

A classe predita da instância em questão é a classe majoritária predita pelo comitê de árvores. O método de *bagging*, portanto, baseia-se em criar preditores em amostras *bootstrap* dos dados, e depois agregá-los, ou combiná-los, para formar um preditor, o qual é esperado apresentar um resultado superior quando comparado a um algoritmo tradicional.

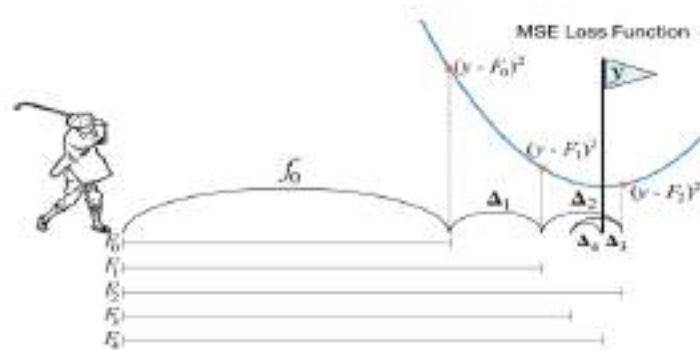
2.3.5 Extreme Gradient Boosting (XGBoost)

De acordo com Chambers e Dinsmore (2014)³¹, *Gradient Boosted Trees* é um algoritmo que produz diferentes modelos sequenciais de árvores de decisão, cujos resultados são adicionados para que o modelo final seja uma combinação dos anteriores, apresentando uma capacidade de predição muito superior à dos modelos individuais que foram gerados.

A cada iteração do algoritmo, uma árvore é gerada de modo a aprender e minimizar os erros da árvore anterior. A Figura 8 ilustra o princípio de funcionamento do algoritmo *Gradient Boosted Trees* como uma sequência de tacadas de golfe. A primeira tacada (F_0) representa a primeira árvore gerada. Em função da distância da posição bola (y^\wedge) até buraco (y), constrói-se uma nova árvore (F_1) com o objetivo de prever Δ_1 , para que $y^\wedge = F_0 + \Delta_1$. Após algumas

iterações, um conjunto de árvores foi construído na busca por estimar os erros das árvores anteriores. Dessa forma, para o exemplo em questão, a predição final será dada por: $y^{\wedge} = F_0 + \Delta_1 + \Delta_2 + \Delta_3 + \Delta_4$, onde F_0 é a árvore inicial, e Δ_1 , Δ_2 , Δ_3 e Δ_4 são valores preditos por árvores geradas para aprender e minimizar os erros das árvores respectivamente anteriores.

FIGURA 8 - PRINCÍPIO DE FUNCIONAMENTO DO ALGORITMO GRADIENT BOOSTED TREES.



Fonte: Retirada de ³².

2.3.6 Redes Neurais Artificiais (RNA)

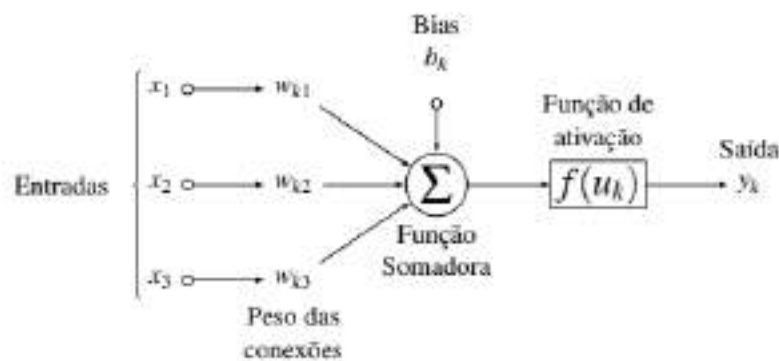
Modelos computacionais de redes neurais artificiais são inspirados na estrutura neural de organismos inteligentes, os quais adquirem conhecimento por meio da experiência. As redes possuem unidades de processamento denominadas neurônios artificiais, os quais, por meio de uma rede de interligação, processam os sinais de entrada, na busca pela predição da variável de interesse, que é possível por meio do encaminhamento do sinal de entrada pela rede, simulando um processo de sinapse ^{28 33}.

Nas RNAs o processamento ocorre nos neurônios artificiais, que estão interconectados. Os dados de entrada $\{x_1, x_2, \dots, x_n\}$ são os sinais externos normalmente normalizados para melhorar a eficiência computacional dos algoritmos de aprendizagem, ou seja, são os dados que alimentam o modelo. Para ponderar os sinais de cada entrada da rede existem os pesos sinápticos $\{w_1, w_2, \dots, w_n\}$ que devem ser ajustados durante o treinamento. O combinador linear Σ agrega todos os sinais de entrada que foram ponderados pelos

respectivos pesos sinápticos a fim de produzir um potencial de ativação, sendo que, se o valor for positivo, então o neurônio produz um potencial excitatório; caso contrário, o potencial será inibitório. O neurônio também conta com um valor limiar b_k que tem o papel de aumentar ou diminuir a influência do valor das entradas para a ativação do neurônio. Esse potencial de ativação passará por uma função de ativação $f(u_k)$ que tem como objetivo limitar a saída de um neurônio para um intervalo de valores dando origem a um sinal de saída ^{34 35}. Assim, o valor de saída do neurônio k , denominado y_k , é dado por:

$$y_k = f(u_k) = f(\sum_{j=1}^m w_{kj}x_j + b_k) \quad \text{EQUAÇÃO 6}$$

FIGURA 9 - ARQUITETURA REDES NEURAIAS.



Fonte: Retirado de ³⁵.

Ao longo da construção de modelos de RNAs, diversos pontos devem ser estabelecidos como:

- (i) a determinação do conjunto de neurônios artificiais;
- (ii) a escolha da arquitetura das redes neurais artificiais, isto é, o padrão de conectividade entre os neurônios e as suas respectivas funções de ativação, e
- (iii) a escolha do método de determinação dos parâmetros da rede, conhecido como algoritmo de aprendizagem.

A escolha adequada da função de ativação $f(u_k)$ e de suas propriedades contribuem para melhorar o processo de convergência da rede durante seu treinamento. Existem diversas funções matemáticas que são utilizadas como

função de ativação. As funções de ativação mais comumente usadas são: a função sigmóide logística e a função tangente hiperbólica. Com o advento das redes neurais profundas, a função de ativação retificadora linear (ReLU) também tem sido bastante utilizada.

A função custo mais utilizada é a do erro quadrático médio definido como ^{35 36}.

$$F(\Psi) = \sum e_t^2 = \sum_t (y_t - d_t)^2 \quad \text{EQUAÇÃO 7}$$

Onde Ψ é o espaço de todos os pesos de conexão e d_t é a resposta desejada para a saída da rede, conhecida durante o treinamento.

As técnicas de otimização usadas para minimizar a função custo são chamadas de regras de aprendizado. A regra de aprendizado mais conhecida na literatura é a da retropropagação (*Backpropagation*) ^{35 36}. Nessa regra, o algoritmo vai aprender por meio da retropropagação a fim de otimizar o ajuste dos pesos para minimizar a função custo.

Outra classificação das redes neurais artificiais está relacionada com a maneira como a rede processa os dados, podendo ser redes diretas (*feedforward*) ou redes recorrentes ³⁷. Nas redes *feedforward*, as conexões entre os neurônios não formam ciclos, pois o sentido de propagação é único. Já nas redes recorrentes, há ciclos nas conexões, tornando o treinamento mais complexo, mas especializando a rede para certos tipos de aplicação, como os sistemas variantes no tempo. As redes recorrentes diferem das redes *feedforward* porque incluem um *loop* de retroalimentação, pelo qual a saída do passo anterior é enviada de volta à rede para afetar o resultado do passo atual, e assim por diante para cada etapa subsequente.


A RNA passa a ser conhecida como um algoritmo de *deep learning* (aprendizado profundo) quando sua arquitetura é formada por múltiplas camadas. As camadas internas das redes neurais artificiais são denominadas camadas ocultas.

2.3.7 Máquinas de Vetores de Suporte (SVM)

Nesta técnica, os pontos de dados são plotados em um espaço de n -dimensões (onde n é o número de recursos) com o valor de cada recurso sendo o valor de uma determinada coordenada. Em um cenário de classificação, uma máquina de vetor de suporte constrói um hiper-plano para alcançar uma boa separação que tenha a maior distância até os pontos de dados de qualquer classe. Por outro lado, em uma situação de regressão, uma máquina de vetor de suporte constrói um hiperplano que melhor se adapte aos dados dentro de alguma margem ^{38 39}. As SVMs baseiam-se em 2 ideias:

- para espaços bidimensionais, o SVM sempre procurará uma solução global já que o algoritmo se preocupa apenas com os vetores próximos ao limite de decisão (vetores de suporte) e para espaço de mais dimensões, os limites de decisão se transformam em hiperplanos.
- utilizar uma transformação (possivelmente) não linear às entradas para um espaço de características lineares, via uma função de kernel.

FIGURA 10 - CONSTRUÇÃO DE UM PLANO DE SEPARAÇÃO DO SVM.




Fonte: Retirado de ³⁹.

A Figura 10 mostra um hiperplano de separação para pontos de dados bidimensionais; os círculos e os quadrados representam, respectivamente, pontos de dados nas classes -1 e $+1$. Nas linhas pontilhadas, em preto, estão os vetores de suporte.

Considere, por exemplo, o conjunto de treinamento da Figura 11. O objetivo do processo de aprendizado é encontrar um classificador que separe os dados das classes “círculo” e “triângulo”. As funções ou hipóteses consideradas são ilustradas na figura por meio das bordas, também denominadas fronteiras de decisão, traçadas entre as classes.

FIGURA 11 - EXEMPLO DE UM CLASSIFICADOR COM SVM.



Fonte: Retirado de ⁴⁰.

Na imagem da Figura 11a, tem-se uma hipótese que classifica corretamente todos os exemplos do conjunto de treinamento, incluindo dois possíveis ruídos. Por ser muito específica para o conjunto de treinamento, essa função apresenta elevada suscetibilidade a para cometer erros quando confrontada com novos dados. Esse caso representa a ocorrência de um superajustamento do modelo aos dados de treinamento.

Um outro classificador poderia desconsiderar pontos pertencentes a classes opostas que estejam muito próximos entre si. A ilustração da Figura 11c representa essa alternativa. Tem-se assim, a ocorrência de um subajustamento, pois o classificador não é capaz de se ajustar mesmo aos exemplos de treinamento.

Um meio termo entre as duas funções descritas é representado na Figura 11b. Esse preditor tem complexidade intermediária e classifica corretamente grande parte dos dados, sem se fixar demasiadamente em qualquer ponto individual ³⁹.

2.4 Métricas de validação dos algoritmos

As métricas de validação buscam avaliar o desempenho do modelo treinado em dados desconhecidos. As principais métricas para avaliação de modelos de classificação de dados são sensibilidade, especificidade, acurácia, precisão e *F-score*, sendo que a definição de cada métrica se encontra na Tabela 2.

TABELA 2 - MÉTRICAS USADAS PARA AVALIAR MÉTODOS DE CLASSIFICAÇÃO: VP: VERDADEIROS POSITIVOS; FN: FALSOS NEGATIVOS; FP: FALSOS POSITIVOS; VN: VERDADEIROS NEGATIVOS; P: PRECISÃO; S: SENSIBILIDADE; N: TOTAL DE ELEMENTOS.

| Método | Fórmula |
|----------------|---------------------------------|
| Sensibilidade | $VP / (VP+FN)$ |
| Especificidade | $VN / (FP+VN)$ |
| Acurácia | $(VP+VN) / N$ |
| Precisão | $VP / (VP+FP)$ |
| F-score | $2 \times (P \times S) / (P+S)$ |

Fonte: Retirado de ⁴¹

De acordo com Ferrari e Silva (2017) ⁴¹, em problemas de classificação binária, predições podem ter quatro possíveis classes:

- **Verdadeiro positivo (VP):** quando o método diz que a classe é positiva e, ao verificar a resposta, vê-se que a classe realmente é positiva;
- **Verdadeiro negativo (VN):** quando o método diz que a classe é negativa e, ao verificar a resposta, vê-se que a classe realmente é negativa;
- **Falso positivo (FP):** quando o método diz que a classe é positiva, mas ao verificar a resposta, vê-se que a classe é negativa;
- **Falso negativo (FN):** quando o método diz que a classe é negativa, mas ao verificar a resposta, vê-se que a classe é positiva;

A matriz de confusão é uma maneira simples de representar os resultados de um método de classificação. Ela indica a quantidade de ocorrências que o

programa teve para cada uma das quatro categorias. A acurácia (ACC) avalia simplesmente o percentual de acertos, a sensibilidade (também conhecida como *recall*) avalia a capacidade do método de detectar com sucesso resultados classificados como positivos, a especificidade avalia a capacidade do método de detectar resultados negativos, a precisão é uma métrica que avalia a quantidade de verdadeiros positivos sobre a soma de todos os valores positivos e o *F-score* é uma média harmônica calculada com base na precisão e *recall*.

Já as métricas para modelos de regressão são projetadas para estimar a quantidade de erros. Busca-se com o modelo, minimizar a diferença entre os valores observados e os valores previstos. Para modelos de regressão as principais métricas são:

- **Erro absoluto médio (MAE)** mede a distância das previsões dos resultados reais, assim, quanto menor esse valor, melhor.
- **Raiz do quadrado médio (RMSE)** cria um valor único que resume o erro do modelo. Ao elevar a diferença ao quadrado, a métrica desconsidera a diferença entre uma previsão abaixo e uma previsão acima do valor real.
- **Erro relativo absoluto (RAE)** é a diferença relativa absoluta entre os valores esperado e real. Ele é relativo porque a diferença média é dividida pela média aritmética.
- **Erro relativo ao quadrado (RSE)** normaliza similarmente o erro ao quadrado total dos valores previstos ao dividi-lo pelo erro total ao quadrado dos valores reais.
- **Coefficiente de determinação**, frequentemente chamado de R^2 , representa o poder de previsão do modelo como um valor entre 0 e 1. Zero significa que o modelo é aleatório (não explica nada) e 1 significa que há um ajuste perfeito. No entanto, deve-se ter cuidado ao interpretar valores de R^2 , pois valores baixos podem ser totalmente normais e valores altos podem ser suspeitos.

2.5 Pesquisa Operacional

A pesquisa operacional (PO) é uma ciência aplicada para melhorar a tomada de decisão de problemas reais e procura trazer para o campo da tomada de decisões o conhecimento de outras áreas científicas como matemática, ciência da computação e engenharia. Originalmente, a PO emergiu como um caminho para melhorar várias operações militares na segunda guerra mundial, mas esse método vem ganhando espaço para modelar e resolver problemas em diversas áreas ⁴². Esse método tem como filosofia criar modelos matemáticos, apoiados em dados e fatos, que lhes permitem perceber os problemas em estudo e avaliar o resultado hipotético de estratégias ou decisões alternativas.

Problemas de PO são usualmente modelados na forma de uma função objetivo (por exemplo, maximizar o lucro da empresa ou minimizar gastos) considerando diversas restrições (associadas, por exemplo, à disponibilidade de matérias-primas, mão-de-obra, etc.). Os métodos de otimização podem ser divididos em programação linear (em que a função objetiva é representada por funções lineares das variáveis de projeto) e não linear (com função objetiva não linear) ⁴³.

Em problemas matemáticos determinísticos, todos os dados de entrada (parâmetros) do problema são conhecidos a priori e nenhuma aleatoriedade em sua ocorrência é admitida. Já nos estocásticos, seus elementos apresentam uma probabilidade de ocorrência em uma determinada forma ^{44 45}.

As técnicas de PO são aplicadas a uma ampla variedade de problemas decisórios, que vão desde a determinação de tempo em filas de um banco até alocação de investimentos e programação de tarefas ⁴³.

Desde 1950, a aplicação de PO em cuidados em saúde produz resultados significativos em ganhos de eficiência na prestação de serviço a saúde, e tem sido amplamente aplicada para o planejamento e controle da capacidade de recursos ⁴⁶.

A radioterapia engloba uma vasta gama de tipos de problemas que podem se beneficiar com a aplicação de PO. De acordo com o quadro proposto por Hans, Houdenhoven e Hulshof (2012) ⁴⁷, decisões gerenciais podem ser divididas em quatro áreas: planejamento médico, planejamento de capacidade

de recursos, planejamento de materiais e planejamento financeiro. O foco desse trabalho será o planejamento da capacidade de recursos e dentro desse foco a estrutura do problema de decisão que está sendo abordada pode ser dividida em quatro categorias ⁴²: 1. decisões estratégicas gerenciais 2. recursos de planejamento 3. priorização do paciente 4. agendamento

2.5.1 Projeto de Pesquisa Operacional

Para executar adequadamente um estudo de pesquisa operacional é interessante que sejam seguidos alguns passos ⁴⁸:

1. Formulação do problema: o responsável pela modelagem deve extrair do responsável pela tomada de decisão o problema que ele deseja resolver para que possa estabelecer os objetivos do modelo.

2. Observação do sistema: coletar os dados necessários, sendo que eles podem ser determinísticos (conhecidos com certeza) ou probabilísticos (conhecida a distribuição de sua probabilidade).

3. Construção do modelo matemático: desenvolvimento do modelo. Além de ser uma representação simplificada da realidade, os modelos matemáticos podem revelar relacionamentos entre as variáveis que não seriam evidentes de outro modo.

4. Verificação do modelo: avaliar a precisão do modelo. É importante que tanto o modelo quanto a solução sejam testados para verificar se todos os componentes foram incluídos no modelo e se ele pode ser executado. Realiza-se uma análise de sensibilidade, com o objetivo de verificar até que ponto pequenas alterações nos dados do problema modificam o resultado.

5. Seleção de uma solução alternativa: dado o modelo e um conjunto de alternativas, escolher a melhor opção que atinge o objetivo proposto.

6. Apresentação dos resultados: apresentação do modelo e recomendações.

7. Implantação e avaliação da recomendação: uma vez que todas as etapas anteriores foram concluídas, a solução pode ser

empregada na prática para resolver o problema. O sistema deve ser constantemente monitorado.

Vários modelos baseados em PO foram desenvolvidos para resolver problemas de agendamento de tratamento de radioterapia, como mostrado na revisão da literatura realizada por Vieira et al ⁴². No entanto, sua revisão também revelou que nenhum dos 18 artigos revisados relatou uma pré-implementação do modelo, sugerindo que as taxas de implementação de abordagens PO em radioterapia são bastante baixas.

2.5.2 Programação Linear (PL)

A pesquisa operacional compreende um conjunto relativamente grande de técnicas que podem ser utilizadas para resolução de problemas decisórios. As principais são ⁴³: algoritmos genéticos; cadeias de Markov; grafos; modelos de estoques; modelos de previsão; programação dinâmica; programação linear; programação não linear; redes neurais artificiais; simulação; teoria da decisão; teoria das filas e teoria dos jogos. A PL é uma das mais importantes e mais utilizadas técnicas de pesquisa operacional.

A modelagem é inteiramente expressa em termos de equações lineares (tanto para as restrições como para a função objetivo). A construção de um modelo de programação linear segue três passos básicos ⁴⁵.

Passo I. Identificar as variáveis desconhecidas a serem determinadas (elas são denominadas variáveis de decisão) e representá-las através de símbolos algébricos (por exemplo, x e y ou x1 e x2).

Passo II. Listar todas as restrições do problema e expressá-las como equações (=) ou inequações (\leq , \geq) lineares em termos das variáveis de decisão definidas no passo anterior.

Passo III. Identificar o objetivo ou critério de otimização do problema, representando-o como uma função linear das variáveis de decisão. O objetivo pode ser do tipo maximizar ou minimizar.

As equações de um modelo geral são:

Função objetivo:

$$Z = c_1 x_1 + c_2 x_2 + \dots + c_n x_n \quad \text{EQUAÇÃO 8}$$

Restrições:

$$a_{11} x_1 + a_{12} x_2 + \dots + a_{1n} x_n <, =, \text{ou} > b_1$$
$$a_{21} x_1 + a_{22} x_2 + \dots + a_{2n} x_n <, =, \text{ou} > b_2 \quad \text{EQUAÇÃO 9}$$

.....

$$a_{m1} x_1 + a_{m2} x_2 + \dots + a_{mn} x_n <, =, \text{ou} > b_m$$

Onde Z é a função objetivo, c_i são os coeficientes da função objetivo, x_j as variáveis de decisão, a_i os coeficientes técnicos e b_i as constantes do lado direito das equações de restrições.

O objetivo é otimizar (maximizar ou minimizar) uma determinada função objetivo, porém ao otimizá-la o resultado deverá obedecer às equações de restrições.

Alguns problemas reais requerem o uso de variáveis que assumem somente valores inteiros. Quando isto acontece tem-se um problema de programação linear inteira (PLI). Em outros problemas, algumas das variáveis são reais não negativas e outras são inteiras e binárias, nesse caso tem-se um problema de programação linear inteira mista (PLIM).

Existem muitos problemas de programação de agendamento de produção que podem ser colocados como problemas de PLIM, pois os modelos matemáticos de otimização correspondentes envolvem variáveis contínuas e discretas que devem satisfazer um conjunto de restrições lineares de igualdade e desigualdade ⁴⁹.

Para cada tipo de modelo matemático existem diversas técnicas de otimização conhecidas. Por exemplo, os problemas de PL podem ser resolvidos usando um tipo de algoritmo Simplex ou um algoritmo de Pontos Interiores. Para resolver um problema não linear pode-se usar várias técnicas tradicionais de otimização (técnicas baseadas em gradiente, relaxação Lagrangeana, método

de Newton, programação linear sucessiva, etc.) ou recentemente um algoritmo de pontos interiores. Para resolver um problema de PLIM pode-se usar a decomposição matemática de Benders, plano de cortes de Gomory ou um algoritmo tipo *branch and bound* (e suas versões modernas *branch and cut* ou *branch and price*). Cabe destacar que para os problemas de PL e PLIM existem condições necessárias e suficientes de otimização teoricamente provadas que garantem se uma dada solução factível é ótima ou não ⁵⁰.

Tradicionalmente, para problemas de PLIM ou programação não linear inteira mista (PNLIM) de grande porte, as técnicas de otimização clássicas apresentam problemas de tempo de processamento para encontrar soluções ótimas ou sub-ótimas de qualidade. Por outro lado, existem as heurísticas e metaheurísticas para tentar resolver problemas de otimização, especialmente, para aqueles cujos modelos matemáticos são de tipo PLIM ou PNLIM. Um outro fato importante a ser observado é que as heurísticas e metaheurísticas podem resolver problemas de otimização, para os quais não é possível obter uma modelagem matemática ⁵⁰.

3 REVISÃO LITERATURA

Existe uma ampla gama de aplicações de pesquisa operacional e de ciência de dados com a ferramenta de aprendizado de máquina para resolver problemas relacionados à radioterapia ^{42 51}. Nessa seção faremos uma revisão de artigos relacionados com previsão de tempo de espera e de otimização de agendamento.

3.1 Tempo de Espera

Nos últimos anos, os sistemas de saúde têm dado maior atenção para o *feedback* do paciente sobre a qualidade do serviço recebido e sua satisfação é sempre influenciada pela sua percepção sobre o tempo de espera ^{52 53}. De acordo com Bleustein (2014) ⁵⁴ e Batt e Terwiesch (2015) ⁵⁵, a satisfação do paciente aumenta com uma previsão de tempo de espera mais preciso, além de ajudar no gerenciamento do fluxo de pacientes. Em outro estudo, Jouini et al. (2011) ⁵⁶ descobriram que as previsões de tempo de espera influenciam na tolerância à espera e na percepção desse tempo. Com as previsões, os pacientes ficam mais tolerantes a espera ⁵⁴.

Um estudo de Horwitz et al. (2010) ⁵⁷ desenvolveu um modelo para estimar os tempos de espera para consultas ambulatoriais, nesse trabalho compararam-se vários métodos de aprendizado de máquina, como RL múltiplas, SVM, *gradient boosting*, RF e *elastic net*. O modelo RF teve o melhor desempenho com área sob a curva (AUC) de 81,55%, seguido pelo SVM com AUC de 81,14%. Em um outro estudo, Javadifard et al (2019) ⁵⁸ utilizaram uma abordagem de redes neurais artificiais para prever os tempos de espera dos pacientes. O estudo previu o tempo de espera do paciente com uma precisão de 88%.

No estudo de Pinykh e Rosenthal (2015) ⁵⁹ foram usados vinte e cinco fatores relacionados à espera para criar modelos de previsão de tempo e os melhores subconjuntos de parâmetros foram testados com dados reais de pacientes. Assim, os estudos relacionados fornecem um vislumbre da previsão

dos tempos de espera do paciente.

No estudo de 2017, realizado por Joseph et al. ⁶⁰, as durações do tratamento em uma clínica de oncologia foram previstas com quatro modelos de regressão com aprendizado de máquina (RL, SVM, AD e um RF). Os modelos foram treinados com dados históricos dos pacientes tratados e o modelo de RF foi considerado o melhor com um MAE de 4,6 minutos e R2-Score de 0,47. O erro médio foi de 0,25 minutos com um desvio padrão de 6,1 minutos.

Em 2018, Curtis et al. ⁵² examinaram a possibilidade de prever o tempo de espera dos pacientes no departamento de Radiologia do Hospital Geral de Massachusetts usando ML. Quatro tipos diferentes de exames foram considerados: CT, ressonância magnética (RM), ultra-som e radiografia. Foram utilizadas 40 variáveis preditoras e foram testados modelos como GBM, regressão linear, *elastic net*, RF, SVM, *Bagging* e redes neurais artificiais. Para a modalidade de exame de radiografia, o modelo de RF alcançou o RMSE mais baixo de 8,816 e teve o 3º maior R2-Score de 0,4582. A rede elástica seguida pelo modelo de regressão linear teve o segundo maior R2-Score, ambos ligeiramente acima de 0,46. O modelo de rede elástica teve o melhor desempenho entre os modelos propostos para prever os tempos de espera ou tempos de atraso em todas as quatro modalidades.

Tempo de espera em oncologia tem sido analisado com o propósito de compreender e explicar os fatores que afetam os atrasos, a fim de diminuir o tempo de espera dos pacientes de radioterapia ⁶¹. Esses estudos enfocam as variações do tempo de espera entre eventos pré-tratamento (como consulta inicial, diagnóstico, cirurgia ou quimioterapia) até o início do tratamento e os fatores que causam variações nos tempos de espera. Outro estudo levantou a hipótese de que os atrasos antes do início do tratamento são devidos à recursos inadequados, ou seja, o tempo de espera para tratamento é causado pelo suprimento insuficiente de recursos de máquinas e funcionários para a demanda do paciente ⁶².

3.2 Otimização de Agendamento

Existem diversos trabalhos sobre otimização de atividades em radioterapia na literatura ⁶². A utilização de pesquisa operacional para essa finalidade é discutida por Ehr Gott e Holder em ⁶³, mas em sua revisão são citados apenas três artigos abrangendo o aspecto logístico dos tratamentos de radioterapia. Já as aplicações de aprendizado de máquina são discutidas em ¹⁵, porém não foi abordada a questão de agendamento. Dentre as áreas citadas temos planejamento do tratamento, segmentação de imagem, garantia da qualidade, previsão da resposta patológica, diagnóstico do paciente, estadiamento do câncer e previsão de toxicidade e suporte de decisão de prescrição de dose.

Uma revisão da literatura sobre radioterapia mostra que o primeiro autor a estudar o agendamento foi Larsson (1993) ⁶⁴. Este trabalho foi conduzido em Manitoba - Canadá e seu estudo foi baseado em fórmulas para organizar lista de espera de pacientes usando macros em Excel. Seu sistema de agendamento registra listas de espera e detalhes do paciente. No entanto, ele usa uma fórmula simples.

Lim et al. (2005) ⁶⁵ afirmam que há dois aspectos cruciais para melhorar a taxa de sobrevivência dos pacientes: Uma boa priorização do paciente e uma redução do tempo de espera. Além disso, o estudo conduzido por Dodwell e Crellin (2006) ⁶⁶ concluiu que a taxa de sobrevida é diretamente ligada ao tempo de espera do paciente para o tratamento ⁶⁷. Kapamara et al. (2006) ⁶⁸ realizaram uma previsão do problema de agendamento de pacientes de radioterapia (pré-tratamento e tratamento), e concluiu que este problema é semelhante a um problema de *job-shop* dinâmico ⁶⁹. Já Proctor et al. (2007) ⁷⁰ publicaram um estudo para ajudar a compreender os efeitos das mudanças na demanda dos seus serviços e os recursos disponíveis em seu departamento de radioterapia.

Em Petrovic, Morshed e Petrovic (2011) ⁷¹ foi proposto outro trabalho baseado em meta-heurística. Foram usados três algoritmos genéticos (GA) com objetivos simultâneos de reduzir o tempo de espera médio dos pacientes e minimizar o tempo médio de violação de metas de tempo de espera. Os GAs desenvolvidos tratam as categorias de pacientes de diferentes maneiras: (1) a

GA-padrão considera todas as categorias de pacientes de forma igual, (2) KB-GA tem conhecimento incorporado na programação da categoria de pacientes de emergência e (3) GA-ponderado opera com pesos diferentes dados às categorias do paciente. Os resultados mostraram que o KB-GA superou de forma moderada o GA-padrão considerando pacientes paliativos e o GA-ponderado superou o GA-padrão, considerando os pacientes de emergência. Os resultados mostraram uma potencial redução dos tempos médios de espera para pacientes radicais (35 para 21,48 dias) e paliativos (15 a 13,10 dias).

Importantes trabalhos foram publicados por Conforti, Guerriero e Guido (2008) ⁷², Conforti, Guerriero e Guido (2009) ⁷³, Conforti et al. (2011) ⁷⁴. No primeiro trabalho, sobre agendamento em radioterapia, modelos matemáticos foram propostos para agendamento de pacientes baseado numa lista de prioridade e possibilidade de reagendamento de horários de pacientes para aumentar o número de pacientes em tratamento. Eles consideraram um sistema de blocos, no qual uma jornada de trabalho é dividida em um número fixo de blocos/slots de tempo. No segundo e terceiro trabalhos, os autores descrevem um programa de otimização linear com intenção de auxiliar na tomada de decisão de agendamento em radioterapia. Os mesmos autores estendem a modelo para levar em consideração a disponibilidade do paciente e executar experimentos mais extensos. Em Conforti et al. (2009) ⁷³ com os blocos de tempo não fixos foi possível garantir uma taxa de 95% de utilização do acelerador linear, minimizando o tempo de espera.

Alguns trabalhos como os realizados por Delaney et al. (1999) ⁷⁵, Burnet et al. (2001) ⁷⁶ discutem a importância de avaliar a complexidade dos casos para definir o tempo de tratamento.

O impacto de uma série de parâmetros em agendamento em radioterapia como a acumulação de pacientes antes do agendamento ao invés de agendamento diário, e atraso no agendamento do paciente nas datas mais próximas de seu tempo de espera alvo foi discutido por Petrovic e Leite-Rocha (2008) ⁷⁷. Além de investigar se é possível melhorar as soluções obtidas pelos métodos construtivos com algoritmos baseados em meta-heurística.

Legrain et al. (2015) ⁷⁸ propuseram um algoritmo genético para fazer agendamento de radioterapia de forma *on-line*. Este artigo levou em

consideração a distribuição de chegada dos pacientes em eventos futuros. Para refletir a incerteza relacionada à chegada dos pacientes e à duração do tratamento, desenvolveu-se um método híbrido combinando a otimização estocástica e otimização *on-line*. Os resultados de experimentos computacionais realizados usando dados reais mostraram uma diminuição média no número de pacientes que violam os padrões, de 50% para pacientes agudos e 81% para pacientes subagudos.

Riff et al. (2016) ⁷⁹ propuseram um novo algoritmo de agendamento baseado em heurística para tratamentos de radioterapia e comparou o algoritmo com as estratégias As Soon As Possible (ASAP) e Just In Time (JIT). Os autores consideram que incluir o tempo de espera do paciente durante o planejamento é fundamental para melhorar a eficácia dos tratamentos.

Em uma revisão da literatura de problemas de otimização de agendamento realizada por Vieira et al. (2016) ⁴², a maioria dos autores aplicou técnicas de programação matemática (9 em 18), alcançando assim soluções quase ótimas. No entanto, os métodos metaheurísticos aparecem como um suplemento ou alternativa viável para esse problema (8 em 18).

Com foco na etapa de pré-tratamento, Petrovic et al. ⁸⁰ exploraram semelhanças entre a radioterapia e os problemas de escalonamento de processos comumente encontrados em processos industriais, usando algoritmos genéticos para minimizar os tempos médios de espera e os atrasos médios no início do tratamento. Os resultados mostraram que esses indicadores foram reduzidos em 35% e 20%, respectivamente. Em Petrovic et al. ⁸¹ foram conseguidas reduções consideráveis em tempos de espera para pacientes paliativos (34%) e radicais (41%).

Sauré et al. ⁸² formularam o problema como um processo de decisão de Markov de horizonte infinito descontado para identificar políticas de alocação em aceleradores lineares (LINACS) que proporcione redução nos tempos de espera. A porcentagem de tratamentos iniciados em 10 dias, para um conjunto de dados clínicos aumentou, em média, de 73% para 96%.

Trabalho como publicado por Heger, Bani e Scholz-Reiter (2012) ⁸³ utilizou redes neurais artificiais e processo gaussiano como métodos de aprendizado para determinar qual a melhor regra de despacho (prioridade para

cada processo) sob diferentes condições do sistema. Um outro trabalho que utiliza técnicas de redes neurais artificiais combinado com métodos heurísticos para melhorar o agendamento de tarefas foi o realizado por Agarwal, Pirkul e Jacob (2003) ⁸⁴. Foi utilizada uma arquitetura de rede que se assemelha ao gráfico de tarefas do problema de agendamento e, através de pesos atribuídos aos links entre tarefas e máquinas, e ajustando os pesos com uma estratégia de aprendizagem apropriada, foi encontrado um cronograma significativamente melhorado com apenas algumas iterações.

4 MATERIAIS E MÉTODOS

Nessa seção serão apresentados o local do estudo e a metodologia utilizada para o desenvolvimento desse trabalho.

4.1 Local de estudo

O presente trabalho foi realizado no departamento de radioterapia do Instituto de Radiologia (InRad) do Hospital das Clínicas da Faculdade de Medicina de São Paulo (HCFMUSP). O HCFMUSP é o maior complexo hospitalar da América Latina e em outubro de 2021 teve seis dos seus serviços de especialidades citados entre os duzentos melhores do mundo, segundo levantamento anual *The World's Best Specialized Hospitals 2022*, da revista americana Newsweek. Na área de oncologia, o hospital apareceu entre os cem melhores do mundo ⁸⁵.

O Hospital é reconhecido por sua excelência em assistência, ensino e pesquisa em prol da saúde. Destaque em inovação, o InRad é um centro de excelência nacional e internacional, com pioneirismo tecnológico em diagnóstico por imagem e tratamento oncológico. Foi a primeira instituição da América Latina a aplicar as técnicas de medicina nuclear e a primeira da América do Sul a dispor de equipamento de braquiterapia de alta taxa de dose. Em 2021, em ação conjunta com a FMUSP, foram realizados pelo InRad 230.945 procedimentos assistenciais ⁸⁵.

O setor de radioterapia localizado no Inrad é composto por três aceleradores lineares nomeados de Clinac 6EX, iX e 2100 CD que funcionam das 7:00 horas até as 19:00 horas. Os três equipamentos têm finalidade médica que produz fótons com energia maior que 1MeV a partir da aceleração de elétrons por radiofrequência, porém existem diferenças de licenças de uso e de acessórios acoplados, são elas:

2100 CD: é um acelerador linear capaz de emitir diversos feixes de radiação (raios-X de 6 MV e de 15 MV, além de elétrons de 6 MeV, 9 MeV, 12 MeV e 15 MeV). O aparelho permite ao médico radioterapeuta a seleção do tipo de radiação mais adequada para cada caso, de acordo com a profundidade da lesão. Além disso, o 2100C é dotado de colimador multifolhas de 120 lâminas com espessura mínima de 0,5 cm, capazes de ajustar o campo de tratamento ao formato da lesão a ser tratada. Ele tem licença de tratamentos convencionais e com intensidade de feixe modulados e a entrega do tratamento pode ser realizada com o *gantry* estático ou em arco (IMRT e VMAT). Para realização de imagens de verificação e controle de qualidade, existe um dispositivo de diodo amórfico acoplado no *gantry* (*Portal Vision/Portal dosimetry*).

iX: é um acelerador linear capaz de emitir feixes de raios-X de 6 MV e de 15 MV, além de elétrons de 6 MeV, 9 MeV, 12 MeV, 15 MeV e 18 MeV. O aparelho é dotado de colimador multifolhas de 80 lâminas com espessura mínima de 1 cm. Ele tem licença para tratamentos convencionais e modulados, porém os modulados só podem ser entregues com o *gantry* estático (IMRT). Para realização de imagens de verificação e controle de qualidade possui *Portal Vision* e *Portal dosimetry*.

Clinac 6 EX: é um acelerador linear capaz de emitir somente feixes de Raios-X de 6 MV. O aparelho não é dotado de colimador multifolhas, entretanto é possível se conectar a um sistema de lâminas externo chamado de m3 do fabricante *Brainlab* que contém 26 pares de lâminas com espessura mínima de 3 mm. Esse sistema possibilita a conformação de lesões com abertura de campo máxima de 9,8 cm por 9,8 cm. Para tamanhos de campos maiores, é utilizado o bloco de colimação de chumbo. Ele tem licença apenas para entrega de tratamento modulado com o *gantry* estático (IMRT). Não existe sistema de verificação de imagem acoplado, apenas um sistema de ExacTrac que não é acoplado.

A equipe responsável pela etapa pré-tratamento e de tratamento é formada por seis físicos médicos, dois neurocirurgiões, nove radio oncologistas, trinta e um tecnólogos, um enfermeiro e dois auxiliares de enfermagem.

4.2 Comissão de Ética

Essa pesquisa teve aprovação do comitê de ética do Hospital das Clínicas da FMUSP e os profissionais entrevistados foram consultados quanto a aceitação em participar da pesquisa e informados por escrito. Os dados de aprovação do comitê estão no ANEXO 1.

4.3 Descrição do Problema

4.3.1 Tempo de espera

Para que o paciente comece seu tratamento de radioterapia, existem diversas etapas antes da sua convocação e para cada paciente, após a etapa de simulação, é fornecida uma data provável de início de tratamento, porém muitas vezes essa data apresenta grandes desvios em relação a data real, o que pode causar ansiedade nos pacientes quando ocorre um atraso nessa data e da mesma forma, se a data for antecipada pode existir uma incompatibilidade de disponibilidade dos pacientes, já que a radioterapia é um tratamento diário que pode durar mais de um mês.

Atualmente existe uma tabela de tempo de espera padrão por técnica de tratamento e para casos de prioridade, porém na prática percebe-se que o tempo de espera real não coincide com o padrão. A análise desse problema é um dos objetivos desse estudo.

4.3.2 Tempo de tratamento

Uma das queixas mais frequentes na ouvidoria do HCFMUSP é o atraso no horário agendado para o tratamento. Cada equipamento tem uma agenda diária, na qual os pacientes são associados a um *slot* de tempo. Esse tempo de tratamento é definido pelo número de isocentros a serem usados e algumas regiões de tratamento têm um tempo específico. Esse tempo é o mesmo para todas as aplicações do paciente e pode assumir os valores de 12, 24, 36, 48 ou 60 minutos. O que se percebe na rotina clínica, é que em algumas épocas

existem muitos atrasos na agenda diária que podem estar relacionados com um tempo padrão de tratamento mal definido. O entendimento desse problema também é objetivo desse estudo.

4.3.3 Agendamento

Na radioterapia a entrega da dose de prescrição do tratamento pode ser fracionada em vários dias, e conseqüentemente o paciente passa a ter que visitar o setor por vários dias, por um número conhecido de semanas que depende do plano de tratamento. Os tratamentos podem ter duração de 1 a 40 dias. Portanto o problema de radioterapia difere dos problemas dos agendamentos clássicos. O problema consiste no fato de ter que se agendar um determinado número de sessões de tratamento em dias consecutivos em uma máquina que tem uma capacidade máxima e que está parcialmente reservada com pacientes já em andamento. Assume-se que cada acelerador linear pode ser modelado como uma seqüência de blocos temporais de mesma duração e cada bloco representa o intervalo de tempo em que um único paciente é tratado. Os aceleradores funcionam de segunda-feira a sexta-feira. Cada acelerador pode atender apenas um paciente por vez. A capacidade de cada acelerador, é dada pelo número de horas de trabalho que não deve ser excedida em um determinado dia.

A cada novo dia pacientes são admitidos no serviço para realização do tratamento e a data prevista de início de tratamento e o equipamento que será utilizado são fornecidos na etapa simulação. Portanto, uma vaga de tratamento no acelerador especificado, no dia previsto, tem que ser reservada. Existem alguns problemas que podem ocorrer para que essa data prevista não ocorra conforme o planejado, por exemplo, se a etapa de pré-tratamento não for finalizada até a data prevista, se não existir vaga no equipamento ou houver algum problema de gerenciamento de agendamentos.

O objetivo da otimização é maximizar o número de pacientes a serem agendados, levando em conta as seguintes condições:

1. o valor de prioridade atribuído ao paciente, determinado com base na "gravidade" da doença do paciente;
2. o número de sessões de tratamento para cada paciente;

3. as sessões de tratamento de cada paciente devem ser realizadas em dias consecutivos e;

4. cada paciente deve passar pelos tratamentos por um determinado número de semanas consecutivas.

4.4 Coleta de dados e período de estudo

No departamento de radioterapia do HCFMUSP foi realizado um estudo retrospectivo de aproximadamente 8000 pacientes. Desses pacientes, aproximadamente 6000 receberam entrega de dose de tratamento dentro do período de estudo, de 2016 a 2021.

Os dados foram coletados através do prontuário eletrônico disponível no serviço, MOSAIQ® (v2.83, Elekta, Sweden). Esse *software* de sistema de gerenciamento dos tratamentos exporta tabelas em extensão .csv com diversas informações referentes aos dados demográficos e diagnóstico dos pacientes e do fluxo de trabalho realizado e a ser realizado. No total, foram extraídas do MOSAIQ aproximadamente 20 tabelas. Os dados coletados foram selecionados por serem considerados previamente importantes para propor modelos e soluções para a melhoria do fluxo de trabalho baseado na minha experiência clínica e por artigos relacionados ^{75 76}.

Como esses dados não eram estruturados, foram realizadas manipulações nos arquivos para tornar os dados organizados e passíveis de análise através de um programa desenvolvido com linguagem de programação *Visual Basic for Applications* (VBA) dentro do Excel 2016. Após as manipulações foram criadas nove tabelas de dados. Um resumo dessas tabelas se encontra na Tabela 3, o número de colunas se refere ao número de variáveis em cada tabela.

TABELA 3 - RESUMO DAS TABELAS GERADAS COM O PROGRAMA EM VBA.

| Nome da Tabela | Descrição | Linhas | Colunas |
|---------------------------|--|--------|---------|
| DadosDemograficos | Dados de data de nascimento e data de admissão | 39392 | 4 |
| QCL | Controle de datas e usuários que realizaram as atividades das etapas pré-tratamento | 112294 | 9 |
| FilaEspera | Controle de horário de entrada e saída dos pacientes no departamento e na sala de tratamento | 147352 | 8 |
| Tdiario | Dados referentes aos parâmetros de tratamento definidos no planejamento | 588309 | 14 |
| agendadiariacapturacodigo | Dados referentes aos códigos capturados na agenda diária do departamento, por exemplo, suspensão de tratamento ou falta do paciente | 20296 | 5 |
| CID | Dados referentes a região e intenção do tratamento | 186740 | 8 |
| DadosCC | Agenda do departamento com os horários, salas e tipo de atividade agendada, por exemplo, tratamento, revisão, controle de qualidade do plano | 151521 | 8 |
| PR | Dados referentes ao número de sessões de tratamento do paciente e o tempo de sessão fixo pré definido | 10198 | 8 |
| CT | Agenda diária da tomografia com o <i>status</i> do paciente | 8658 | 6 |

As tabelas foram importadas no *software* R ⁸⁶ utilizando a interface de desenvolvimento integrada RStudio para a realização das análises dos dados e construção dos modelos. Os pacotes utilizados foram importados do repositório Cran, sendo eles: readxl, ggplot, ggstatsplot, plyr, dplyr, data.table, lubridate, bizdays, tidyverse, stringr, utf8, rpart, rhandsontable, ompr, ROI.plugin.glpk, ompr.roi, xgboost, caret, mlr, h2o, e1071, ModelMetrics, forecast, randomForest e neuralnet ^{87 88 89 90 91 92 93 94 95 96 97 98 99 100 101 102 103 104 105 106 107 108} .

No R foram realizadas associações entre as tabelas e foram utilizadas as variáveis coincidentes como referência para a realização da união das informações. Novas variáveis foram criadas a partir dos dados dessas tabelas.

Das nove tabelas iniciais, foram criadas quatro tabelas para realização do estudo, Tabela 4.

TABELA 4 - RESUMO DAS TABELAS UTILIZADAS PARA A ANÁLISE EXPLORATÓRIA E CRIAÇÃO DOS MODELOS PREDITIVOS.

| Nome da Tabela | Descrição | Linhas | Colunas |
|-------------------------|---|---------------|----------------|
| Dados | Utilizada para a realização da análise exploratória inicial dos dados, como idade dos pacientes, região e técnica de tratamento | 9280 | 34 |
| Tempoqcl | Utilizada para análise exploratória dos dados de tempo de atividades pré-tratamento e criação do modelo de previsão das atividades pré-tratamento | 4041 | 46 |
| AnaliseTempoSala | Utilizada para análise exploratória dos dados de tempo de sessão de tratamento e criação do modelo de previsão do tempo de sessão de tratamento | 108460 | 22 |
| Dados_agenda | Utilizada para a previsão de tratamento após o horário comercial e para o modelo de otimização do agendamento do tratamento | 5944 | 41 |

Um dicionário completo das variáveis encontra-se no anexo B deste trabalho. Para os modelos de previsão, os dados categóricos foram transformados em variáveis *dummy* (binárias 0 ou 1) e as variáveis numéricas não binárias foram normalizadas conforme equação 10.

$$x = \frac{x - x_{min}}{x_{max} - x_{min}} \quad \text{EQUAÇÃO 10}$$

Como diferentes tabelas apresentavam dados de uma mesma variável, quando uma união de tabelas produzia um dado faltante, buscava-se em outra tabela a informação para completá-la e maximizar a taxa de casos completos. Por exemplo, uma variável muito importante para a análise exploratória dos dados é o grupo de tratamento do paciente e essa informação é baseada no CID do paciente, em 364 casos esta informação estava ausente e pela prescrição médica da região a ser tratada foi possível retirar essa informação e apenas 50

pacientes ficaram sem um grupo assimilado. Nesse caso, um grupo chamado “Não Def” foi criado. Os dados que não foi possível definir pelas tabelas foram excluídos para as análises e para a criação dos modelos, por exemplo, se a data de execução da atividade de contorno de estruturas não foi adquirida, para esse paciente a data do contorno não foi definida e os dados desse paciente não foram utilizados para as análises que lidam com a data da atividade.

A análise dos dados foi dividida em três partes.

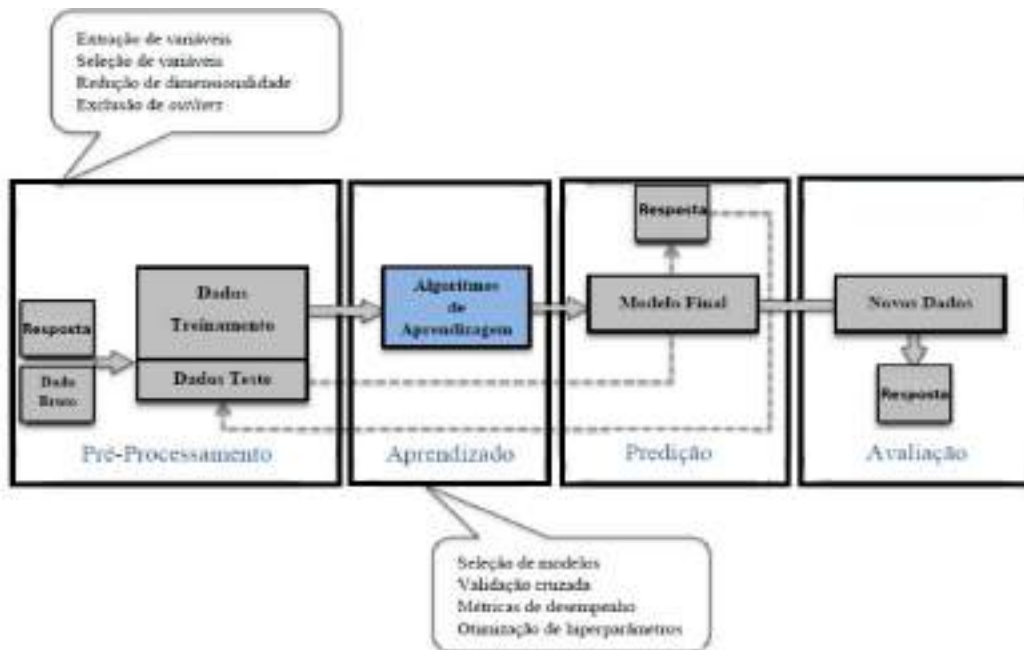
- 1- Análise exploratória inicial dos dados.
- 2- Avaliação do tempo necessário para realização das atividades de pré-tratamento (etapas simulação e planejamento) afim de liberá-lo para a agenda de início de tratamento e
- 3- Avaliação do tempo de sessão de tratamento necessária para cada tipo de tratamento.

Após esse estudo dos dados foram propostos quatro modelos.

- 1- Modelo de previsão das atividades pré-tratamento.
- 2- Modelo de previsão do tempo de sessão de tratamento.
- 3- Modelo de otimização para o agendamento do tratamento e
- 4- Modelo de previsão de tratamento após o horário comercial.

Na figura 12 é apresentado um diagrama com os principais passos realizados para criação dos modelos preditivos com aprendizado de máquina.

FIGURA 12 - ROTEIRO PARA APLICAÇÃO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA EM ANÁLISE PREDITIVA.



Fonte: Adaptado de ¹⁰⁹.

4.5 Análises Estatísticas

Na análise exploratória foram utilizadas medidas estatísticas descritivas e análise de correlação. Para a quantificação das correlações das variáveis numéricas utilizou-se correlação de Spearman e para avaliação quantitativa das variáveis categóricas utilizou-se a métrica x^2y , que consiste em verificar a porcentagem (%) de redução do erro do modelo quando passamos de um modelo *baseline* (sem a variável testada) para um modelo preditivo com a variável testada, ou seja, mede a força da relação entre duas variáveis. Na etapa de modelo de previsão, para as atividades pré-tratamento e de tempo de sessão de tratamento, foram testados modelos utilizando algoritmos XGBOOST, RNA, RF e SVM.

Para o modelo de classificação foram testados os algoritmos XGBOOST, RF, regressão logística e árvore de decisão. Como os dados eram desbalanceados, ou seja, a proporção de dias com atraso é muito menor que os dias sem atraso, foram testadas técnicas de reconstrução dos dados (*undersampling*, *oversampling*, *SMOTE*), diferentes funções custos e diferentes limiares de classificação. Enquanto o método *undersampling*, diminui, através de amostragem, o número de observações da classe majoritária para igualar com o

número de observações da classe minoritária, o método *oversampling*, aumenta, através de duplicação, a quantidade de observações da classe minoritária para igualar com a classe majoritária. Já o método SMOTE, gera novos exemplos para a classe minoritária com pontos de dados sintéticos baseados nos pontos de dados originais. A função custo refere-se à penalidade relacionada a uma previsão errada, atribuem-se custos diferentes para uma classificação incorreta.

Para avaliação de desempenho dos modelos de regressão foi utilizada a raiz quadrada do erro quadrático médio (RMSE) e foi analisada a importância das variáveis no modelo. Já para os modelos de classificações, as métricas utilizadas para avaliar o desempenho do modelo foram acurácia, sensibilidade e especificidade, valor predito positivo e negativo.

Para o modelo de otimização de agendamento, utilizou-se um modelo de programação linear inteira mista e comparou-se o número de pacientes agendados do modelo com o número real, e a variação do tempo de espera dos pacientes entre o modelo e o real.

Na avaliação do tempo gasto com as atividades de pré-tratamento, através de dados retirados do sistema de gerenciamento, buscou-se avaliar quais conjuntos de parâmetros interferem nesse tempo e qual a melhor configuração para fornecer um tempo mais próximo do real para o paciente. Também foi estudado se existe correlação entre o tempo de espera do paciente e recidivas de tratamento. Já na avaliação do tempo de tratamento buscou-se avaliar quais parâmetros interferem no tempo de tratamento e propor um tempo padrão para grupos específicos. Também foi avaliado o aumento de tempo da sessão de tratamento do primeiro dia e do agendamento consecutivo de pacientes do mesmo grupo.

Com o modelo de atraso buscou-se, através de dados anteriores de dias em que o expediente teve que se estender após 19 h e das características dos pacientes nesse dia de atraso, prever se uma determinada configuração de agenda diária de tratamento, como número de inícios de tratamento e proporção de pacientes na agenda de cada grupo de tratamento, produz atrasos que levam os tratamentos a se estenderem fora do horário comercial. O modelo de otimização de agendamento buscou maximizar o número de pacientes

agendados com menor tempo de espera seguindo uma métrica de priorização de paciente e respeitando restrições pré-estabelecidas.

5 RESULTADOS E DISCUSSÕES

Nessa seção serão apresentados os principais resultados encontrados no estudo. Os resultados estão divididos em análise pré-processamento, análise exploratória dos dados, previsão do tempo de espera, previsão do tempo de tratamento, previsão de atraso no expediente e agendamento.

5.1 Pré-Processamento

O primeiro passo para a exploração dos dados foi a realização do pré-processamento:

- (1) normalização das variáveis quantitativas não binárias;
- (2) exclusão de preditores altamente correlacionados e
- (3) exclusão de variáveis/observações com dados faltantes.

Nessa etapa de pré-processamento, avaliaram-se as principais alterações, na rotina de inserção de dados no prontuário eletrônico, que são necessárias para facilitar a utilização de aprendizado de máquina e evitar dados faltantes. São elas:

1. padronização das prescrições médicas inseridas no sistema, por exemplo, mama direita para casos de tratamento de mama direita e SRS meningioma, para casos de radiocirurgia de meningioma. Com essa informação é possível fazer uma dupla checagem do CID inserido no sistema e definir grupos de tratamentos específicos;

2. definição de um curso de tratamento para cada novo tratamento de um mesmo paciente. Se o paciente retornar para um novo tratamento, a prescrição e o plano de tratamento devem ser associados a um novo curso;

3. inserção no sistema que a atividade foi finalizada após encerramento de uma determinada atividade na fase de pré-tratamento. Foram encontrados muitos dados faltantes na aprovação de contorno do volume alvo de tratamento e na aprovação do plano de tratamento. Com isso para as análises dos tempos de cada atividade muitos dados foram descartados, apenas 70% dos pacientes tinham os dados completos de data de realização das atividades;

4. inserção do CID relacionado ao tratamento atual, ou seja, não associar o CID da lesão primária se o paciente for tratar uma lesão secundária. Encontrou-se divergência entre o CID e o nome da prescrição para casos de pacientes que trataram metástases, aproximadamente 9%. Por exemplo, o paciente tratou cérebro total e o CID era de tratamento de mama;

5. cancelamento da lista de atividades pré-tratamento a antiga que não foi usada sempre que o paciente for simulado novamente;

6. colocação de uma anotação no sistema se o paciente não puder tratar em um determinado horário da agenda. Assim pode-se levar em conta essa informação no agendamento automático;

7. preenchimento correto do tipo de tratamento, como, por exemplo, se curativo ou paliativo. Não foi realizada dupla checagem dessa informação;

8. associação correta do conjunto de atividades para cada tipo de tratamento, isso porque foram encontrados pacientes que trataram com técnica IMRT, porém no prontuário eletrônico tinha sido adquirido o código de tratamento 3D. Esse erro foi encontrado em 2% dos dados e;

9. adição do *status* correto na agenda de tratamento diária do equipamento. Na agenda diária alguns pacientes não estavam com *status* de início no primeiro dia ou sem o *status* de falta quando o mesmo não compareceu no dia. Esse erro foi encontrado em 5% dos dados.

Essas alterações e cuidados propostos auxiliam na automatização da retirada dos dados do sistema de prontuário eletrônico.

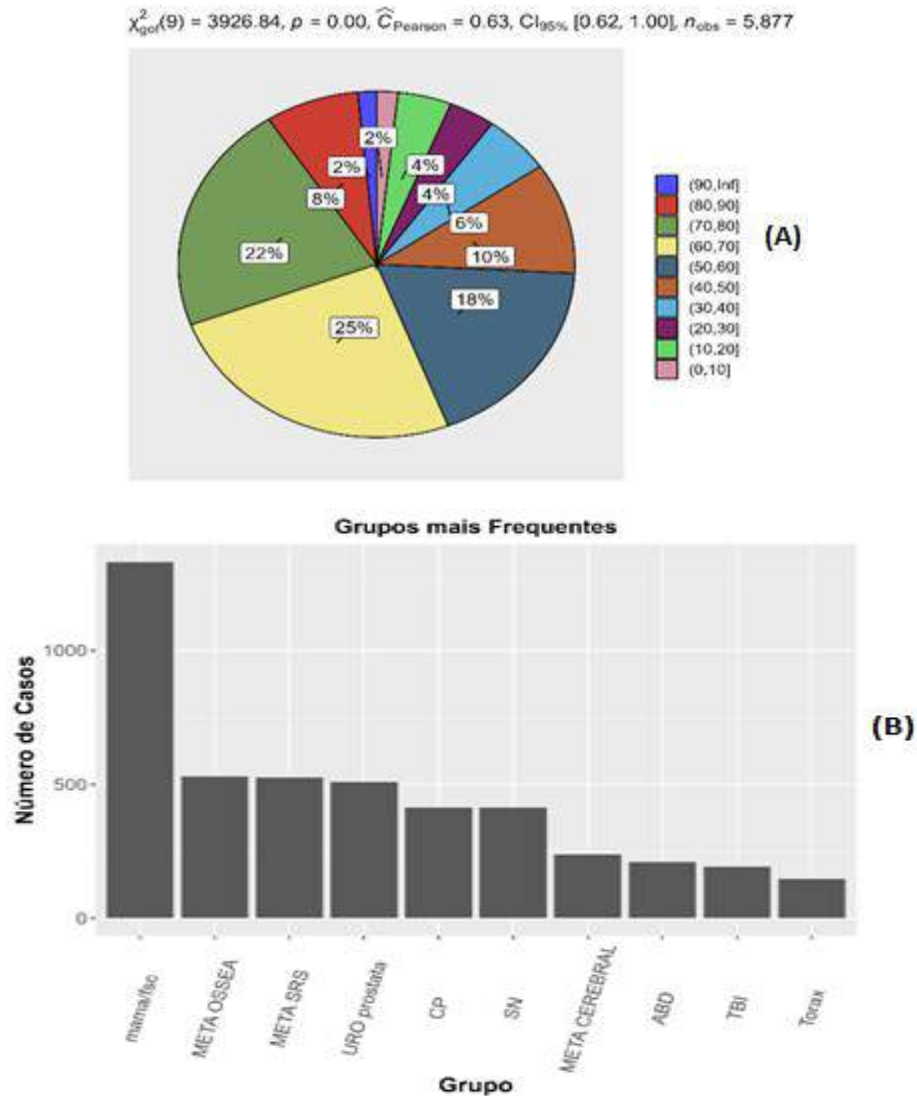
5.2 Análise Exploratória

Na etapa de avaliação dos dados, foi realizada uma análise exploratória dos dados para identificar relações entre as variáveis e extrair *insights* preliminares. Essas análises orientam as etapas de modelagem. No total, foram trabalhados dados de 5.942 pacientes tratados nos três equipamentos disponíveis no serviço durante 2016 e 2020 (1.782 no 2100CD, 2.400 no iX e 1.760 no 6EX). Para as análises, as idades foram divididas de duas formas:

1. faixa etária: pacientes crianças com idades entre 0 e 12 anos, adolescentes entre 13 e 17 anos, adultos entre 18 e 60 anos e idosos maiores que 60 anos.
2. grupos de idades com intervalo de 10 anos.

A Figura 13 apresenta os grupos de tratamentos e as faixas de idade mais frequentes, a lista dos CIDs que compõem cada grupo de tratamento se encontra no APÊNDICE A. Para formar grupos mais específicos, informações da prescrição médica foram adicionadas ao nome do grupo, por exemplo para o grupo de metástase (META) foi adicionada a região, subdividindo o grupo em META óssea para metástase nos ossos, META cerebral para metástase na região do encéfalo tratada com tratamentos convencionais e META SRS para metástase na região do encéfalo tratada com radiocirurgia. Para o grupo de SN também foi adicionada a região, como craniofaringioma, hipófise, neurinoma, schwannoma e meningioma. Para os tratamentos de SN com radiocirurgia a sigla SN foi substituída por SRS. Outra subdivisão foi no grupo de HEMATO, sendo que, os casos que utilizaram a técnica de TBI foram alocadas a um grupo chamado de TBI. A Figura 14 mostra a evolução na distribuição das faixas etárias entre 2015 a 2020 e a distribuição média das faixas etárias no período avaliado. Como o ano de 2015 só tem dados do último trimestre, ele não foi levado em consideração na análise.


FIGURA 13 - (A) DISTRIBUIÇÃO DE FREQUÊNCIA DE PACIENTES POR INTERVALOS DE IDADES E (B) GRUPOS DE TRATAMENTOS COM MAIORES NÚMEROS DE CASOS.



O intervalo de idade com maior número de pacientes é o que vai de 60 a 69 seguido do intervalo 70 a 79, Figura 13A. Os cânceres mais comuns no Brasil são de pele, próstata e mama, o que explica esses sítios anatômicos no grupo de mais frequentes, Figura 13B. O câncer de pele, na maioria das vezes, não é tratado com radioterapia justificando sua ausência nessa lista. O tratamento paliativo de metástase, tanto óssea como cerebral, tem um número significativo de casos no departamento.

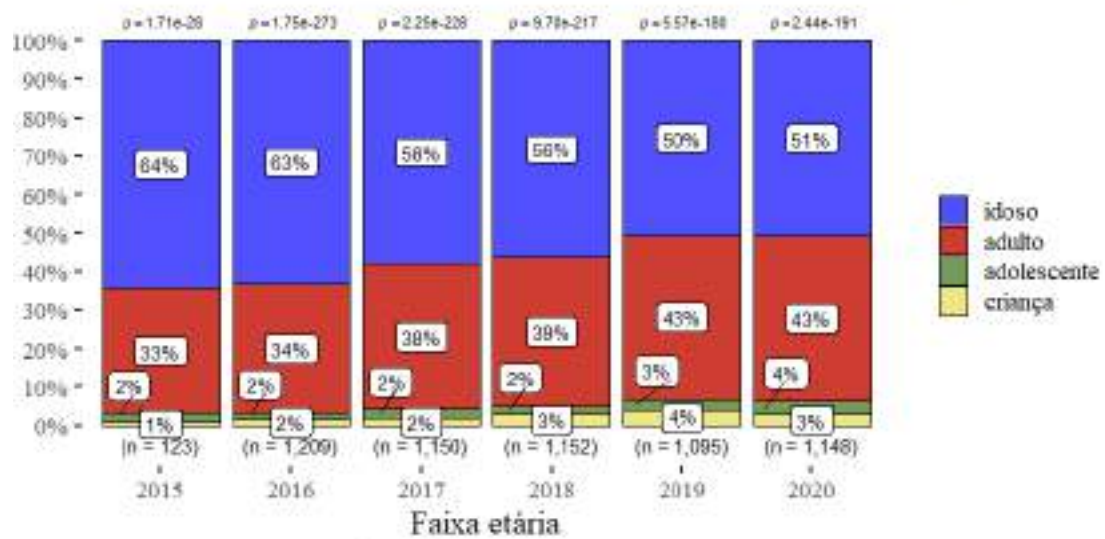
FIGURA 14 - EVOLUÇÃO DAS FAIXAS ETÁRIAS AO LONGO DO TEMPO. (A) DISTRIBUIÇÃO DE FREQUÊNCIA DE PACIENTES POR FAIXA ETÁRIA E (B) EVOLUÇÃO DA DISTRIBUIÇÃO DE FREQUÊNCIA POR ANO.

$$\chi^2_{\text{gof}}(3) = 5078.31, p = 0.00, \hat{C}_{\text{Pearson}} = 0.68, \text{CI}_{95\%} [0.67, 1.00], n_{\text{obs}} = 5,877$$



(A)

$$\chi^2_{\text{Pearson}}(15) = 70.33, p = 3.90e-09, \hat{V}_{\text{Cramer}} = 0.06, \text{CI}_{95\%} [0.03, 1.00], n_{\text{obs}} = 5,877$$



$$\log_e(\text{BF}_{01}) = -1.65, \hat{V}_{\text{Cramer}}^{\text{posterior}} = 0.06, \text{CI}_{95\%}^{\text{ETI}} [0.05, 0.08], \sigma_{\text{Gambel-Dickey}} = 1.00$$


(B)

Percebe-se pela Figura 14A que a maioria dos pacientes são idosos e adultos, somando 95% dos pacientes avaliados. Em 2016 tínhamos 63% de pacientes idosos e em 2020 esse número caiu para 51%, já o número de adultos foi de 34% para 43%. Em relação aos dados de crianças e adolescentes houve um aumento de 3% no período avaliado.

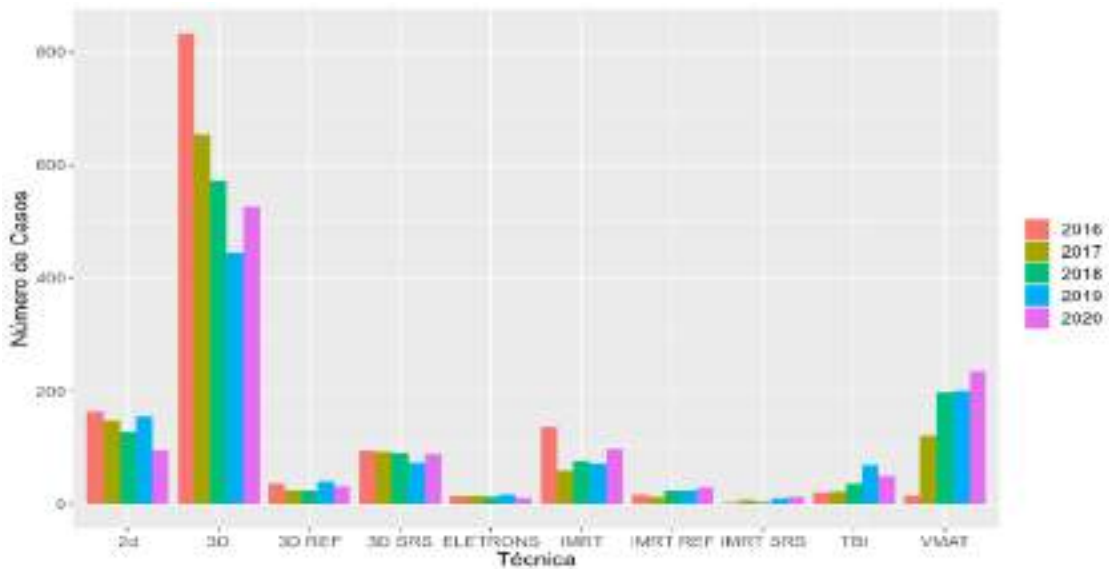
Outra avaliação realizada foi a evolução das técnicas de tratamento, Figura 15, observa-se que a frequência da realização das técnicas moduladas vem crescendo ao longo dos anos e das técnicas 3D e 2d vem diminuindo.

FIGURA 15 - EVOLUÇÃO DO NÚMERO DE CASOS PARA CADA TÉCNICA DE TRATAMENTO ENTRE 2016 E 2020. (A) EVOLUÇÃO DA PORCENTAGEM DE CASOS COM UMA DETERMINADA TÉCNICA ENTRE 2016 E 2020, (B) NÚMERO DE CASOS DE UMA DETERMINADA TÉCNICA POR ANO E (C) DISTRIBUIÇÃO DE CADA TÉCNICA DE TRATAMENTO POR ANO.

$$\chi^2_{\text{Pearson}}(36) = 393.62, p = 1.03e-61, \hat{V}_{\text{Cramer}} = 0.12, CI_{95\%} [0.11, 1.00], n_{\text{obs}} = 5,819$$

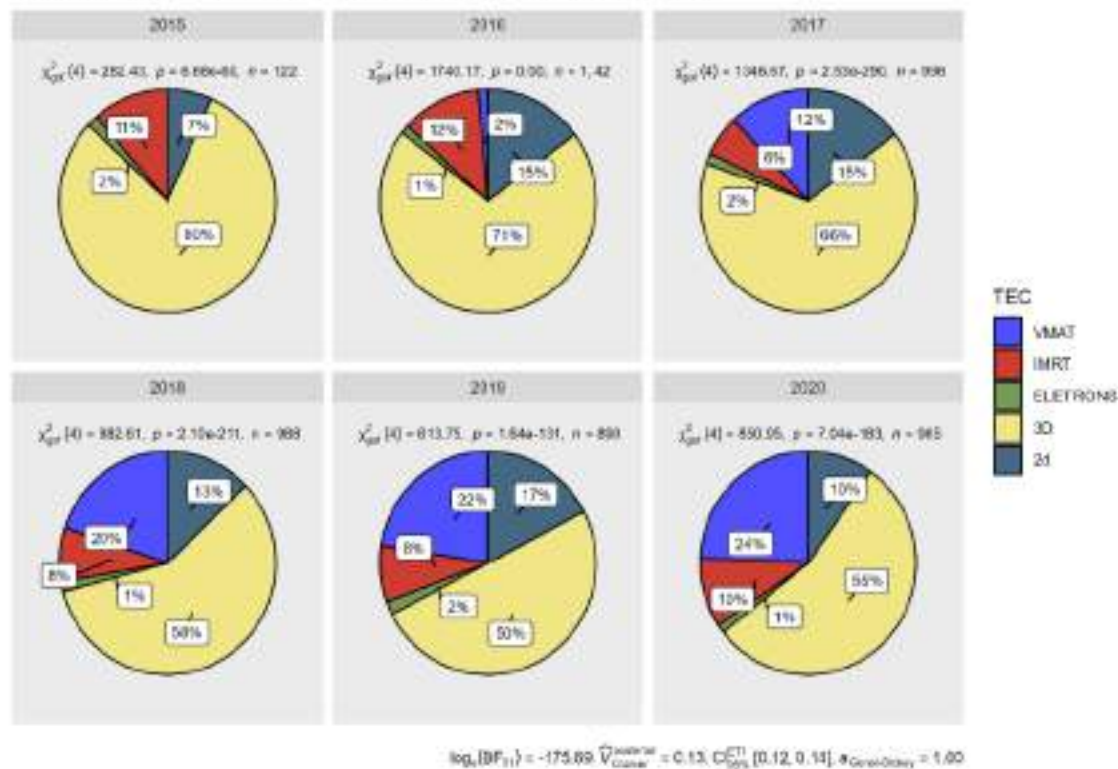


(A)



(B)

$$\chi^2_{\text{Pearson}}(20) = 353.34, p = 9.12e-63, \hat{V}_{\text{Gower}} = 0.13, CI_{95\%} [0.11, 1.00], n_{\text{obs}} = 5,003$$



(C)


As técnicas de tratamento são divididas em 3D, 2d, IMRT e VMAT. Porém para esse trabalho, foi realizada uma subdivisão incluindo os tratamentos especiais, assim para os casos de radiocirurgia com dose única foi adicionada a sigla SRS, após a técnica de tratamento, (3D SRS e IMRT SRS) e para casos de radiocirurgia fracionada foi adicionada a sigla REF (3D SRS e IMRT REF). Para os casos de TBI, a técnica foi definida como TBI, mas na prática é uma técnica 2d. Também foi criada uma técnica chamada de ELETRONS para os casos que utilizam o feixe de elétrons ao invés de fótons.

Atualmente, o tratamento utilizando a técnica 3D ainda é predominante no serviço, porém a diferença entre a porcentagem de pacientes que utiliza essa técnica de tratamento e as técnicas moduladas tem diminuído ao longo dos anos. De 2016 para 2020 o número de casos com a técnica de VMAT aumentou sendo que o ano de 2020 representou 31% do total dos casos tratados com VMAT em todo o período. A porcentagem de técnicas moduladas (IMRT+ VMAT) em relação a outras técnicas foi de 14% em 2016 para 34% em 2020, casos 2d, que já tinham uma porcentagem baixa, foi de 15% em 2016 para 10% em 2020, e de casos 3D foi de 71% de 2016 para 55% em 2020. Acredita-se que os casos com

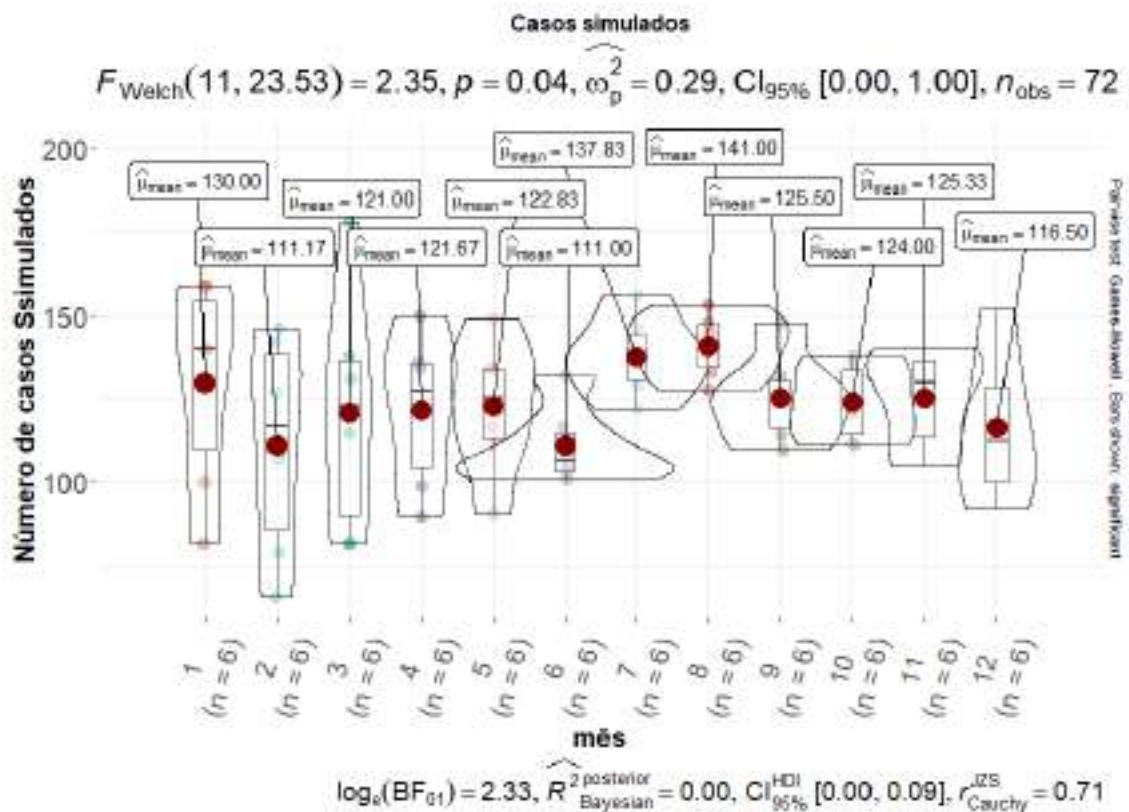
técnica modulada terão uma proporção similar à técnica 3D daqui 10 anos, já que atualmente apenas um equipamento realiza a técnica de VMAT e nos outros dois que realizam a técnica de IMRT, apenas um não tem limitação no tamanho de campo de tratamento. Um novo equipamento, que realiza as técnicas de tratamento VMAT e IMRT, chegará no departamento em julho de 2023 para substituir o equipamento 2100 CD e para 2025 há planos para aquisição de outro equipamento que realize técnicas de VMAT e IMRT para substituir o Clinac 6EX.

Para avaliar se existe uma sazonalidade de novos pacientes que chegam para a radioterapia, foi elaborado um gráfico de dispersão do número de casos novos entre os anos de 2016 e 2020 e um gráfico com a média de casos em um determinado mês, Figura 16A e 16B.

FIGURA 16 - AVALIAÇÃO DA SAZONALIDADE DE CHEGADA DE PACIENTES NO DEPARTAMENTO. (A)- NÚMERO DE NOVOS PACIENTES AO LONGO DO TEMPO E (B)- VARIAÇÃO DO NÚMERO DE CASOS POR MÊS.



(A)

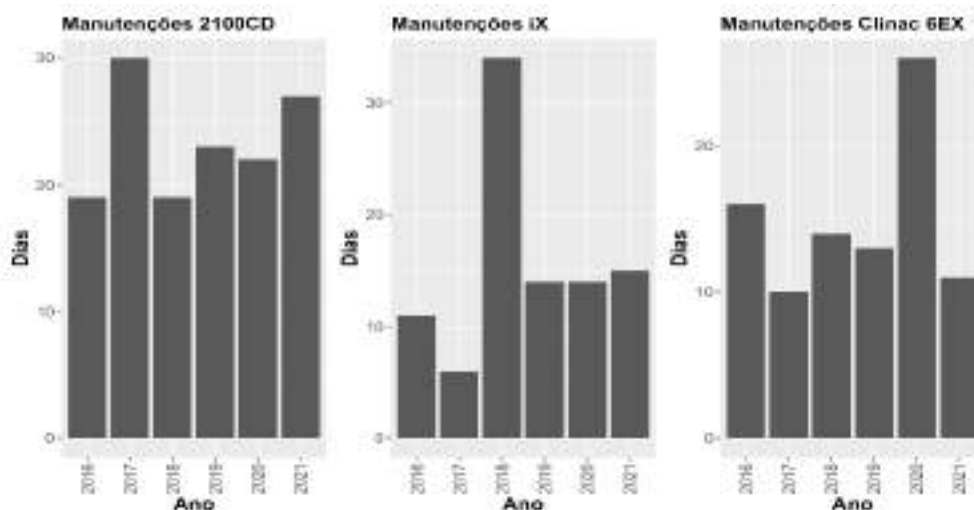


(B)

O gráfico demonstra uma leve tendência de haver maior número de casos no terceiro trimestre, Figura 16A e 16B. Avaliando Figura 16A, o número de pacientes que iniciaram seu tratamento em 2019 se demonstrou abaixo do que se esperava pelos outros anos e ao avaliar possíveis causas foi constatado que nesse período a tomografia de simulação estava inoperante o que impactou no número de casos chamados para tratamento. Em abril de 2020, ocorreu uma queda significativa de pacientes que, provavelmente, se deveu à pandemia de COVID-19. Pelo teste estatístico realizado não se pode afirmar que existe uma diferença significativa de novos casos por mês, $p\text{-value} = 0,27$.

Também foi realizada uma avaliação de problemas técnicos do equipamento para avaliar o tempo de máquina parada no serviço, Figura 17.

FIGURA 17 - TOTAIS DE DIAS DE EQUIPAMENTO PARADO PARA MANUTENÇÃO POR ANO.



O equipamento 2100 CD teve maior número de problemas técnicos de equipamento durante o período estudado. O número máximo de paradas para realização de manutenção em um mês foi de 18,15 e 13 dias, respectivamente para o 2100 CD, iX e Clinac 6EX. O equipamento 2100 CD é o mais antigo dos equipamentos e é o único que realiza o tratamento com técnica VMAT, portanto quando fica inoperante não há como os outros equipamentos absorverem os casos de VMAT. De maneira similar, o equipamento Clinac 6EX é o único que realiza tratamentos de SRS.

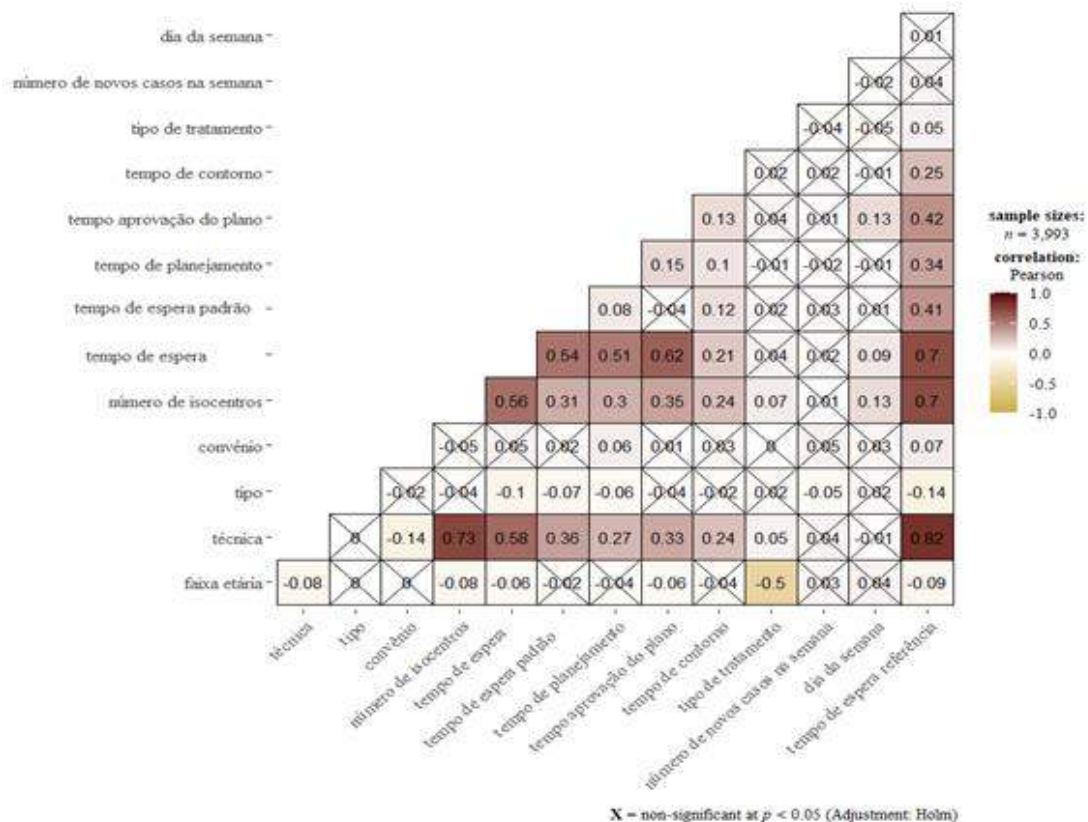
5.3 Tempo de realização da etapa pré-tratamento

Através de gráficos e tabelas buscou-se entender o tempo de espera dos pacientes (tempo entre simulação e início do tratamento). Como referência de tempo de espera ideal, tem-se os valores definidos pela *Joint Collegiate Council for Oncology*¹¹⁰, sendo que para radioterapia urgente o tempo ideal de espera é de 24h e o máximo aceitável de 48h; para radioterapia radical o tempo ideal é de 14 dias e máximo aceitável de 28 dias e para radioterapia paliativa o tempo ideal é de 2 dias e o máximo aceitável de 14 dias. Para avaliar a relação entre as variáveis preditivas e o tempo de espera foi realizada correlação, Figura 18. As variáveis categóricas faixa etária, técnica de tratamento e tipo de tratamento foram transformadas em numéricas com uma ordenação de valores baseado na

complexidade do processo e de prioridades pré-existentes no departamento, por exemplo, crianças são priorizadas e, portanto, têm as tarefas de planejamento e contorno realizadas em menos tempo. A ordenação das faixas etárias ficou 1 para criança, 2 para adolescente, 3 para adultos e 4 para idosos, já para técnica de tratamento ficou 1 para 2d, 2 para TBI, 3 para ELETRONS, 4 para 3D SRS, 5 para 3D REF, 6 para 3D, 7 para IMRT SRS, 8 para IMRT REF, 9 para VMAT e 10 para IMRT . O tipo de tratamento foi ordenado como 1 para *BMT Regimen*, 2 para *Palliative*, 3 para *Prophylactic*, 4 para *Induction-Primary*, 5 para *Curative*, 6 para *Primary-Neoadjuvant*, 7 para *De-Bulking*, 8 para *Reconstruct/Rehab*, 9 para *Other, NOS* e 10 para *NAO DEF*.

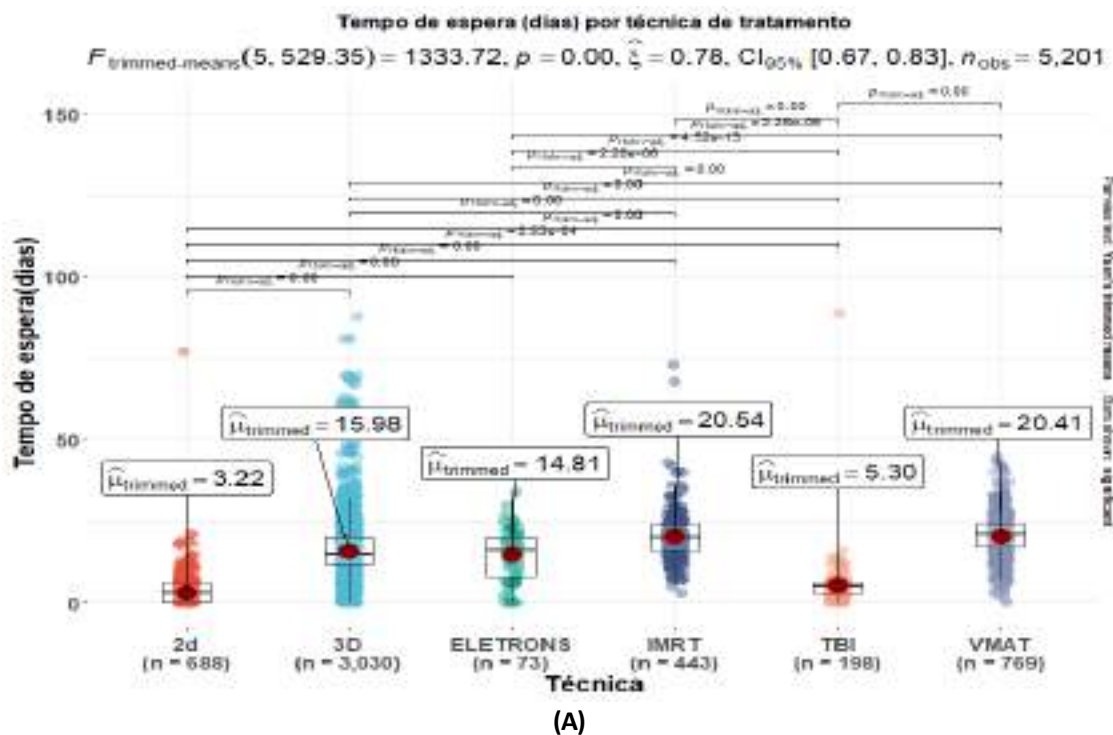
Na Figura 19 são apresentados os resultados desses tempos de espera por técnica de tratamento, por grupo de especialidade, faixa etária e tipo de tratamento.

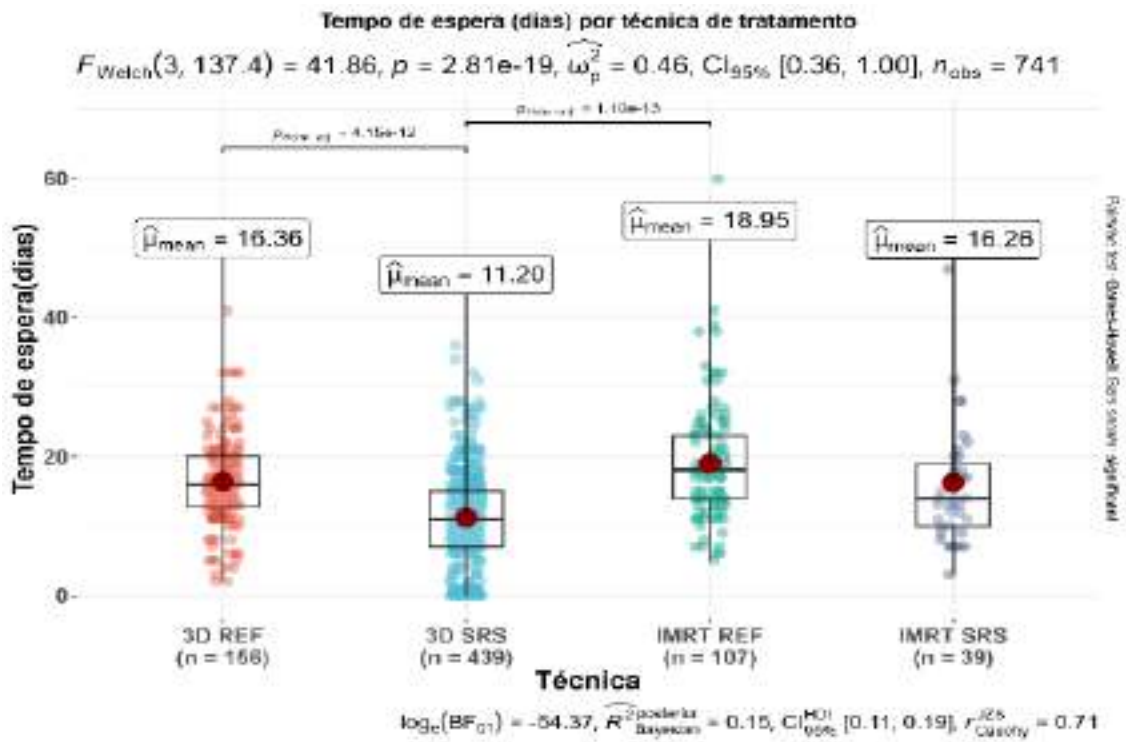
FIGURA 18 - CORRELAÇÃO ENTRE AS VARIÁVEIS ESTUDADAS PARA PREDIÇÃO DO TEMPO DE ESPERA.



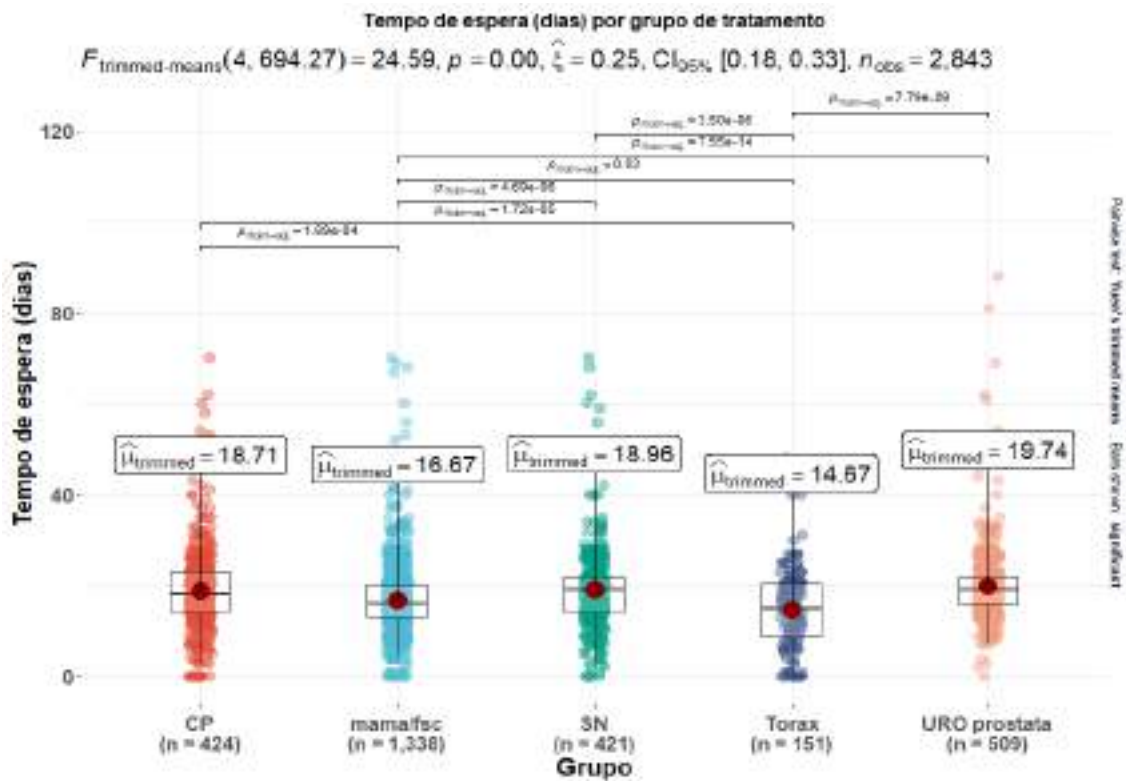
A variável tempo de espera apresentou correlação mais forte com as variáveis técnica, número de isocentros, tempo de espera de referência, tempo de espera padrão e tempo de contorno. Apesar do número de casos novos na mesma semana parecer promissor, a correlação encontrada foi baixa, isto porque, o número de casos novos não tem uma grande variação entre as semanas. As informações de tempo de planejamento, contorno, tempo de aprovação do plano e cálculo, apesar de terem correlação forte, não foram utilizadas no modelo de predição pois não temos essa informação na simulação. A variável idade também não foi utilizada já que possui correlação forte com a faixa etária.

FIGURA 19 - TEMPO DE ATIVIDADE PRÉ-TRATAMENTO (DIAS) POR TÉCNICA DE TRATAMENTO E PELOS PRINCIPAIS GRUPOS DE TRATAMENTO. (A) AVALIAÇÃO PARA AS TÉCNICAS CONVENCIONAIS DESCONSIDERANDO OS PACIENTES DE RADIOCIRURGIA, (B) AVALIAÇÃO PARA AS TÉCNICAS 3D E IMRT PARA OS TRATAMENTOS DE RADIOCIRURGIAS, (C) GRUPOS MAIS FREQUENTES SEM CONSIDERAR METÁSTASES, (D) GRUPOS DE METÁSTASES E TBI, (E) AVALIAÇÃO PARA OS PRINCIPAIS TIPOS DE TRATAMENTO E (F) AVALIAÇÃO PARA AS FAIXAS ETÁRIAS.

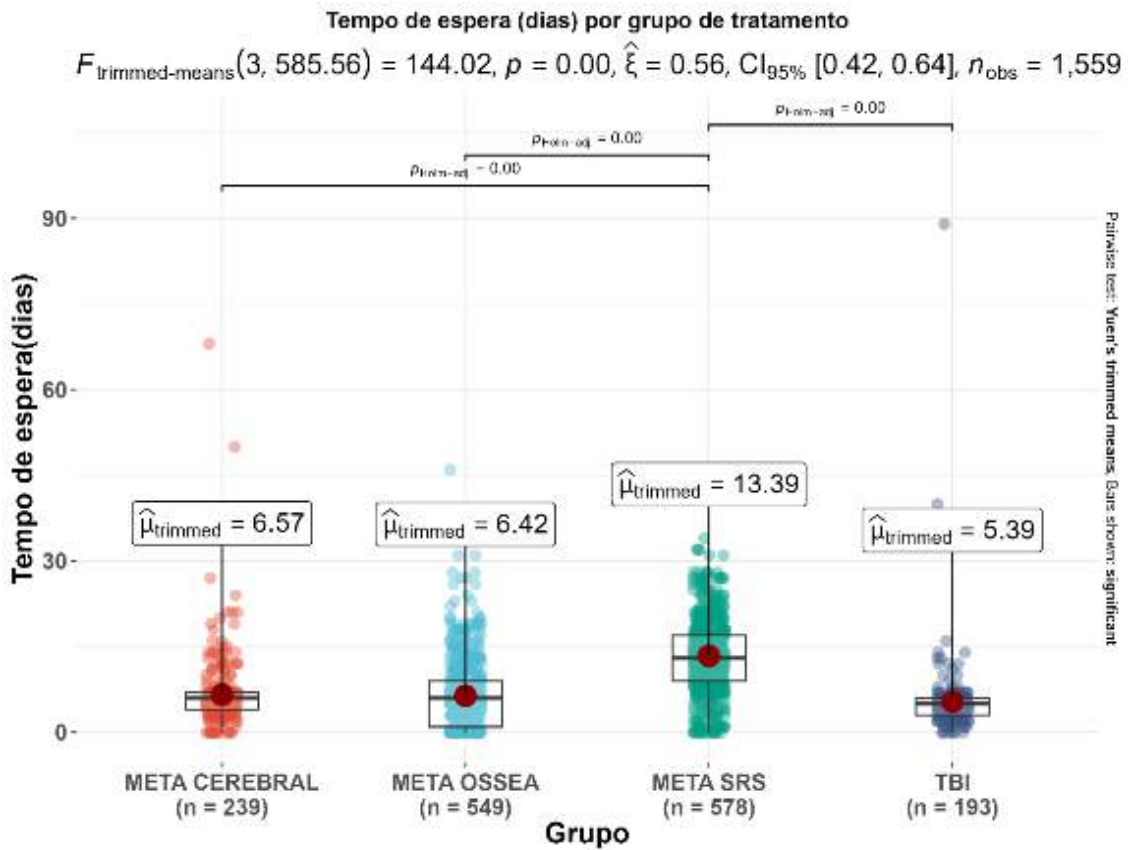




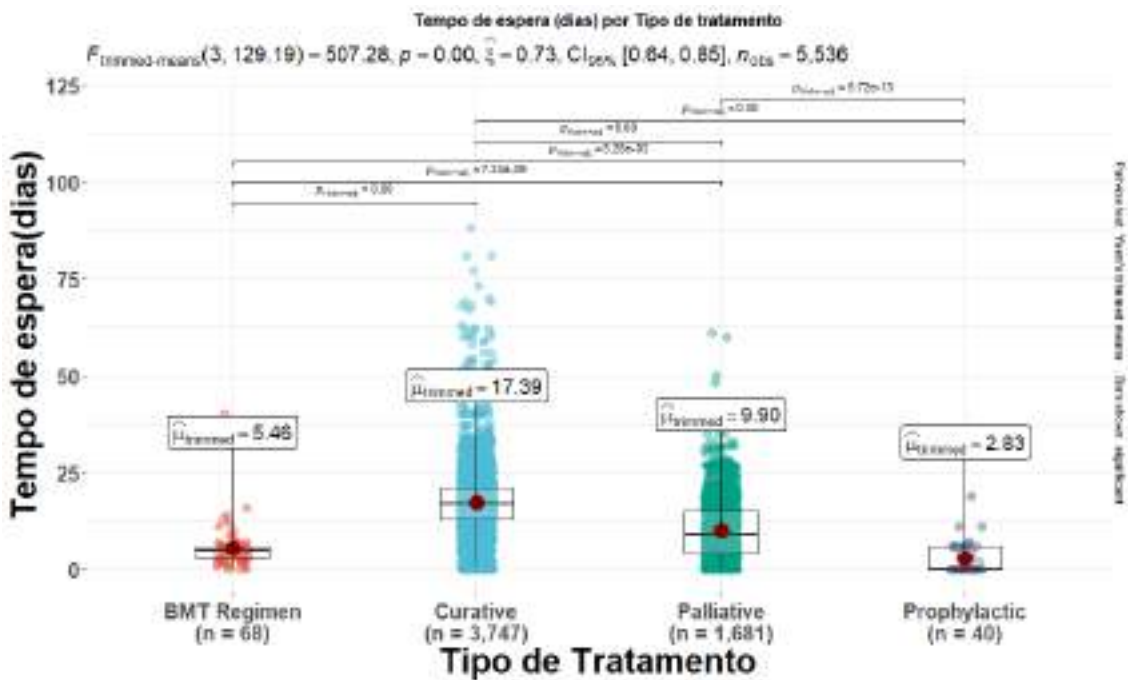
(B)



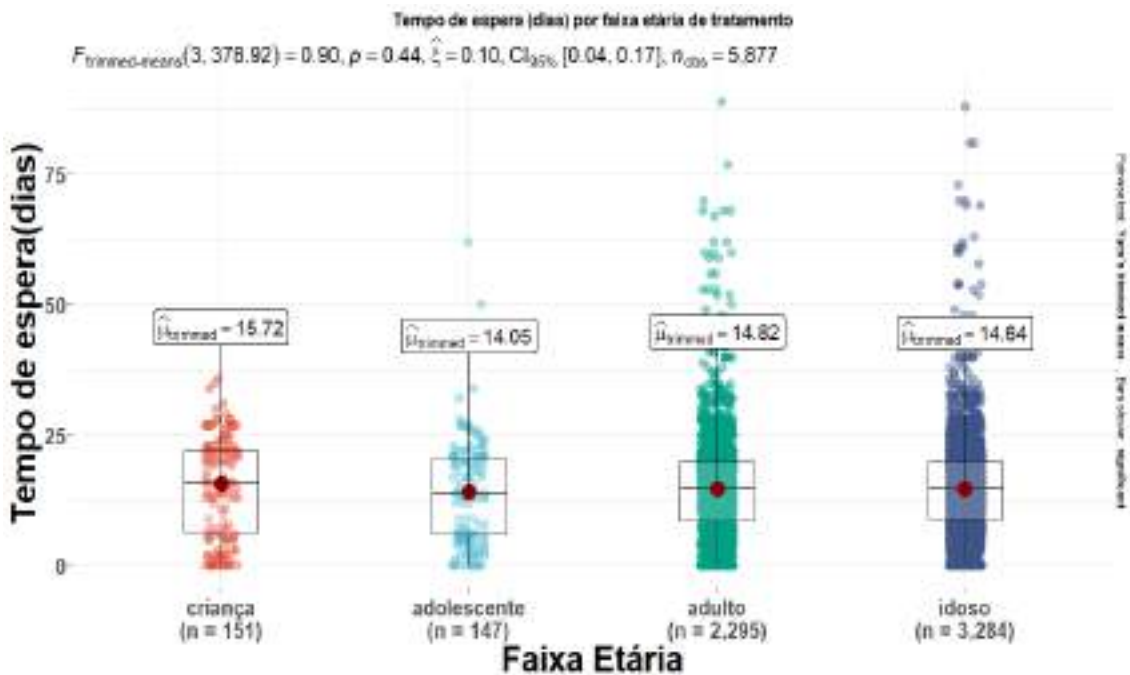
(C)



(D)



(E)



(F)

A Figura 19 apresenta gráficos de caixa dos dados do tempo de espera com análises estatísticas fazendo diferentes agrupamentos. As comparações entre os atributos que o *p-value* ficou menor que 0,05 são representadas na Figura 19 por uma linha contínua horizontal, ou seja, existe diferença estatística entre os *inputs* da variável. As técnicas moduladas apresentam uma média de tempo de espera maior (Figura 19A), porque é necessário fazer um controle de qualidade específico para essa modalidade de tratamento enquanto as técnicas de TBI e 2d como são mais simples, têm um tempo menor. Já em relação aos grupos de tratamento, têm-se que o grupo de próstata (URO próstata) (Figura 19C) possui a maior média de tempo de espera e o grupo de SN apresenta a maior mediana de tempo de espera. Vale comentar que ao realizar a comparação do tempo de espera dos grupos mais frequentes selecionando apenas a técnica VMAT, o grupo de CP tornou-se o grupo com a maior média de tempo de espera, porém, os grupos não se mostraram estatisticamente diferentes. O grupo de metástase óssea (Figura 19D) é o que possui menor média de tempo.

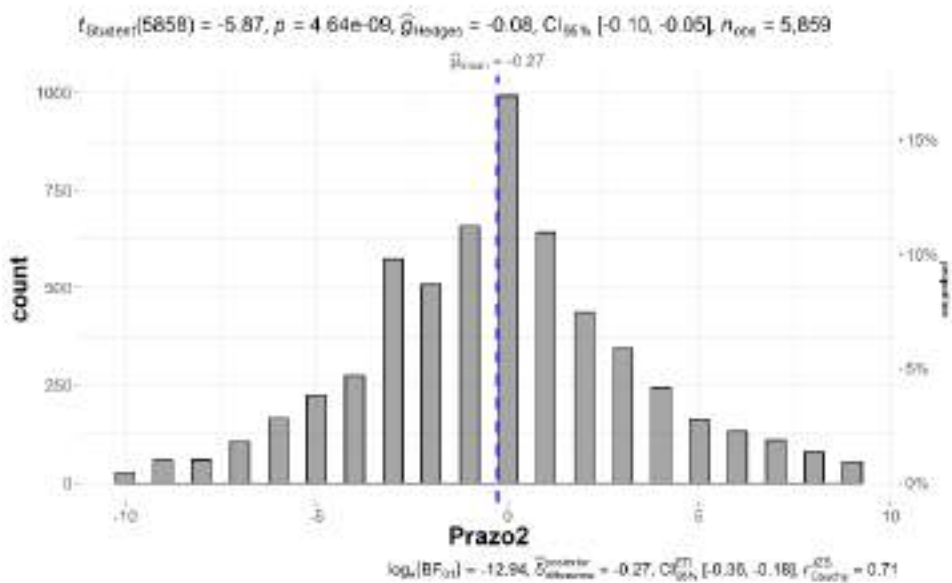
Em relação aos tratamentos de radiocirurgia dose única e fracionada, os tempos de espera com a técnica 3D e IMRT não são significativamente

diferentes (Figura 19B). Porém o tempo de espera de SRS com 3D mostrou-se diferente do tempo de REF 3D, como mostra a Figura 19B. O tempo de espera dos casos paliativos é menor que dos curativos, Figura 19E.

A média do tempo de espera dos casos paliativos é de aproximadamente 10 dias e dos curativos de 17 dias. Avaliando o tempo ideal e máximo sugerido pelo *Joint Collegiate Council for Oncology*, 75% dos nossos casos se encontram dentro do tempo máximo aceitável, porém menos que 50% se encontram dentro do tempo ideal. O tempo de espera por tipo de tratamento é significativamente diferente. Já o tempo de espera por faixa etária não se mostrou diferente, Figura 19F.

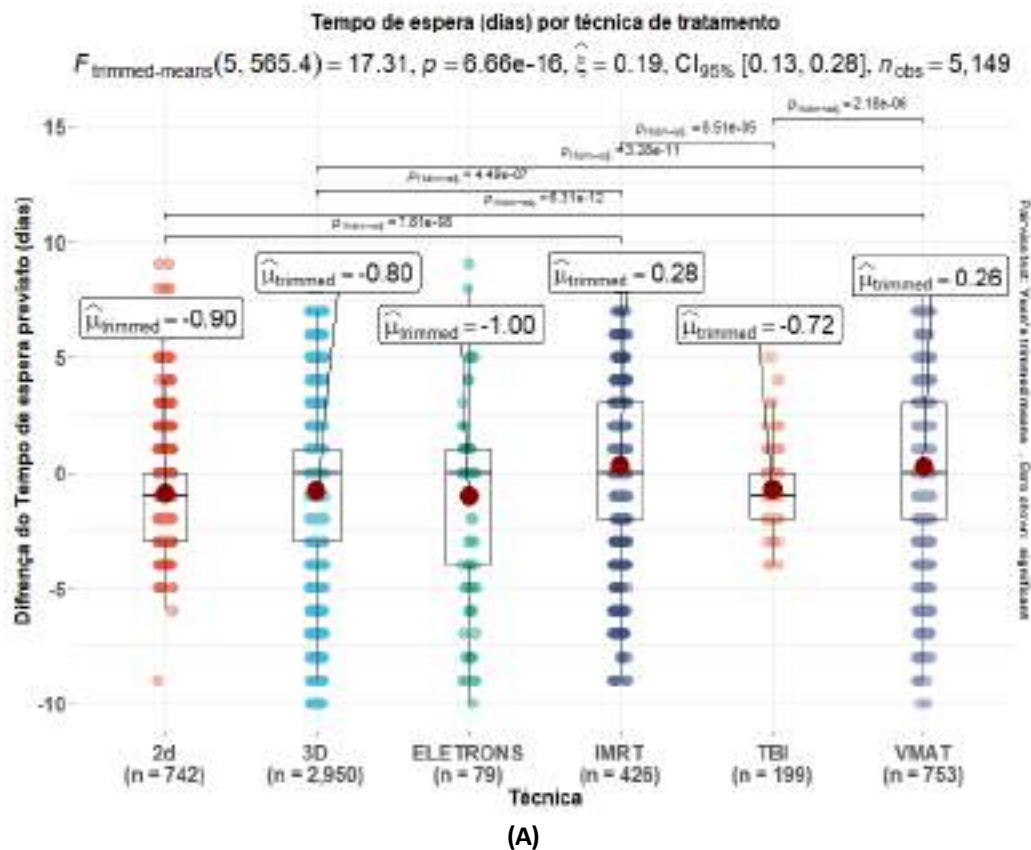
Além do tempo de espera, analisou-se a diferença entre o tempo previsto e o tempo real, ou seja, na etapa de simulação é fornecida uma data provável de início de tratamento, porém muitas vezes essa data tem grandes desvios em relação à data efetiva, o que pode causar ansiedade nos pacientes. Da mesma forma, se a data for antecipada pode existir uma incompatibilidade de disponibilidade dos pacientes, e como a radioterapia é um tratamento diário que pode durar mais de um mês é necessária uma organização pessoal prévia. O histograma com a diferença entre o tempo de espera real e o tempo previsto (variável nomeada com Prazo2) está apresentado na Figura 20.

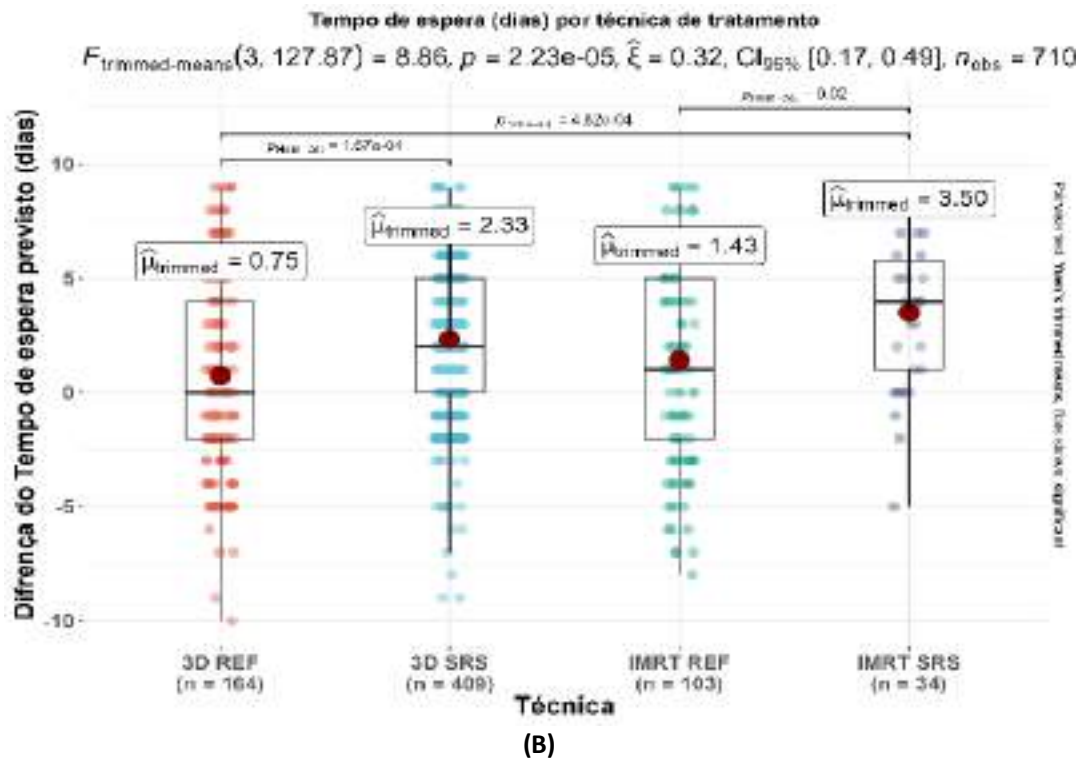
FIGURA 20 - HISTOGRAMA COM AS DIFERENÇAS ENTRE O TEMPO DE ESPERA REAL E O TEMPO PREVISTO EM DIAS.



Em média, a data prevista é igual a data real de início. Os desvios mais frequentes são adiantamento e atraso de 1 dia. Para essa análise foram retirados os dados discrepantes, total de 321 pacientes. Um dos motivos para esses dados discrepantes é que não foi adquirida, no sistema de gerenciamento, a data de execução das atividades referentes ao tempo de espera ou foi associado ao paciente um prazo de data previsto incorreto, por exemplo, inserido uma previsão de data para o paciente de um tratamento com técnica IMRT para um paciente que teve seu planejamento com técnica 2d. Pela Figura 20 percebe-se que existem casos com atraso e adiantamento de até 10 dias, logo para entender esses dados, realizou-se análise dos desvios de data de espera prevista por técnica, Figura 21 e por grupo Figura 22.

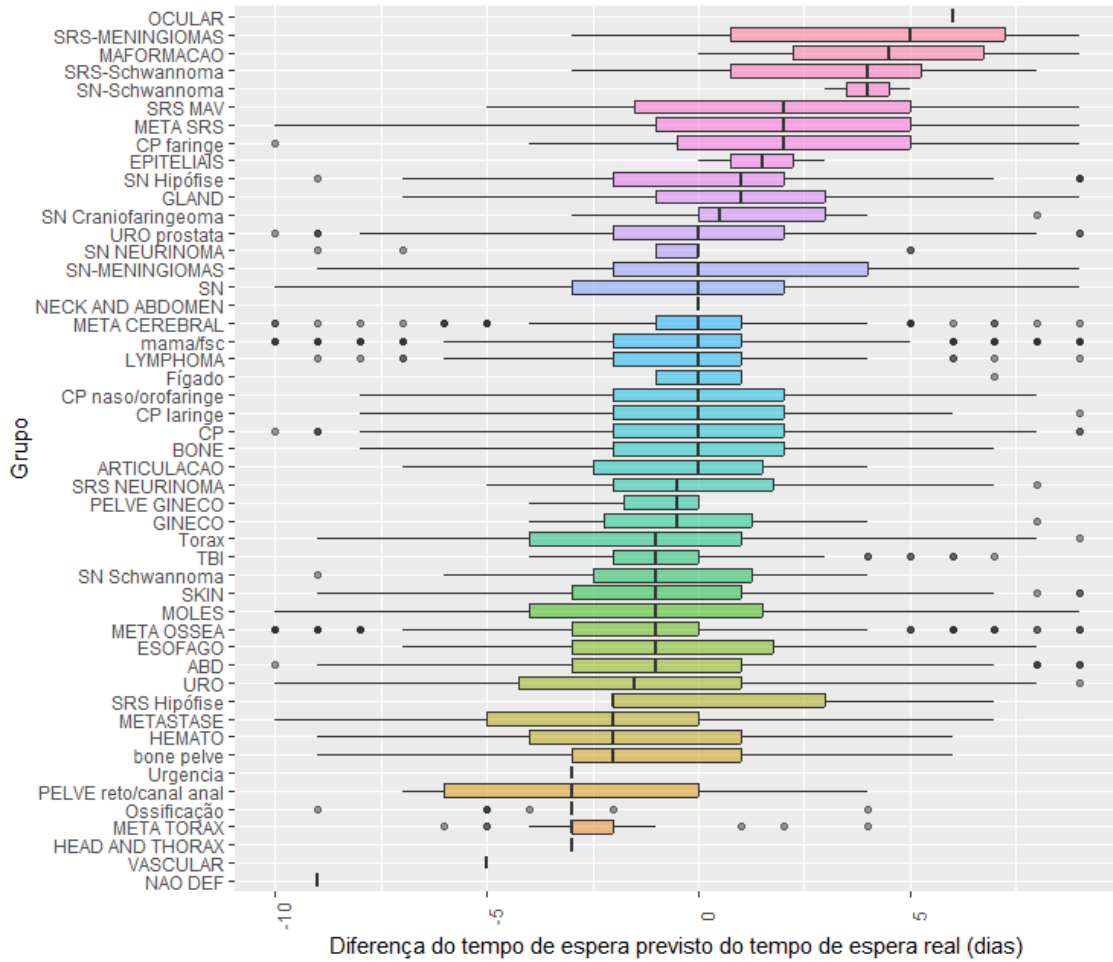
FIGURA 21 - DIFERENÇAS ENTRE O TEMPO DE ESPERA REAL E O TEMPO PREVISTO POR TÉCNICA DE TRATAMENTO.

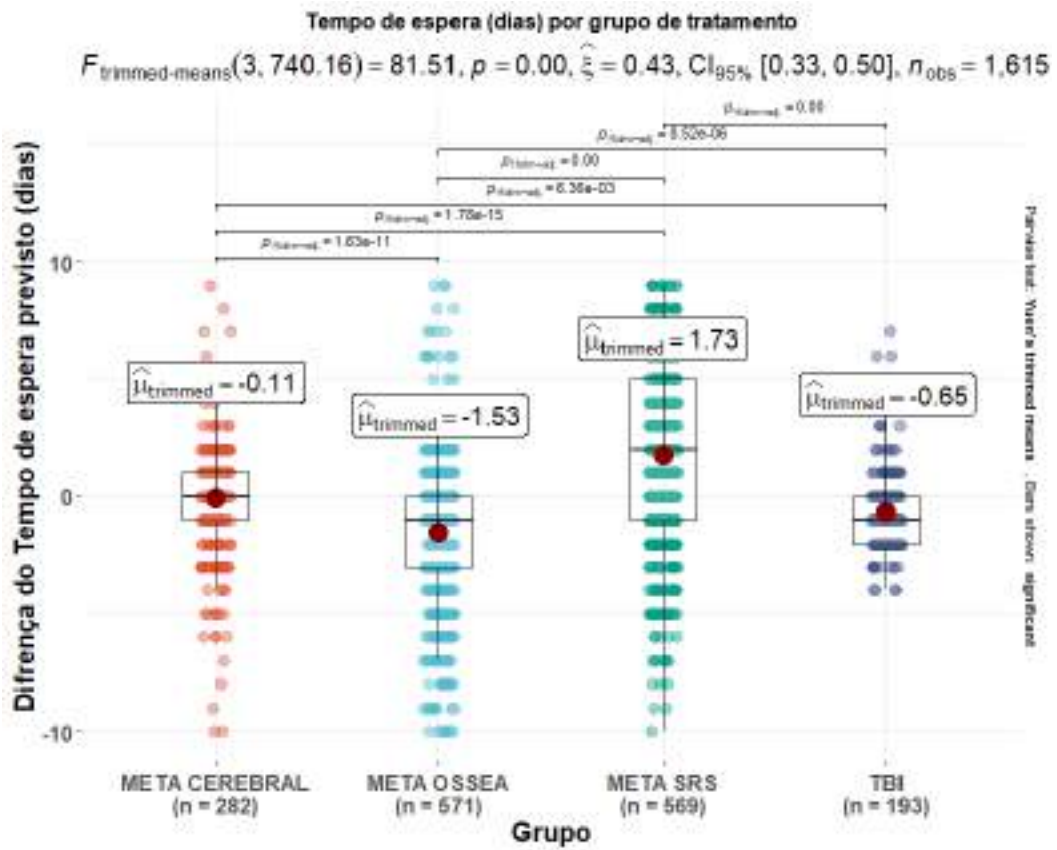
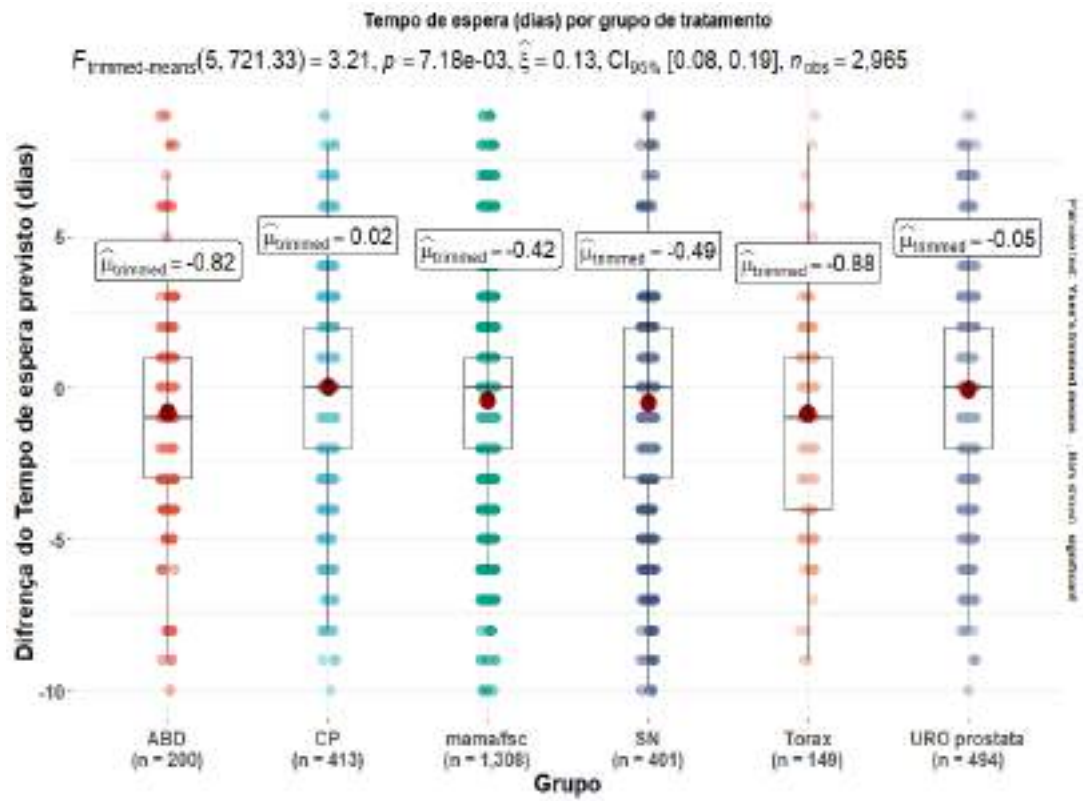




Os tratamentos de radiocirurgia em dose única com técnica 3D, arco e IMRT e as radiocirurgias fracionadas com IMRT são os que mais atrasam em relação a data prevista, suas médias estão maiores que zero. Os tratamentos com técnica 2d e TBI apresentam média da variável Prazo2 e terceiro quartil menor que zero, o que representa que os pacientes são convocados antes da data prevista. A mediana dos casos com a técnica 3D, IMRT, ELÉTRONS e VMAT é próxima de 0.

FIGURA 22 - DIFERENÇA ENTRE O TEMPO DE ESPERA REAL E O TEMPO DE ESPERA PREVISTO POR GRUPO. (A)- BOXPLOT DE TODOS OS GRUPOS, (B)- BOXPLOT COM TESTE ESTATÍSTICO PARA OS GRUPOS MAIS FREQUENTES EXCETO METÁSTASES E TBI E (C) BOXPLOT COM TESTE ESTATÍSTICO PARA OS GRUPOS DE METÁSTASES E TBI.






Pela Figura 22A observa-se que os maiores desvios, considerando a mediana da diferença entre as datas prevista e real, são os tratamentos de meningiomas, schwannomas, MAV, radiocirurgia de metástases e CP faringe. O grupo ocular apresenta apenas um caso, logo esse dado não é representativo. Percebe-se que existe uma grande variação entre o tempo de espera dentro dos grupos e que em alguns grupos menos que 25% dos pacientes tem o tempo de espera previsto igual ao real, como por exemplo, radiocirurgia de meningiomas e schwannomas. Pela Figura 22B e 22C, tem-se que os grupos mais frequentes têm a média de desvio próximo de zero. Para os grupos de CP, SN, mama/fsc, uro próstata e meta cerebral 50% dos pacientes tem tempo de espera maior que o previsto. No grupo de TBI e de meta óssea pelo menos 75% dos pacientes são tratados no prazo previsto. O grupo que tem maior frequência de atrasos é o de meta SRS, sendo que menos de 50% dos pacientes são tratados no prazo.

Vale ressaltar que ao longo dos anos houve variações no tempo padrão do departamento, porém não foi possível definir as datas exatas dessas modificações, a Figura 23 exemplifica essas modificações.

FIGURA 23 - VARIAÇÃO DO TEMPO PADRÃO NO PERÍODO AVALIADO POR TÉCNICA.



As técnicas de 3D REF e IMRT REF foram as que mais tiveram modificações ao longo dos anos.

Uma comparação da média do tempo de espera real por técnica e a média do tempo de espera padrão por técnica está representada na Tabela 5, o desvio padrão do tempo padrão é referente às modificações apontadas na Figura 23.

TABELA 5 - COMPARAÇÃO DO TEMPO DE ESPERA PADRÃO MÉDIO E O TEMPO REAL MÉDIO POR TÉCNICA.

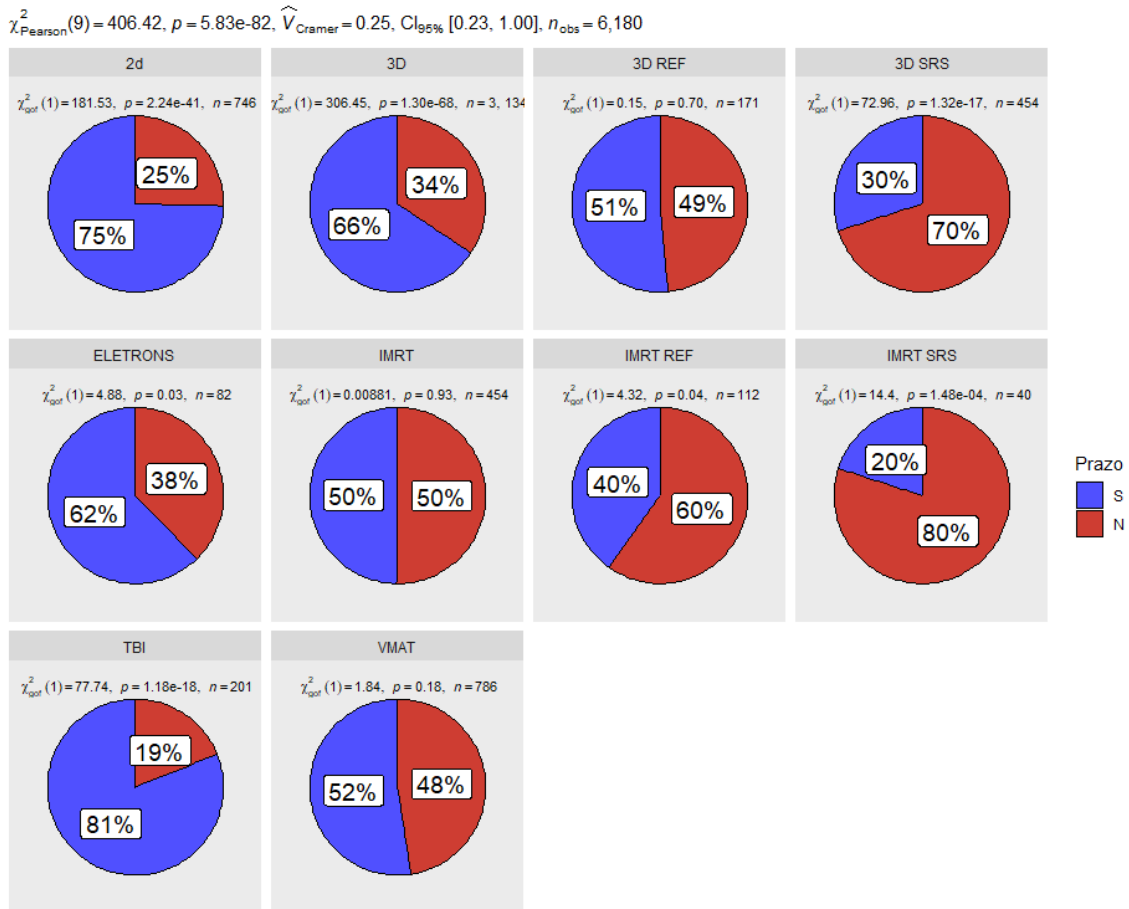
| Técnica | Convênio | Tempo de espera real (dias) | Tempo de espera padrão (dias) |
|----------|----------|-----------------------------|-------------------------------|
| 2d | SIM | 1 ± 1 | 1 ± 0 |
| | NÃO | 2 ± 2 | 1 ± 0 |
| 3D | SIM | 5 ± 5 | 8 ± 3 |
| | NÃO | 11 ± 6 | 9 ± 3 |
| 3D REF | SIM | 9 ± 4 | 7 ± 6 |
| | NÃO | 11 ± 5 | 8 ± 4 |
| 3D SRS | SIM | 6 ± 5 | 2 ± 1 |
| | NÃO | 7 ± 5 | 2 ± 2 |
| ELETRONS | SIM | 2 ± 3 | 7 ± 3 |
| | NÃO | 10 ± 6 | 9 ± 3 |
| IMRT | SIM | 11 ± 7 | 11 ± 2 |
| | NÃO | 14 ± 5 | 11 ± 2 |
| IMRT REF | SIM | 6 ± 2 | 7 ± 5 |
| | NÃO | 13 ± 6 | 9 ± 4 |
| IMRT SRS | SIM | 7 ± 3 | 3 ± 0 |
| | NÃO | 11 ± 7 | 3 ± 3 |
| TBI | SIM | 3 ± 2 | 1 ± 1 |
| | NÃO | 3 ± 3 | 1 ± 1 |
| VMAT | SIM | 9 ± 4 | 11 ± 2 |
| | NÃO | 14 ± 5 | 12 ± 2 |

Pela Tabela 5 tem-se que a técnica VMAT tem a média do tempo de espera real 2 dias maior que a média do tempo padrão para casos que não são convênio e um adiantamento de 2 dias para casos de convênio e a técnica de SRS sem técnica modulada (3D SRS) tem a média do tempo de espera real 5 dias maior que a média do tempo padrão para casos sem ser convênio e de 4 dias para convênio e a técnica modulada (IMRT SRS) de 8 dias para casos sem ser convênio e 4 dias para casos de convênio. Quando o paciente de radiocirurgia faz simulação o tempo (padrão) fornecido a ele é o mesmo, independentemente da técnica que será utilizada no seu tratamento, mas na prática o planejamento com IMRT têm uma fase extra de atividade (controle de qualidade do plano com verificação da dose planar).

Foi realizada uma avaliação da porcentagem de pacientes que são tratados com atraso e constatou-se que 39% deles tem atrasos na convocação, e 33% desses,

como tiveram atraso na fase pré-tratamento, não foram liberados para o agendamento na data prevista. Isso significa que a fase de agendamento aumenta o atraso. Figura 24 apresenta, por técnica e tipo de tratamento, as porcentagens dos casos iniciados e não iniciados na data de início prevista.

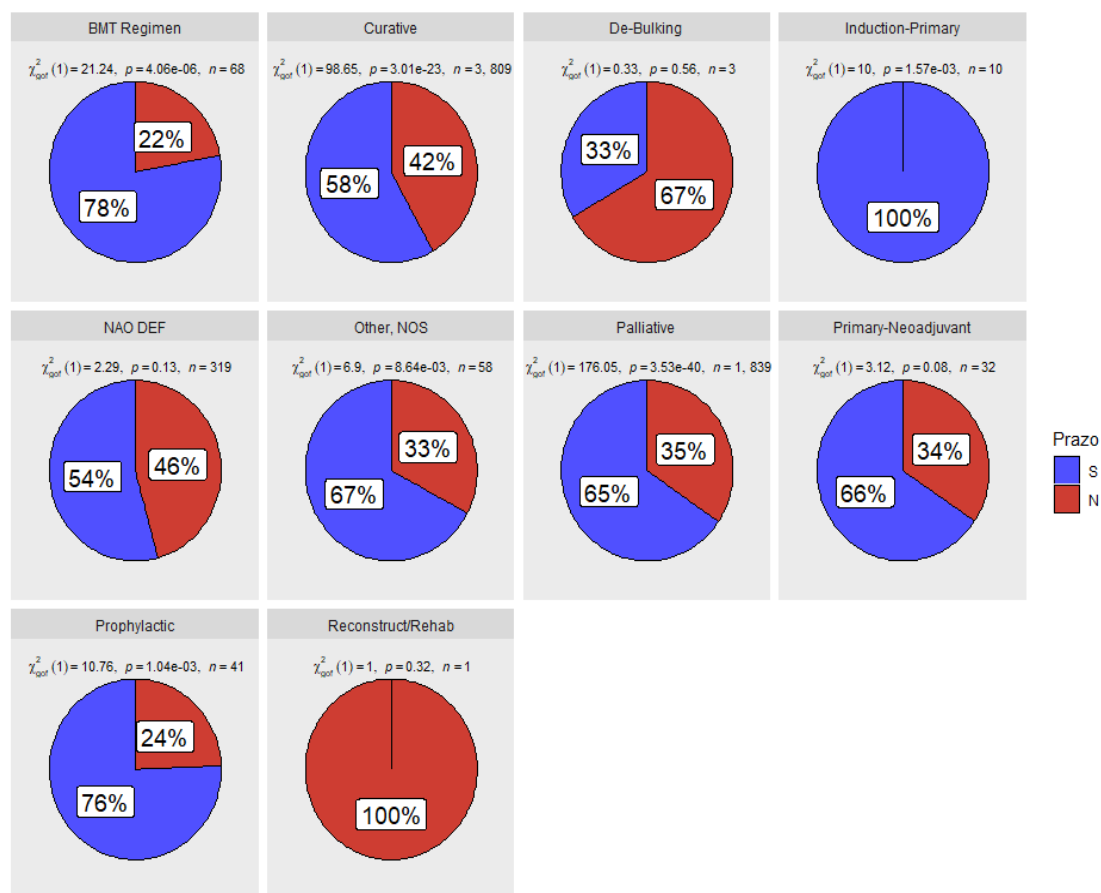
FIGURA 24 - (A) DISTRIBUIÇÃO DOS CASOS DE ATRASOS NO TEMPO DE ESPERA POR TÉCNICA DE TRATAMENTO E (B) DISTRIBUIÇÃO DOS CASOS DE ATRASOS NO TEMPO DE ESPERA POR TIPO DE TRATAMENTO.



$\log_e(\text{BF}_{01}) = -176.81, \hat{V}_{\text{Cramer}}^{\text{posterior}} = 0.25, \text{CI}_{95\%}^{\text{ETI}} [0.23, 0.28], a_{\text{Gurel-Dickey}} = 1.00$

(A)

$\chi^2_{\text{Pearson}}(9) = 56.88, p = 5.32e-09, \hat{V}_{\text{Cramer}} = 0.09, \text{CI}_{95\%} [0.06, 1.00], n_{\text{obs}} = 6,180$



$\log_e(\text{BF}_{01}) = 6.14, \hat{V}_{\text{Cramer}}^{\text{posterior}} = 0.09, \text{CI}_{95\%}^{\text{ETI}} [0.07, 0.11], \theta_{\text{Gureel-Dickey}} = 1.00$

(B)

Pela Figura 24A percebe-se que 80% dos pacientes que tratam SRS com IMRT e 70% dos pacientes que tratam SRS com 3D são convocados para o tratamento com atraso. Nos casos de tratamentos com a técnica 2d apenas 25% dos pacientes são convocados com atraso.

Dos casos curativos (Curative), 42% são convocados para o tratamento com atraso e para os casos paliativos (Palliative) são 35%. Os tipos de tratamentos definidos como *De-Bulking* e *Reconstruct/Rehad* possuem poucos casos, portanto os dados não são representativos. Os casos classificados como “NAO DEF” também podem ser desconsiderados para análise pois foram pacientes que não continham a informação de tipo de tratamento (Figura 24B).

Para avaliar quais etapas do processo de pré-tratamento influenciam no tempo de espera, foi realizada uma avaliação por técnica e por grupo nas duas principais atividades da etapa de pré-tratamento, Figura 25 e 26.

FIGURA 25 - AVALIAÇÃO DO TEMPO DE CONTORNO POR GRUPO E TÉCNICA.


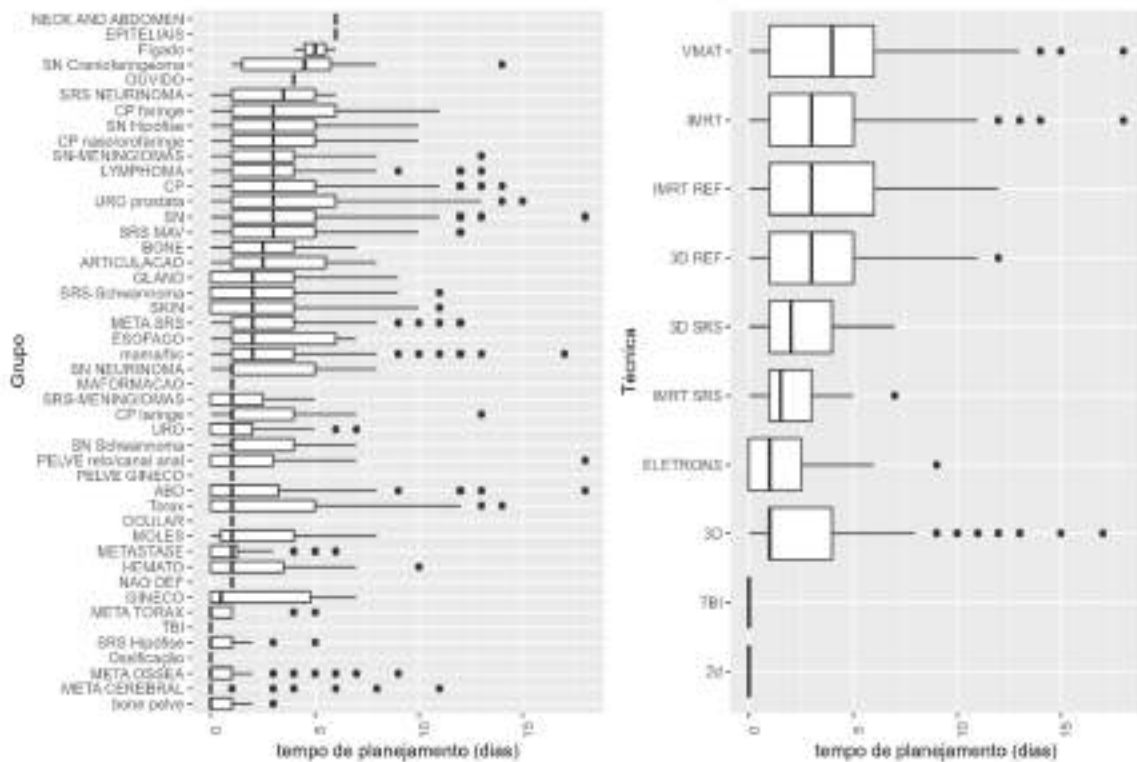


FIGURA 26 - AVALIAÇÃO DO TEMPO DE PLANEJAMENTO POR GRUPO E TÉCNICA.



As atividades de contorno e planejamento são as etapas mais demoradas do processo de pré-tratamento e apresentam alto coeficiente de correlação com o tempo de espera, por isso foram selecionadas para serem apresentadas por técnica e grupo. Percebe-se que a técnica de tratamento influencia mais o tempo de planejamento que o tempo de contorno. A técnica de VMAT e a região de craniofaringioma têm o maior tempo de planejamento e a região de neurinoma tem maior tempo de contorno. As Figuras 27 e 28 mostram as diferenças dos tempos de planejamento e contorno por técnica de tratamento e se existem diferenças estatísticas.

FIGURA 27 - AVALIAÇÃO COM TESTE ESTATÍSTICO DAS DIFERENÇAS DO TEMPO DE CONTORNO.






FIGURA 28 - AVALIAÇÃO COM TESTE ESTATÍSTICO E AS DIFERENÇAS DO TEMPO DE PLANEJAMENTO.




Os tempos de contorno e de planejamento dos casos 3D, VMAT e IMRT são estatisticamente diferentes. Os tempos de planejamento 3D REF e 3D SRS são estatisticamente diferentes, assim como, o de IMRT REF e IMRT SRS. As técnicas VMAT e IMRT têm os maiores tempos médios de planejamento e contorno.

Estudando quais etapas influenciam mais nos atrasos do tempo de espera, temos como principais atividades o contorno e aprovação do plano. Na fase de contorno, 30% dos pacientes tem o tempo de contorno maior do que o previsto com diferença média de 3 dias. Na fase de planejamento, 28% dos pacientes tem o tempo de planejamento maior do que o previsto com diferença média de 3 dias e na fase de aprovação do plano, 29% dos pacientes tem o tempo de execução maior do que o previsto com diferença média de 3 dias. A avaliação dos desvios de prazo por grupo e técnica encontram-se nas Figuras 29 e 30.


FIGURA 29 - MÉDIA DOS DESVIOS ENTRE O TEMPO REAL E O PREVISTO POR GRUPO DE TRATAMENTO EM RELAÇÃO AS ATIVIDADES DE CONTORNO (A), CONFECÇÃO DO PLANO (B) E APROVAÇÃO DO PLANO (C).



(A)




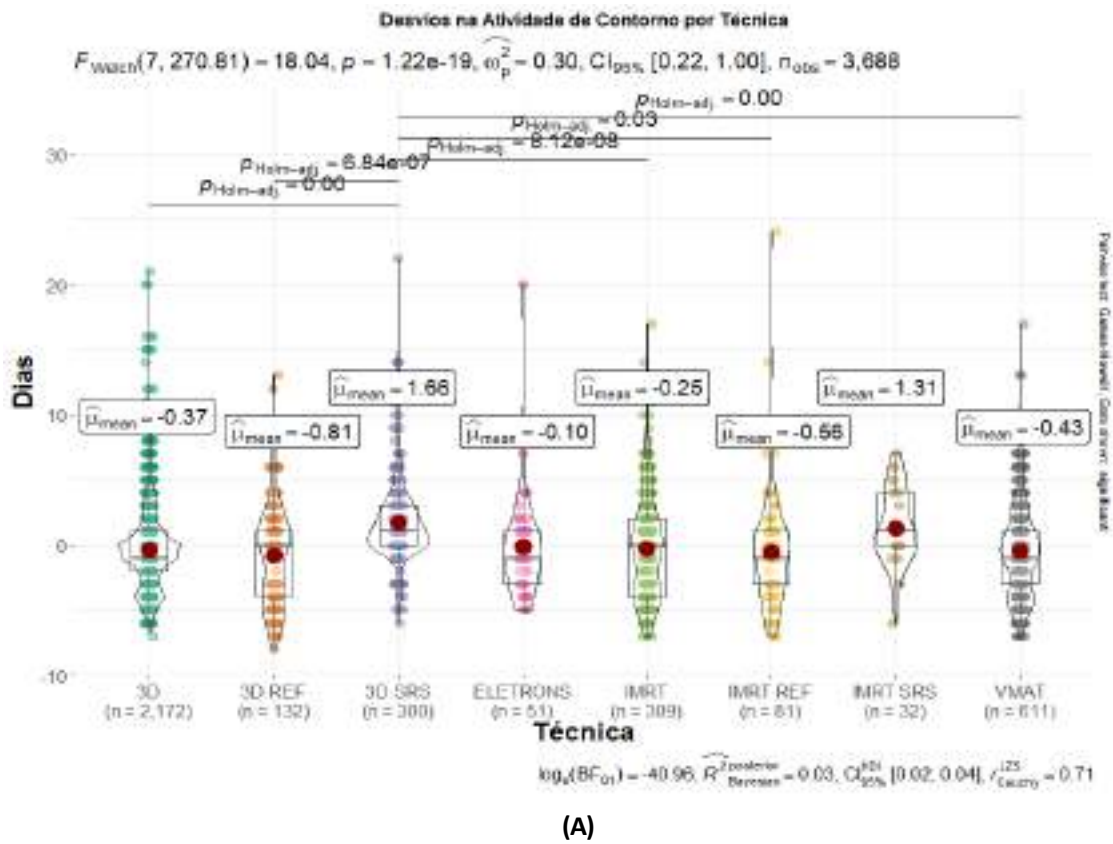
(B)




(C)

Avaliando a Figura 29, os desvios encontrados sugerem que o contorno para casos de naso/orofaringe e faringe deveria ser aumentado de um dia e contorno e aprovação do plano para radiocirurgia de meningioma e neurinoma deveria ser aumentado de três dias. O tempo de plano deveria apenas ser aumentado para o grupo epiteliais e de pescoço/abdome. O tempo médio para contorno de casos de radiocirurgia e de aprovação de plano deveria ser aumentado em um dia.

FIGURA 30 - MÉDIA DOS DESVIOS ENTRE O TEMPO REAL E O PREVISTO POR TÉCNICA DE TRATAMENTO EM RELAÇÃO AS ATIVIDADES DE CONTORNO (A), CONFECÇÃO DO PLANO (B) E APROVAÇÃO DO PLANO (C).






(C)

Pela Figura 30A percebe-se que menos que 25% dos pacientes tem seu tempo de contorno dentro do prazo para os casos de 3D SRS e IMRT SRS. Os casos de 3D REF têm 50% dos pacientes dentro do prazo e os casos 3D convencional, VMAT, IMRT e ELETRONS mais que 50%. Pela Figura 30B tem-se que em todas as técnicas de tratamento, pelo menos 50% dos pacientes estão dentro do prazo de planejamento. Os desvios médios maiores que zero foram encontrados para a técnica 3D REF e SRS e IMRT REF e SRS. Casos utilizando elétrons (ELETRONS) têm um tempo de planejamento menor do que o previsto. Pela Figura 30C, observa-se que os casos de SRS tanto 3D e IMRT têm maiores diferenças do prazo de aprovação do plano.

Para analisar a sazonalidade desses atrasos observados avaliou-se o número de casos com atrasos por mês e para entender razões para os atrasos verificou-se a porcentagem de ocupação das vagas disponíveis no equipamento, Figuras 31 e 32.


FIGURA 31 - (A) INCIDÊNCIA DE CASOS EM ATRASOS AO LONGO DE 2016 A 2020 E (B) PORCENTAGEM DE PACIENTES EM ATRASOS POR MÊS E ANO, S SÃO OS PACIENTES QUE ESTÃO DENTRO DO PRAZO PREVISTO E N SÃO OS PACIENTES QUE NÃO ESTÃO DENTRO DO PRAZO.



(A)

2016

$$\chi^2_{\text{Pearson}}(11) = 156.28, p = 7.73e-28, \hat{V}_{\text{Cramer}} = 0.33, CI_{95\%} [0.27, 1.00], n_{\text{obs}} = 1,300$$




$$\log_e(\text{BF}_{01}) = -59.14, \hat{V}_{\text{Cramer}}^{\text{posterior}} = 0.34, CI_{95\%}^{\text{ETI}} [0.28, 0.39], \alpha_{\text{Guel-Dickey}} = 1.00$$

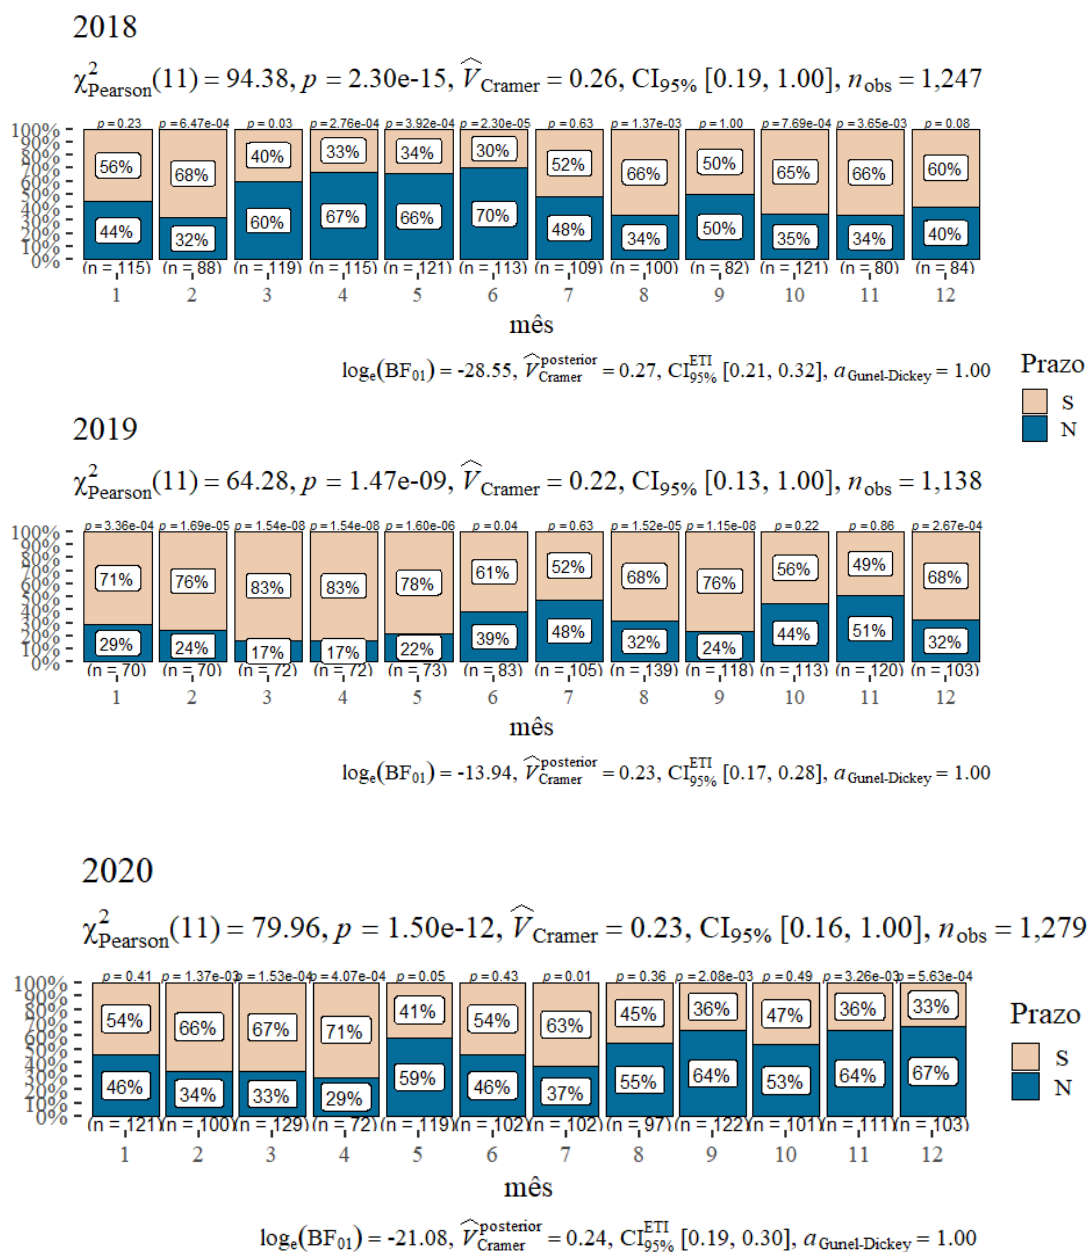
Prazo
■ S
■ N

2017

$$\chi^2_{\text{Pearson}}(11) = 22.14, p = 0.02, \hat{V}_{\text{Cramer}} = 0.10, CI_{95\%} [0.00, 1.00], n_{\text{obs}} = 1,216$$



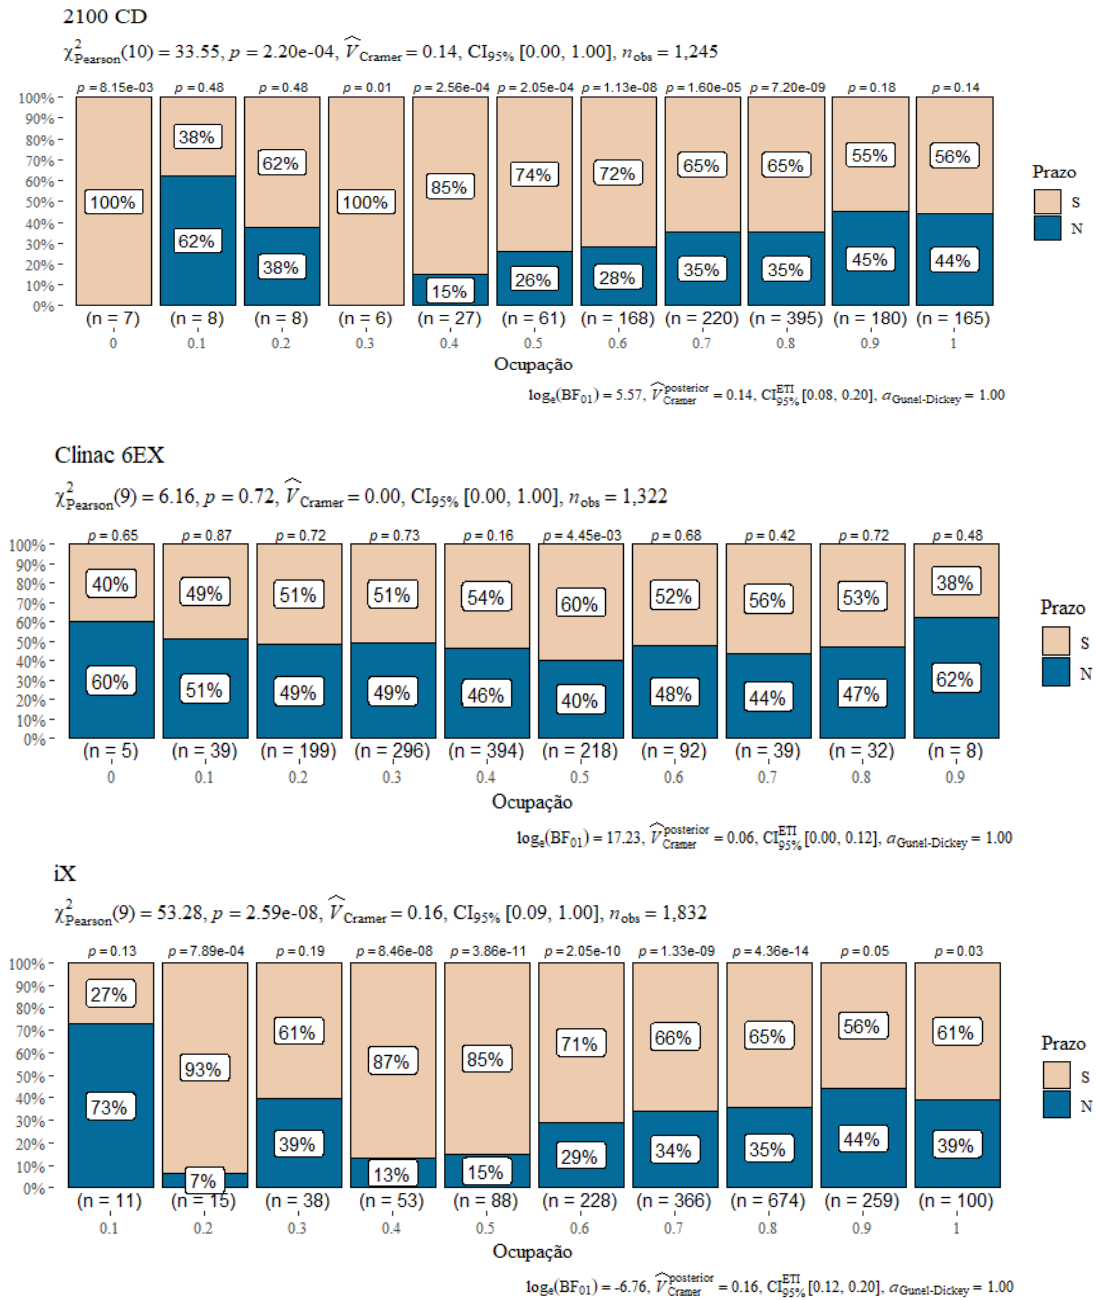
$$\log_e(\text{BF}_{01}) = 7.24, \hat{V}_{\text{Cramer}}^{\text{posterior}} = 0.13, CI_{95\%}^{\text{ETI}} [0.05, 0.19], \alpha_{\text{Guel-Dickey}} = 1.00$$



(B)

A Figura 31A mostra que o ano de 2020 tem média de atrasos maior do que os outros anos avaliados. Na Figura 31B percebe-se que no ano de 2020, em 6 de 12 meses os casos em atraso (Prazo=N) são predominantes, o que não ocorreu nos outros anos. Em 2017, nenhum dos meses teve predominância do grupo fora do prazo. O número total de casos avaliados por ano variou de 1.138 a 1.300.

FIGURA 32 - INCIDÊNCIA DE CASOS EM ATRASO POR FAIXAS DE OCUPAÇÃO E EQUIPAMENTO.



Uma razão provável para ocorrer atrasos é a falta de vagas, a Figura 32 apresenta esse estudo. A ocupação de 0 até 20% (0,2) é referente a dias em que ocorreram manutenções corretivas ou preventivas no equipamento, logo a agenda estava bloqueada para o agendamento e não significa que não havia ocupação. Pela Figura 32, percebe-se que a proporção de casos atrasados não tem uma relação linear com a ocupação e não tem um padrão entre os

equipamentos. Porém, existe uma relação entre a ocupação e a porcentagem de atraso com *p-value* significativo para o equipamento 2100 CD e iX.

As manutenções preventivas geram atrasos no início dos tratamentos, já que a maioria dos pacientes não realizam seus tratamentos e a agenda não fica disponível para novos agendamentos. A ocupação mais frequente dos equipamentos 2100 CD e iX é de 80% (0,8) e do Clinac 6EX é de 40% (0,4). No equipamento 2100 CD a proporção de atrasos aumenta com o aumento da ocupação. O equipamento Clinac 6EX é um aparelho que realiza radiocirurgia e TBI, e existem muitas vagas bloqueadas para a chegada desses casos no departamento então é difícil avaliar alguma relação com a ocupação, entretando, 62% dos dias com a ocupação 90% (0,9) produziram atrasos nos inícios de tratamento. No iX parece haver uma relação entre o aumento de atrasos e o aumento da ocupação.

Uma preocupação que surge com maiores tempos de espera para o início de tratamento é a progressão da doença, portanto realizou-se um estudo com os casos que retornaram para um novo tratamento, Figura 33 e Tabela 6.

FIGURA 33- PORCENTAGEM DE RETORNOS PARA NOVOS TRATAMENTOS POR GRUPO.




TABELA 6- NÚMERO DE CASOS POR GRUPO (FREQ_GRUPO) E NÚMERO DE CASOS QUE RETORNARAM EM CADA GRUPO (FREQ).

| Grupo | Freq_Grupo | Freq | Grupo | Freq_Grupo | Freq |
|-----------------------|------------|--------|---------------------|------------|-------|
| HEAD AND THORAX | 1 | 1.00 | mama/fsc | 1331 | 47.00 |
| NECK AND ABDOMEN | 1 | 1.00 | Ossificação | 54 | 1.00 |
| BONE | 21 | 8.00 | TBI | 193 | 3.00 |
| META SRS | 525 | 108.00 | URO prostata | 509 | 4.00 |
| MOLES | 62 | 12.00 | EPITELIAIS | 2 | 0.00 |
| bone pelve | 52 | 10.00 | Figado | 4 | 0.00 |
| METASTASE | 42 | 8.00 | GLAND | 62 | 0.00 |
| HEMATO | 32 | 6.00 | MAFORMACAO | 2 | 0.00 |
| META OSSEA | 529 | 71.00 | NAO DEF | 1 | 0.00 |
| CP faringe | 18 | 2.00 | OCULAR | 1 | 0.00 |
| SKIN | 133 | 14.00 | OUVIDO | 1 | 0.00 |
| CP naso/orofaringe | 139 | 14.00 | PELVE GINECO | 4 | 0.00 |
| CP | 414 | 38.00 | SN-MENINGIOMAS | 43 | 0.00 |
| META CEREBRAL | 238 | 22.00 | SN-Schwannoma | 4 | 0.00 |
| ARTICULACAO | 22 | 2.00 | SN Craniofaringeoma | 14 | 0.00 |
| Torax | 148 | 12.00 | SN Hipófise | 80 | 0.00 |
| URO | 51 | 4.00 | SN NEURINOMA | 13 | 0.00 |
| ABD | 211 | 16.00 | SN Schwannoma | 15 | 0.00 |
| GINECO | 14 | 1.00 | SRS-MENINGIOMAS | 14 | 0.00 |
| META TORAX | 31 | 2.00 | SRS-Schwannoma | 43 | 0.00 |
| ESOFAGO | 47 | 3.00 | SRS Hipófise | 24 | 0.00 |
| CP laringe | 65 | 4.00 | SRS MAV | 55 | 0.00 |
| SN | 414 | 24.00 | SRS NEURINOMA | 16 | 0.00 |
| LYMPHOMA | 95 | 5.00 | Urgencia | 1 | 0.00 |
| PELVE reto/canal anal | 26 | 1.00 | VASCULAR | 1 | 0.00 |

Atualmente 8% dos pacientes retorna para realizar um novo tratamento. Analisaram-se esses casos para avaliar fatores que influenciam esses retornos. Foi feita correlação entre o número de casos por grupo e o número de retornos por grupo obtendo um valor de 0,67.

Foi realizada correlação entre o tempo de espera e o número de retornos e obteve-se um valor de 0,03, não demonstrando uma relação forte. Entretanto, observou-se que os retornos têm relação com certas doenças, ou seja, existem grupos de diagnóstico que apresentam maior frequência de retorno para um novo tratamento, os grupos com maior proporção de recidivas são os grupos de metástase cerebral, metástase óssea, partes moles, hemato e faringe. A metástase cerebral tem taxa de recidiva de 20,5%. Como os casos dos grupos nomeados por *Head and thorax* e *Neck and Abdomen* só têm uma amostra, não se pode fazer suposições de porcentagem de retorno. Para isso, seria necessária uma amostra maior.

Para avaliar possíveis relações foi realizado um teste dx2y que é uma opção viável quando se lida com variáveis categóricas e numéricas, Tabela 7.

TABELA 7- RESULTADOS DA AVALIAÇÃO DE DX2Y.

| x | y | perc_of_obs | x2y | CI_95_Lower | CI_95_Upper |
|-------------|-------------|-------------|-------|-------------|-------------|
| Frequencia | Tipo_tto | 100 | 13.17 | 11.07 | 15.41 |
| Tipo_tto | Frequencia | 100 | 10.74 | 8.69 | 12.34 |
| Grupo | Frequencia | 100 | 8.67 | 5.87 | 9.92 |
| Dose_Total | Frequencia | 100 | 6.74 | 4.57 | 7.79 |
| Dose_Fracao | Frequencia | 100 | 5.8 | 2.5 | 6.9 |
| TEC | Frequencia | 100 | 3.47 | 2.08 | 4.53 |
| Frequencia | Dose_Total | 100 | 3.19 | 2.3 | 4.02 |
| Frequencia | Grupo | 100 | 2.53 | 1.89 | 3.16 |
| Frequencia | Aparelho | 100 | 1.45 | 0.12 | 2.9 |
| Frequencia | Dose_Fracao | 100 | 1.39 | -0.38 | 1.88 |
| Aparelho | Frequencia | 100 | 1.32 | 0.6 | 2.64 |

O resultado da avaliação x_2y depende da ordem com que a variável é colocada na análise, logo uma boa pratica é selecionar a média dos valores. Como resultados temos que as relações mais fortes são do tipo de tratamento com uma média de dx_2y de 12, grupo com média de dx_2y de 5 e dose total com média de dx_2y de 4,9.

5.3 Tempo de Tratamento

Nessa seção são apresentadas as análises do tempo de sessão de tratamento. Foi realizada correlação entre as variáveis numéricas preditoras e o tempo de tratamento. Para essa correlação, as variáveis categóricas não foram transformadas em numéricas pois não se tinha o conhecimento da ordenação dessas informações. Portanto, para levar em consideração essas variáveis, foi avaliada a correlação agrupada por técnica, tipo de tratamento e pelos grupos mais frequentes, Tabelas 8, 9 e 10. A Figura 34 apresenta o resultado da correlação entre as variáveis para os casos 3D.

TABELA 8 - CORRELAÇÃO ENTRE O TEMPO DE TRATAMENTO E AS VARIÁVEIS PREDITORAS NUMÉRICAS AGRUPADAS PELA TÉCNICA.

| Variável | Técnica | | | | | | | | | |
|---------------|---------|-------|--------|--------|-------|----------|----------|-------|----------|------|
| | 2d | 3D | 3D REF | 3D SRS | IMRT | IMRT REF | IMRT SRS | VMAT | ELETRONS | TBI |
| CONVENIO | 0,05 | -0,01 | - | 0,07 | -0,04 | 0,07 | - | 0,03 | -0,03 | 0,03 |
| ANESTESIA | 0,07 | 0,01 | - | - | -0,13 | - | - | 0,15 | - | - |
| Bloco.Sessao | 0,09 | 0,11 | - | - | - | - | - | - | - | 0,48 |
| Filto.Sessao | 0,07 | 0,01 | - | - | - | - | - | -0,03 | - | -0,3 |
| campos.Sessao | 0,18 | 0,12 | 0,33 | 0,2 | 0,13 | 0,32 | 0,49 | 0,2 | 0,2 | 0,55 |
| Dose_Fracao | 0,21 | 0,23 | 0,27 | 0,18 | -0,27 | 0,19 | 0,53 | -0,11 | 0,1 | 0,05 |
| Isocentros | 0,32 | 0,34 | 0,28 | 0,21 | 0,13 | 0,21 | 0,26 | 0,14 | 0,32 | 0,48 |
| Dose_Total | 0 | 0,09 | 0,27 | 0,18 | 0,01 | 0,2 | -0,23 | -0,02 | 0,16 | 0,1 |
| INICIO | 0,49 | 0,48 | 0,21 | -0,05 | 0,42 | 0,17 | 0,45 | 0,46 | 0,51 | 0 |
| Portais | 0,35 | 0,49 | -0,08 | -0,08 | 0,06 | 0,15 | - | 0,5 | 0,58 | 0,17 |
| UM.Sessao | 0,19 | 0,2 | 0,2 | 0,2 | -0,1 | 0,12 | 0,52 | -0,1 | 0,14 | 0,54 |
| TempoRef | 0,74 | 0,67 | 0,82 | 1 | 0,75 | 0,84 | 0,98 | 0,63 | 0,67 | 0,79 |


TABELA 9 - CORRELAÇÃO ENTRE O TEMPO DE TRATAMENTO E AS VARIÁVEIS PREDITORAS NUMÉRICAS AGRUPADAS PELOS PRINCIPAIS TIPOS DE TRATAMENTO.

| Variável | Tipo de Tratamento | |
|---------------|--------------------|----------|
| | Paliativo | Curativo |
| CONVENIO | -0,03 | 0 |
| ANESTESIA | 0,04 | 0,09 |
| Bloco.Sessao | 0,05 | 0,08 |
| Filto.Sessao | 0,05 | -0,07 |
| campos.Sessao | 0,29 | 0,23 |
| Dose_Fracao | 0,34 | 0,09 |
| Isocentros | 0,26 | 0,28 |
| Dose_Total | 0,07 | 0,09 |
| INICIO | 0,49 | 0,48 |
| Portais | 0,2 | 0,36 |
| UM.Sessao | 0,35 | 0,19 |
| TempoRef | 0,77 | 0,69 |

TABELA 10 - CORRELAÇÃO ENTE O TEMPO DE TRATAMENTO E AS VARIÁVEIS PREDITORAS NUMÉRICAS AGRUPADAS PELOS PRINCIPAIS GRUPOS DE TRATAMENTO.

| Variável | Grupo de Tratamento | | | | |
|---------------|---------------------|--------------|-------|----------|------------|
| | Mama/fsc | Uro Prostata | CP | Meta SRS | Meta Óssea |
| CONVENIO | -0,03 | 0,02 | 0,04 | -0,04 | 0,02 |
| ANESTESIA | 0,05 | | 0,07 | | 0,09 |
| Bloco.Sessao | 0,02 | -0,01 | 0,09 | | 0,14 |
| Filtro.Sessao | 0,12 | -0,07 | -0,05 | -0,05 | 0,18 |
| campos.Sessao | 0,19 | -0,04 | 0,12 | 0,24 | 0,29 |
| Dose_Fracao | 0,29 | 0,03 | 0,08 | 0,41 | 0,21 |
| Isocentros | 0,34 | 0,07 | 0,22 | 0,26 | 0,37 |
| Dose_Total | 0,24 | 0,02 | 0,03 | -0,03 | 0,11 |
| INICIO | 0,54 | 0,47 | 0,49 | 0,3 | 0,49 |
| Portais | 0,54 | 0,6 | 0,51 | -0,06 | 0,44 |
| UM.Sessao | 0,3 | 0,16 | 0,1 | 0,43 | 0,23 |
| TempoRef | 0,61 | 0,55 | 0,66 | 0,91 | 0,72 |

FIGURA 34 - CORRELAÇÃO ENTRE AS VARIÁVEIS ESTUDADAS PARA TÉCNICA 3D.



Algumas variáveis só estão presentes em alguns tipos de técnicas, como é o caso dos acessórios blocos (Bloco.Sessao) e filtros (Filtro.Sessao) que não existem nos casos de IMRT, portanto, o agrupamento por técnica altera a força da correlação das variáveis, como se pode ver na Tabela 8. Nas Tabelas 8, 9 e


10, os valores em vermelho apresentaram *p-value* não significativo. A variável que possui muita força de correlação é a variável tempo de referência (TempoRef). Isso porque, essa variável foi definida através do agrupamento de algumas variáveis desse estudo para definir um tempo de tratamento mais adequado do que o utilizado atualmente. As variáveis agrupadas foram escolhidas, por serem informações conhecidas na simulação, são elas: dose por fração (Dose_Fracao), dose total (Dose_Total), grupo (Grupo), técnica (TEC), tipo de tratamento (Tipo_tto), número de isocentros (Isocentros), se a sessão é início (INICIO), se o paciente usa anestesia (ANESTESIA) e se o paciente é de convênio (CONVENIO). Porém o modelo de previsão foi proposto para melhorar ainda mais a previsão do tempo de tratamento já que utiliza as informações que só são conhecidas após o planejamento.

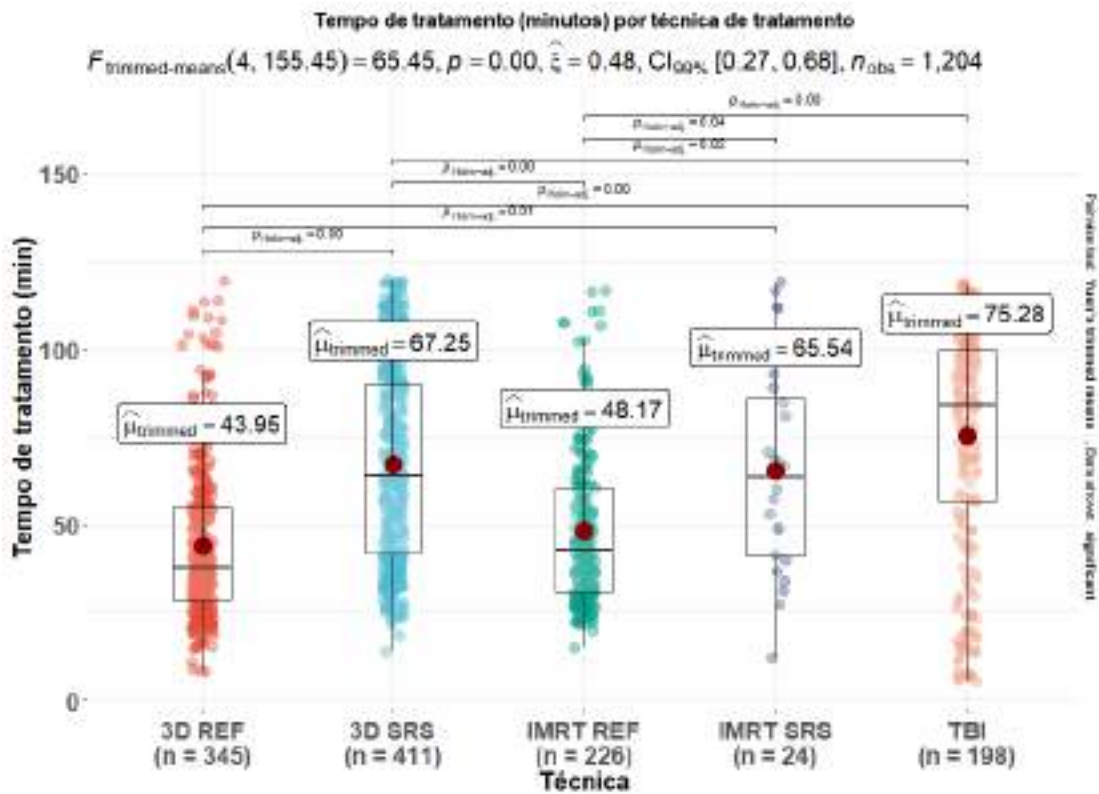
A Tabela 8 mostra que para a técnica de tratamento 3D, as variáveis mais correlacionadas com o tempo de tratamento são o tempo de referência sugerido (0,67), realização de portal de tratamento (0,49), sessão inicial de tratamento (0,48), número de isocentros (0,34), dose por fração (0,23) e unidade monitora (0,2). Já para a técnica de tratamento VMAT, foi encontrada correlação mais forte do tempo de tratamento com o tempo de referência sugerido (0,63), realização de portal de tratamento (0,5), sessão inicial de tratamento (0,46), número de campos (0,2) e realização de anestesia (0,15). Os casos de radiocirurgia apresentaram valores um pouco diferentes, além do TempoRef, as variáveis Isocentros e campos.Sessao apresentam correlação mais forte.

A correlação por tipo de tratamento, Tabela 9, mostrou que em ambos os tipos de tratamento a variável TempoRef e INICIO apresentaram os maiores valores de correlação. Para os casos paliativos a variável Dose_Fracao apresentou uma correlação maior com o tempo de tratamento do que os casos curativos, porém a variável Portal tem uma maior correlação nos casos curativos. Uma das razões para isso, é que as doses por fração dos casos curativos não têm uma variação grande, na maioria das vezes 180 cGy e 200 cGy e as dos casos paliativos variam entre 300 cGy e 800 cGy para casos convencionais e entre 24 Gy e 500 cGy para radiocirurgia. Em relação aos portais, os tratamentos paliativos têm menos frações de tratamento e na maioria dos dias são realizados portais.


A correlação por grupo, Tabela 10, mostrou que as variáveis TempoRef, INICIO e Portais têm uma maior força de correlação para as técnicas convencionais (Mama/fsc, Uro Prostata, CP e Meta Ossea), porém para os casos de metástase craniais (Meta SRS) a variável Portais e INICIO não são relevantes, pois, o tratamento é feito em apenas uma sessão de tratamento. Nesse caso a Dose_Fracao entra para o *ranking* das maiores correlações. Além disso, a métrica de x2y mostra que as variáveis TempoRef, INICIO, Portais, Grupo, UM.Sessao e TEC são as mais relacionadas com o tempo de tratamento, os valores de x2y encontrados foram 43, 23, 18, 12,5, 12 e 12, respectivamente. A Figura 35 apresenta a distribuição do tempo de tratamento por grupo e por técnica.

FIGURA 35 - DISTRIBUIÇÃO DO TEMPO DE TRATAMENTO. (A) TEMPO DE TRATAMENTO POR TÉCNICA PARA OS TRATAMENTOS CONVENCIONAIS, (B) TEMPO DE TRATAMENTO POR TÉCNICA PARA OS TRATAMENTOS ESPECIAIS, (C) TEMPO DE TRATAMENTO PARA OS GRUPOS DE ABDOME, CABEÇA E PESCOÇO, MAMA, SISTEMA NERVOSO CENTRAL, TORAX E PRÓSTATA E (D) TEMPO DE TRATAMENTO PARA OS GRUPOS DE METÁSTASES E TBI.

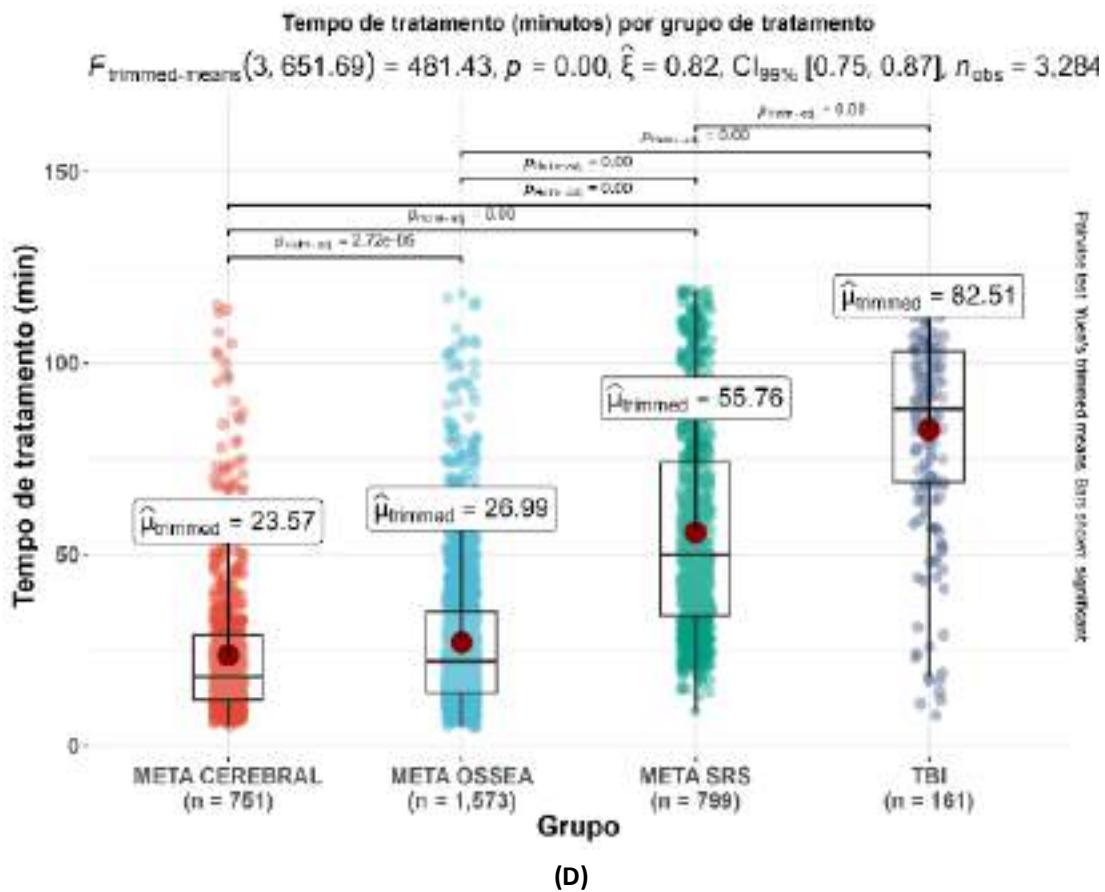




(B)



(C)



O teste de hipótese mostrou que a técnica e o grupo impactam no tempo de tratamento ($p\text{-value} = 0$). Os tratamentos especiais possuem tempo de tratamento maiores do que os tratamentos convencionais e com maior variação. Uma explicação para essa variação é que os casos de REF e SRS têm uma amplitude maior nas doses de prescrição e no número de isocentros e essas variáveis influenciam o tempo de tratamento. Não se pode afirmar que os tratamentos de radiocirurgias com dose única (SRS) e fracionada (REF) têm diferentes tempo de tratamento para a técnica 3D e IMRT, entretanto, o tempo de tratamento das REFs são menores do que as de SRS, a diferença do tempo médio é de 23 minutos para a técnica 3D e 17 minutos para a técnica IMRT. Os tratamentos de TBI são os que mais requerem tempo de tratamento. Os tratamentos de VMAT e elétrons são os mais rápidos. Fazendo uma comparação entre as técnicas que possuem a habilidade de modular a fluência de dose nos tratamentos convencionais, os tratamentos VMAT são mais vantajosos se considerarmos o tempo médio dos tratamentos, 19,74 minutos para o VMAT contra 28,19 minutos para o IMRT. Apesar do plano de tratamento com a técnica

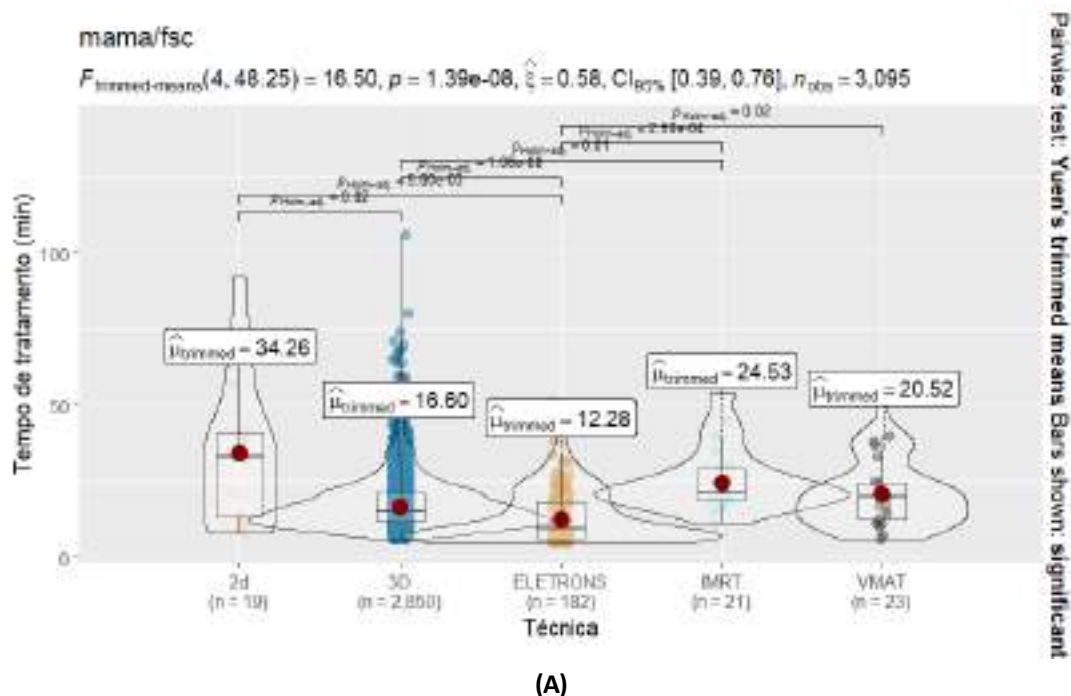
2d ser mais simples que os planos com a técnica 3D, o tempo médio dos tratamentos 3D é menor do que o tempo médio dos 2d. Uma razão para isso é a utilização de blocos de colimação para a maioria dos casos 2d, que obriga o técnico a entrar na sala para trocar a colimação a cada campo.

Em relação aos grupos de tratamento, o grupo relacionado com a radiocirurgia (META SRS) e TBI são os mais demorados. O grupo URO próstata possui o menor tempo de tratamento, 16,7 minutos. Entre os principais grupos de tratamentos convencionais, Figura 35C, só não podemos afirmar que o grupo de Torax e SN têm tempos de tratamentos diferentes e também o grupo de CP e mama/fsc. Os grupos relacionados a metástase possuem tempo de tratamento estatisticamente diferentes.

Também foi comparado o tempo de tratamento para os principais grupos de especialidades por técnica, conforme Figura 36.


Também foi comparado o tempo de tratamento para os principais grupos de especialidades por técnica, conforme Figura 36.

FIGURA 36 - COMPARAÇÃO DO TEMPO DE TRATAMENTO DOS PRINCIPAIS GRUPOS COM DIFERENTES TÉCNICAS DE TRATAMENTO. (A)- COMPARAÇÃO PARA OS CASOS DE CÂNCER DE MAMA, (B) - COMPARAÇÃO PARA OS CASOS DE CÂNCER DE PRÓSTATA, (C) – COMPARAÇÃO PARA OS CASOS DE CÂNCER DE CABEÇA E PESCOÇO, (D) - COMPARAÇÃO PARA OS CASOS DE CÂNCER DE SISTEMA NERVOSO CENTRAL, (E) - COMPARAÇÃO PARA OS CASOS DE CÂNCER DE METÁSTASE ÓSSEA E (F)- COMPARAÇÃO PARA OS CASOS DE CÂNCER DE METÁSTASE CEREBRAL.



URO prostata


$F_{\text{trimmed-means}}(3, 19.5) = 19.66, p = 4.09e-06, \hat{\xi} = 0.53, CI_{95\%} [0.24, 0.99], n_{\text{obs}} = 1,355$




(B)

CP


$F_{\text{trimmed-means}}(4, 73.16) = 5.16, p = 1.02e-03, \hat{\xi} = 0.46, CI_{95\%} [0.27, 0.66], n_{\text{obs}} = 1,091$



(C)




(D)



(E)

META SRS

$t_{\text{Yuen}}(147.37) = 1.92, p = 0.06, \hat{\delta}_R^{\text{AKP}} = -0.26, \text{CI}_{95\%} [-0.52, -1.37\text{e-}03], n_{\text{obs}} = 218$



(F)

Os casos de próstata e CP têm tempos de tratamentos significativamente diferentes entre as técnicas 3D e IMRT, Figura 36B e 36C. Nos casos de próstata não se pode considerar que o tempo de tratamento é diferente entre as técnicas IMRT e VMAT, já nos casos de CP essa consideração é válida. Nos casos de SN, Figura 36D, apenas a comparação do tempo de tratamento entre as técnicas 3D e IMRT não foi significativa, as outras comparações deram que os tempos são significativamente diferentes.

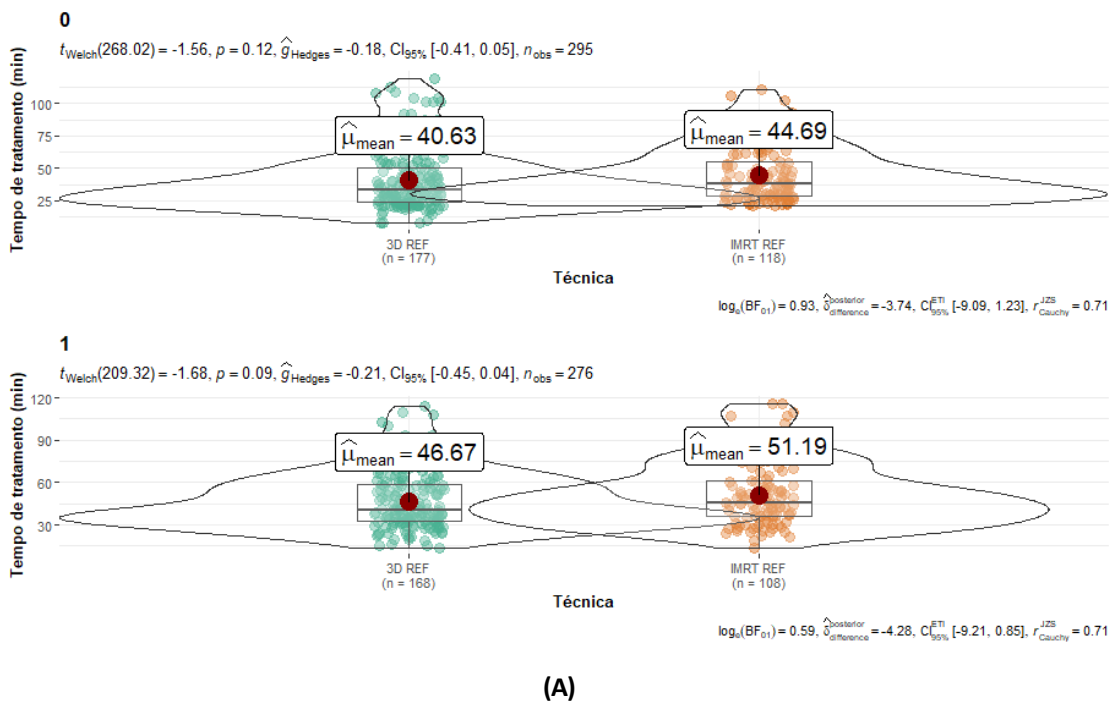
Nos casos de próstata, os tratamentos com a técnica 3D são os mais rápidos e para os casos de CP são os tratamentos de VMAT. A variação do tempo de tratamento dentro de uma técnica não tem grandes dispersão para mama, próstata e SN. Para os casos de CP, o tempo de tratamento com a técnica 2d tem grande dispersão.

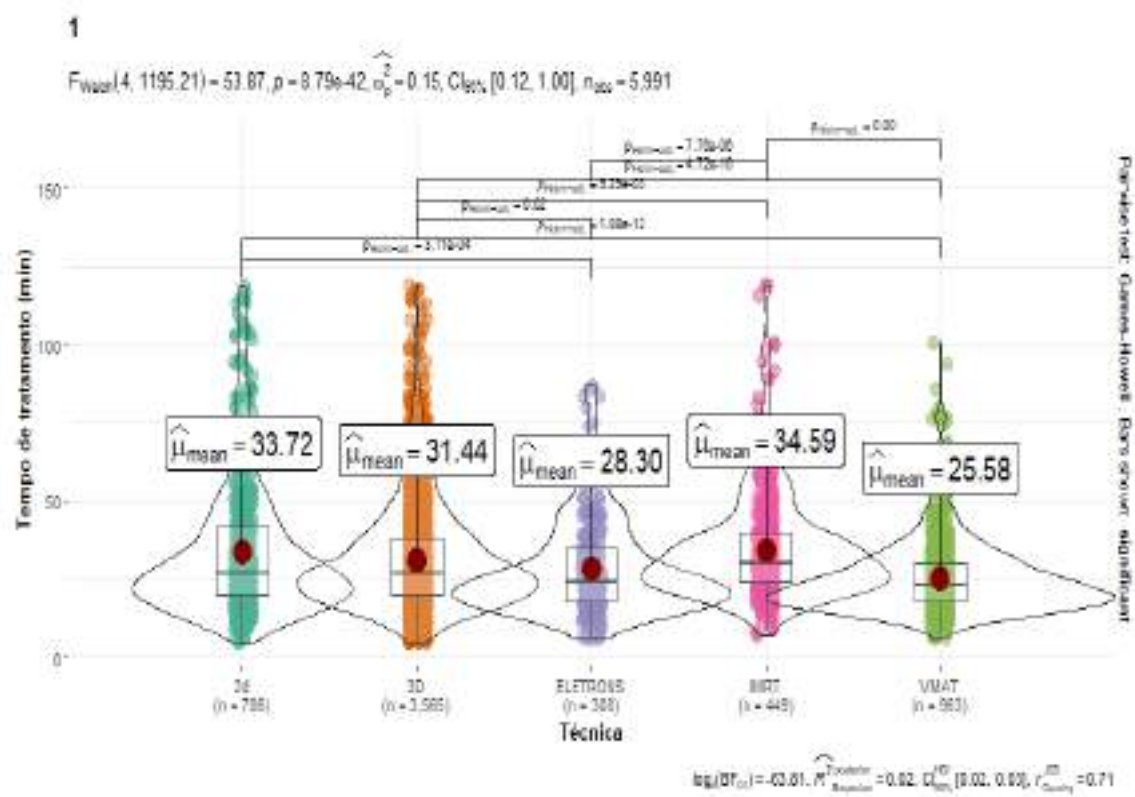

Nos casos de metástases tratadas com radiocirurgia, Figura 36F, não se pode afirmar que a técnica influencia no tempo de tratamento e nos casos de metástase óssea, Figura 36E, diferenças significativas foram encontradas entre as técnicas 2d e 3D, e também entre 3D e elétrons. Nas metástases ósseas, o tempo médio com a técnica 2d foi de 15,57 minutos e de 21,73 minutos com a técnica 3D. A técnica de IMRT possui maior dispersão entre os tempos de tratamentos e também possui o maior valor de tempo médio. No grupo de

metástases, os casos de IMRT óssea e os casos de metástases tratados com radiorirugia têm grande dispersão no tempo de tratamento.

Outra avaliação importante é o tempo no primeiro dia de tratamento, o técnico não conhece o paciente nem o plano de tratamento do caso, e o paciente não sabe como será o procedimento, fazendo com que o paciente fique mais tenso o que dificulta o procedimento de posicionamento. Além disso, um físico médico e um médico acompanham o tratamento nesse dia para avaliar se todos os parâmetros de tratamento estão de acordo com o planejado. Uma avaliação do tempo do primeiro dia de tratamento foi realizada e verificou-se o quanto esse tempo difere daquele dos dias seguintes, Figura 37.

FIGURA 37 - COMPARAÇÃO ENTRE O TEMPO DE TRATAMENTO DA PRIMEIRA SESSÃO E A MÉDIA DO TEMPO DAS OUTRAS SESSÕES. (A) COMPARAÇÃO PARA RADIOCIRURGIA FRACIONADA E (B) COMPARAÇÃO PARA AS MODALIDADES CONVENCIONAIS.





(B)

A variável nomeada como INICIO é binominal, recebendo o valor de um (1) se aquela sessão de tratamento é a primeira, e zero (0) se a sessão não é a primeira. Pela Figura 37, percebe-se que o tempo de tratamento do primeiro dia é consideravelmente maior do que das outras sessões de tratamento para todas as técnicas de tratamento convencionais. Os tratamentos com técnica IMRT e 2d têm os maiores valores de tempo de tratamento no primeiro dia, respectivamente, 34,59 minutos e 33,72 minutos. Apesar do tratamento 2d ser mais simples em questão de planejamento, a maioria dos casos utilizam bloco para conformação do campo, o que torna o trabalho manual, e conseqüentemente mais demorado, além da necessidade de ser realizada a verificação do formato do bloco, e também da verificação do posicionamento do isocentro de tratamento. Já no tratamento de IMRT, a entrega de dose é mais demorada, pois para cada *gantry* de tratamento existem diversas posições de lâminas.

Uma avaliação estatística entre as técnicas do tempo de tratamento no primeiro dia, tem como resultado que não podemos considerar que os casos 2d têm um tempo diferente dos casos 3D e IMRT. O VMAT apresenta diferença significativa comparado com as outras técnicas, sendo que a média do tempo de tratamento é a menor, 25 minutos. Já na análise das outras sessões de tratamento, os tempos de tratamento com a técnica 2d é significativamente diferente dos tempos das técnicas IMRT, VMAT e ELETRONS. Em todas as técnicas de tratamento, o tempo de tratamento diminui para as outras aplicações.

O tempo de tratamento não pode ser considerado diferente entre os casos tratados com técnica 3D e 2d. Em termo da média do tempo de tratamento, a técnica 2d teve maior diminuição. As técnicas que apresentam menores valores de tempo de tratamento, sem levar em consideração o primeiro dia, são as de ELETRONS e VMAT.

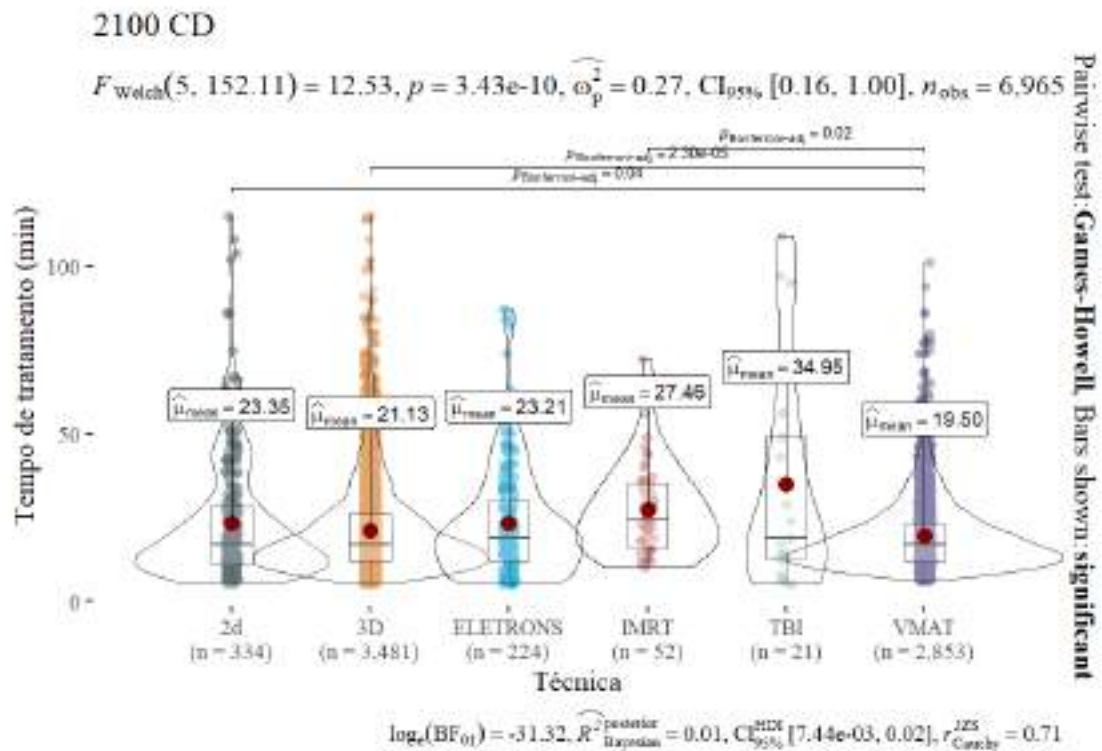
Nos casos de radiocirurgias, apenas as fracionadas têm mais do que um dia de tratamento e percebe-se que a diferença entre o tempo de tratamento do primeiro dia e das aplicações seguintes é menor do que nas técnicas convencionais. Uma razão para isso, é que nesse tratamento o posicionamento do isocentro é realizado através de um sistema de infravermelho que auxilia o técnico nesse procedimento. Outra observação é que o tempo de tratamento é

maior para essa modalidade de tratamento, já que a dose de prescrição é maior. Para os casos de radiocirurgia com a técnica 3D o tempo para o primeiro dia foi de 46,6 minutos e para técnica de IMRT de 51,19 minutos e para as outras sessões de 40,6 minutos e 44,6 minutos. Para essa modalidade de tratamento, as diferenças dos tempos de tratamento entre as técnicas não foram significativas.

Uma avaliação da diferença do tempo de tratamento na primeira aplicação, sem considerar a técnica, também foi realizada através do teste t pareado, e como resultado teve-se um p-value $< 2,2 \times 10^{-16}$, que significa que existe uma diferença entre o tempo de tratamento no primeiro dia e nas outras aplicações. Uma diferença média de 14 minutos.

A influência do equipamento no tempo de tratamento também foi estudada, já que os aceleradores lineares têm características diferentes. Os resultados encontram-se na Figura 38.


FIGURA 38 - TEMPO DE TRATAMENTO POR TÉCNICA E APARELHO. (A) APARELHO 2100CD, (B) APARELHO IX E (C) APARELHO 6EX.



(A)

iX


$$F_{\text{Weich}}(4, 186.43) = 4.84, p = 9.70\text{e-}04, \hat{\omega}_p^2 = 0.07, \text{CI}_{0.5\%} [0.01, 1.00], n_{\text{obs}} = 8,285$$



(B)

Clinac 6EX

$$F_{\text{Weich}}(3, 612.3) = 318.24, p = 1.77\text{e-}124, \hat{\omega}_p^2 = 0.61, \text{CI}_{0.5\%} [0.57, 1.00], n_{\text{obs}} = 2,053$$




(C)

O tempo de tratamento dos casos 2d no Clinac 6EX são mais demorados do que nos outros aparelhos já que esse equipamento não possui multifolhas para colimação e *Portal Vision* para realização de portais. A técnica 3D é a mais frequente em todos os equipamentos. No equipamento Clinac 6EX, apenas o tempo de tratamento da técnica 3D e IMRT não podem ser considerados diferentes. Os tratamentos de TBI dos equipamentos 2100 CD e o iX são referentes ao *boost* de dose de elétrons no testículo dos pacientes que trataram TBI. Do equipamento 2100, apenas o tempo de tratamento do VMAT é significativamente diferente das técnicas 2d, 3D e IMRT e no equipamento iX apenas os tempos de tratamento de elétrons e IMRT são significativamente diferentes.

Como a realização de portal mostrou-se impactante no tempo de tratamento, uma avaliação dessa variável com a técnica de tratamento é mostrada na Figura 39.



FIGURA 39 - AVALIAÇÃO DO IMPACTO DE PORTAIS NO TEMPO DE TRATAMENTO.



Nos dias em que se realiza o portal de verificação o tempo de tratamento é maior, sendo o tempo médio com portal (1) de 19,23 minutos e o tempo médio sem portal (0) de 13,7 minutos. Também se realizou uma avaliação do impacto dos portais para os diferentes aparelhos, já que o Clinac 6EX não possui um

dispositivo de imagem acoplado no equipamento, o processo é realizado manualmente, Figura 40.

FIGURA 40 - COMPARAÇÃO DO TEMPO DE TRATAMENTO COM A TÉCNICA 2D PARA OS DIFERENTES EQUIPAMENTOS. (A) DIAS SEM REALIZAÇÃO DE PORTAL DE VERIFICAÇÃO DE POSICIONAMENTO E (B) DIAS COM REALIZAÇÃO DE PORTAL DE VERIFICAÇÃO DE POSICIONAMENTO DESCONSIDERANDO O PRIMEIRO DIA DE TRATAMENTO.




Sem a realização de portais, os equipamentos têm um tempo de tratamento similar, porém quando se realizam portais de verificação, o equipamento Clinac 6EX tem um tempo de tratamento maior que os outros equipamentos, sendo o tempo médio nele de 31,3 minutos, de 23,34 minutos para o 2100CD e de 22,19 minutos para o iX. Isso demonstra que a falta de um dispositivo acoplado prejudica o tempo de tratamento.

Uma avaliação de não comparecimento do paciente na data do tratamento agendado foi realizada para avaliar o impacto de faltas no agendamento, Figura 41.

FIGURA 41 – AVALIAÇÃO DA DISTRIBUIÇÃO DE FALTAS NO PERÍODO AVALIADO.

$$\chi_{\text{gof}}^2(27) = 83579.62, p = 0.00, \hat{C}_{\text{Pearson}} = 0.97, \text{CI}_{95\%} [0.97, 1.00], n_{\text{obs}} = 5,942$$

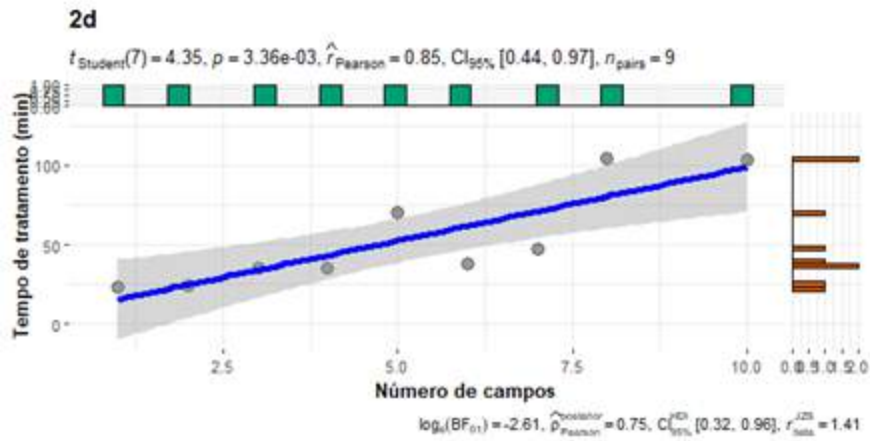


$$\log_e(\text{BF}_{01}) = -\text{Inf}, a_{\text{GuneI-Dickey}} = 1.00$$


Pela Figura 41, tem-se que 72% dos pacientes não faltaram em nenhuma sessão de tratamento e 13% faltaram em uma sessão do tratamento. Dentro desses dados de faltas também se encontram os pacientes que não compareceram em nenhuma sessão de tratamento ou por desistência ou por óbito.

Para entender a relação do número de campos e dose por fração prescrita com tempo de tratamento plotaram-se essas informações em gráfico e a distribuição dos pontos foi avaliada em relação a uma reta, Figura 42 e 43.


FIGURA 42- REGRESSÃO DO NÚMERO DE CAMPOS E TEMPO DE TRATAMENTO. (A) CASOS CONVENCIONAIS E TÉCNICA 2D, (B) CASOS CONVENCIONAIS E TÉCNICA 3D, (C) CASOS CONVENCIONAIS E TÉCNICA IMRT, (D) CASOS CONVENCIONAIS E TÉCNICA VMAT, (E) CASOS DE RADIOCIRURGIA E TÉCNICA 3D REF, (F) CASOS DE RADIOCIRURGIA E TÉCNICA 3D SRS, (G) CASOS DE RADIOCIRURGIA E TÉCNICA IMRT REF E (H) CASOS DE RADIOCIRURGIA E TÉCNICA IMRT SRS.




(A)




(B)




(C)




(D)




(E)



(F)




(G)




(H)

Para os casos 2d e 3D em tratamentos convencionais, o tempo de tratamento segue um crescimento linear com o número de campos. Já para os tratamentos modulados não existe essa relação. Para os tratamentos de radiocirurgia, apenas os fracionados com técnica 3D seguiram essa tendência.


FIGURA 43 - REGRESSÃO DA DOSE POR FRAÇÃO E TEMPO DE TRATAMENTO. (A) CASOS CONVENCIONAIS E TÉCNICA 2D. (B) CASOS CONVENCIONAIS E TÉCNICA 3D, (C) CASOS CONVENCIONAIS E TÉCNICA IMRT, (D) CASOS CONVENCIONAIS E TÉCNICA VMAT (E) CASOS DE RADIOCIRURGIA E TÉCNICA 3D REF, (F) CASOS DE RADIOCIRURGIA E TÉCNICA 3D SRS, (G) CASOS DE RADIOCIRURGIA E TÉCNICA IMRT REF E (H) CASOS DE RADIOCIRURGIA E TÉCNICA IMRT SRS.



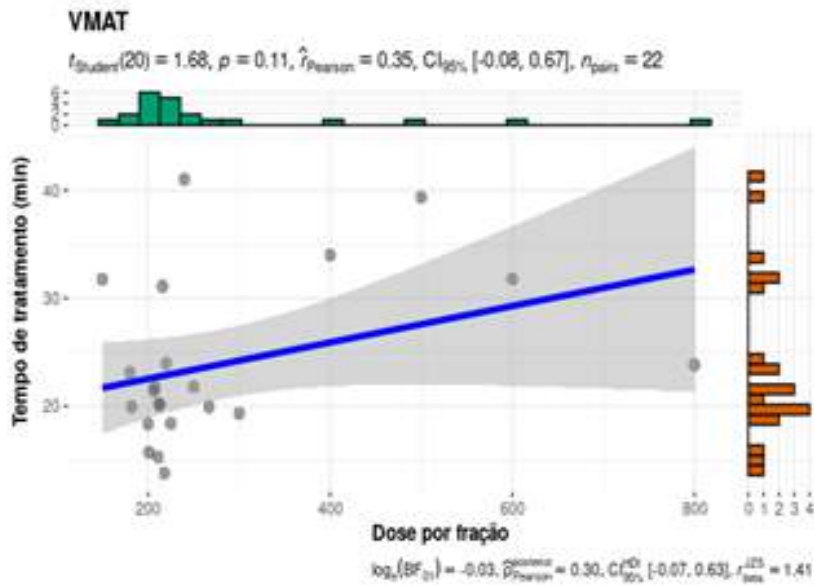
(A)




(B)




(C)




(D)




(E)



(F)



(G)



(H)

Para os casos 2d e 3D em tratamentos convencionais, o tempo de tratamento segue um crescimento linear com a dose por fração prescrita. Já para os tratamentos modulados não existe essa relação. Para os tratamentos de radiocirurgia, apenas os tratamentos com a técnica 3D seguiram essa tendência.

Também foi avaliado se pacientes que tratam a mesma região do corpo, têm benefício se colocados em seguida na agenda. Um teste t foi realizado e com $p\text{-value} = 1,897 \times 10^{-7}$ existe diferença no tempo de tratamento. Há um ganho médio de 1 minuto e 48 segundos.

5.4 Modelo de Previsão de Tempo de Espera

Para o modelo de previsão do tempo de espera, utilizou-se um cenário supervisionado, no qual o conjunto de dados dispunha de variáveis preditoras e variável resposta, um exemplo de variável preditoras utilizada foi a técnica de tratamento e a variável resposta era o tempo de espera das atividades pré tratamento

Como a variável resposta é quantitativa realizou-se um modelo de regressão. O ajuste dos modelos preditivos, foi representado pelas seguintes etapas: pré-processamento, divisão do conjunto de dados em treinamento e teste (para verificação da performance e generalização), aprendizado do modelo e avaliação do modelo. A divisão utilizada foi 80% de treinamento e 20% de validação.

Antes de fazer o modelo com os dados de treinamento, agruparam-se os valores de tempo de espera, dos dados de treinamento, para criar uma variável de referência para o tempo de espera e depois comparou-se essa variável com o tempo de espera predita pelo modelo e com o tempo de espera padrão usado atualmente. Essa variável pode ser uma opção de tempo de espera padrão para o departamento, já que as informações utilizadas são conhecidas na data de simulação. As variáveis utilizadas para formar essa variável foram grupo de tratamento, técnica de tratamento, número de isocentros, faixa etária e se o paciente é de convenio ou não. Essa variável possibilitou a diminuição do RMSE em comparação com o RMSE do tempo de espera padrão, de 6,1 dias para 4,6

dias, entretanto, o modelo de previsão buscou melhorar ainda mais esse tempo de referência.

Para o modelo foram utilizadas 11 variáveis preditoras: técnica de tratamento, tipo de tratamento, uso de anestesia, grupo de tratamento, paciente de convênio, número de isocentros, faixa etária, número de casos simulados na mesma semana da data da simulação, equipamento de tratamento, dia da semana da simulação e tempo médio de referência. O objetivo foi ajustar um modelo que relacionasse a variável resposta com as preditoras, a fim de prever esse evento em observações futuras.

Para cada modelo foi utilizada a técnica de otimização *Search grid* para definir os melhores parâmetros do modelo. Essa técnica constrói um modelo para cada combinação de hiperparâmetros especificados e avalia cada modelo. Os valores testados nessa otimização de hiperparâmetros para cada algoritmo são apresentados nas Tabelas 11,12,13,14 e 15:

TABELA 11 - HIPERPARÂMETROS TESTADOS NO MODELO DE REGRESSÃO COM RF E ALGUMAS CONSIDERAÇÕES SOBRE OS PARÂMETROS.

| Algoritmo | Hiperparâmetros | Espaço de Busca | Características |
|-----------|--------------------|--|---|
| RF | <i>ntrees</i> | [5;55;105;155;205;255;305;355;405;455] | Número de árvores usadas. |
| | <i>mtries</i> | [1;3;5;7;9;11;12;30] | Número de variáveis que serão aleatoriamente disponibilizados para a formação de cada novo nível em uma árvore. |
| | <i>sample_rate</i> | [0,3; 0,5; 0,70; 0,80] | Proporção de registros que cada árvore terá acesso para ser construída. |
| | <i>max_depth</i> | [5;10;15;20;25;30;35;40] | Comprimento máximo de cada árvore. |
| | <i>min_rows</i> | [1;2;3;4;5] | Quantidade mínima de registros em um ramo da árvore de decisão para que ocorra divisão em dois ramos. |
| | <i>nbins</i> | [5;10;15;20;25;30] | Especifica o número de <i>bins</i> a serem incluídos no histograma e, em seguida, dividir no melhor ponto. |

TABELA 12 - HIPERPARÂMETROS TESTADOS NO MODELO DE REGRESSÃO COM ÁRVORE DE DECISÃO E ALGUMAS CONSIDERAÇÕES SOBRE OS PARÂMETROS.

| Algoritmo | Hiperparâmetros | Espaço de Busca | Características |
|-------------------|-------------------------|-----------------|---|
| Árvore de Decisão | <i>max_depth</i> | [2; 4;6;8;10] | Número máximo de nós permitido da raiz até a folha mais distante de uma árvore. Árvores mais profundas podem modelar relacionamentos mais complexos, mas à medida que vamos avançando, as divisões se tornam menos relevantes, fazendo com que o modelo se ajuste demais, ou seja, <i>overfitting</i> . |
| | <i>min_sample_split</i> | [5;10;15] | O mínimo de registros necessários para que uma separação seja realizada. Um valor baixo, aumenta muito o risco de <i>overfitting</i> e divide as amostras, mesmo que não sejam uma população diferente. |
| | <i>min_sample_leaf</i> | [3;6;9] | O mínimo de registros necessários em cada nós-folha. Um valor baixo, aumenta o risco de <i>overfitting</i> . |

TABELA 13 - HIPERPARÂMETROS TESTADOS NO MODELO DE REGRESSÃO COM SVM E ALGUMAS CONSIDERAÇÕES SOBRE OS PARÂMETROS.

| Algoritmo | Hiperparâmetros | Espaço de Busca | Características |
|-----------|-----------------|--|---|
| SVM | <i>cost</i> | [0;0,1;0,2;0,3;0,4;0,5;0,6;0,7;0,8;0,9;1] | Responsável por controlar o quão tolerante a erros será o modelo. Alto valor de <i>Cost</i> faz com que o algoritmo treine o modelo almejando a separação completa entre classes, podendo causar <i>overfitting</i> e demandar muito tempo de treinamento por gerar fronteiras de decisão muito complexas. Por outro lado, baixos valores de <i>Cost</i> flexibilizam a etapa de treinamento e permitem fronteiras de decisão com erros, mas pode levar a um <i>underfitting</i> . |
| | <i>gamma</i> | [10^{-5} ; 10^{-4} ; 10^{-3} ; 10^{-2} ; 10^{-1} ; 10^1 ; 10^2 ; 10^3 ; 10^4 ; 10^5] | Influenciam na distância na qual as amostras serão consideradas para o cálculo da fronteira de decisão. São pesos que são introduzidos para a distância entre amostras, dando maior ou menor importância às amostras distantes ou próximas da fronteira de decisão. Aumentar o valor de <i>Gamma</i> faz com que os pontos mais distantes da região de separação entre classes sejam desconsiderados, levando a fronteiras de decisão mais restritas e complexas (<i>overfitting</i>). Por outro lado, valores menores de <i>Gamma</i> aumentam a influência dos pontos mais distantes e flexibilizam a região de separação, permitindo mais erros e podendo levar ao <i>underfitting</i> . |
| | <i>Kernel</i> | [linear;radial] | A função de <i>kernel</i> recebe dois vetores e os combina de alguma forma para produzir um único. |
| | <i>epsilon</i> | [10^{-5} ; 10^{-4} ; 10^{-3} ; 10^{-2} ; 10^{-1} ; 10^1 ; 10^2 ; 10^3 ; 10^4 ; 10^5] | Define a margem de tolerância onde nenhuma penalidade é dada para erros. Assim, quando esse erro for menor que um determinado " <i>epsilon</i> ", em termos absolutos, não haverá penalização. Por outro lado, para erros maiores que um determinado " <i>epsilon</i> ", é aplicada uma penalização linear. |

TABELA 14 - HIPERPARÂMETROS TESTADOS NO MODELO DE REGRESSÃO COM XGBOOST E ALGUMAS CONSIDERAÇÕES SOBRE OS PARÂMETROS.

| Algoritmo | Hiperparâmetros | Espaço de Busca | Características |
|-----------|------------------|------------------------------------|---|
| XGBOOST | subsample | [0,3;0,5;0,6] | Corresponde à fração de observações (as linhas) em cada etapa. Aleatoriza a amostra. Isso poderia evitar um overfitting e essa atividade de subsampling ocorrerá uma vez durante toda iteração. O valor 1 significa o uso de todas as linhas. |
| | colsample_bytree | [0,3;0,5; 0,6;0,7] | Corresponde à fração de recursos (as colunas) a serem usadas. O valor 1 significa o uso de todos os recursos. |
| | max_depth | [2; 4;6;8;10] | Número máximo de nós permitido da raiz até a folha mais distante de uma árvore. Árvores mais profundas podem modelar relacionamentos mais complexos, mas à medida que vamos aumentando, as divisões se tornam menos relevantes, fazendo com que o modelo se ajuste demais, ou seja, overfitting. |
| | min_child_weight | [0;1;5] | Peso mínimo (ou número de amostras, se todas as amostras tiverem um peso 1), necessário para criar um novo nó na árvore. Um menor min_child_weight permite que o algoritmo crie filhos que correspondam a menos amostras, permitindo árvores mais complexas, mas, novamente, mais propensas a superajustes, ou seja, overfitting. |
| | eta | [0,0001; 0,001; 0,01;0,05;0,1;0,2] | Controla a taxa de aprendizado do algoritmo a cada interação, ou seja, define a quantidade de correção que faremos em cada etapa. Assim, ter um valor baixo de eta torna nosso modelo mais robusto ao overfitting. Portanto, na maioria dos casos, quanto menor a taxa de aprendizado, melhor. No entanto, quanto menor for o eta, mais precisaremos de rodadas de reforço, o que acarretará num maior tempo para treinar nosso modelo. |
| | n_trees | [50;100] | Número de árvores usadas. |

TABELA 15 - HIPERPARÂMETROS TESTADOS NO MODELO DE REGRESSÃO COM RNA E ALGUMAS CONSIDERAÇÕES SOBRE OS PARÂMETROS.

| Algoritmo | Hiperparâmetros | Espaço de Busca | Características |
|---------------------|-----------------|--|--|
| RNA | hidden | {20};{20,20};{30,30,30};{5,5,5,5} | Especifica o número de camadas ocultas e o número de neurônios em cada camada oculta. |
| | activation | {Rectifier;Tanh;Maxout;RectifierWithDropout;TanhWithDropout;MaxoutW} | Função de Ativação. É a transformação que se faz ao longo do sinal de entrada. As funções com dropout são úteis para evitar o overfitting, pois selecionam um subconjunto da rede para realizar o treinamento. |
| | l1 | {0,0,01,0,001,0,0001} | Regularização L1 para adicionar estabilidade e melhorar a generalização. Apenas pesos fortes "sobrevivem". |
| | l2 | {0,0,01,0,001,0,0001} | Regularização L2 para adicionar estabilidade e melhorar a generalização. Evita que os pesos assumam valores muito grandes. |
| | epochs | {50;100;200} | Especifica o número de vezes para iterar (transmitir) o conjunto de dados. |
| | rate | {0,0,1;0,005;0,001} | Especifica a taxa de aprendizagem. Valores mais altos resultam em um modelo menos estável, enquanto valores mais baixos levam a uma convergência mais lenta. |
| | rate_annealing | { 10^{-5} ; 10^{-7} ; 10^{-9} } | Especifica o valor da taxa de recozimento. A taxa de recozimento é calculada como $rate / (1 + rate_annealing * amostras)$. |
| | rho | {0,0,95;0,99} | Especifica o fator de decaimento do tempo da taxa de aprendizagem adaptativa. |
| | epsilon | { 10^{-10} ; 10^{-8} ; 10^{-6} } | Especifica o fator de suavização do tempo da taxa de aprendizagem adaptativa para evitar a divisão por zero. |
| | momentum_start | {0;0,5} | Especifica o momento inicial no início do treinamento. O valor sugerido é 0,5. |
| | momentum_stable | {0,0,5;0,99} | Especifica o momento final após o término de tempo. O valor sugerido é 0,99. |
| input_dropout_ratio | {0;0,1;0,2} | Especifica a taxa de abandono da camada de entrada para melhorar a generalização. Os valores sugeridos são 0,1 ou 0,2. | |

A Tabela 16 apresenta os melhores conjuntos de parâmetros encontrados pela técnica de *Grid Search* para os modelos de predição do tempo de espera estudados e apresenta a métrica de avaliação do modelo final com os dados de teste, ou seja, dados que não foram utilizados no treinamento do modelo. A métrica de otimização utilizada foi o RMSE.

TABELA 16 - RESULTADOS DO MODELO DE PREDIÇÃO TEMPO DA ATIVIDADE PRÉ TRATAMENTO.

| Algoritmo | RF | SVM | XGBOST | RNA |
|---|---|--|--|--|
| Pacote | h2o.randomForest | e1071 | Xgboost | h2o.deeplearning |
| Hiperparâmetros (resultados para o melhor modelo) | ntrees = 400 mtries = 3 sample_rate = 0,3 max_depth = 10 min_rows = 3 nbins = 15 | epsilon = 0,5 gamma = 1e-05 cost = 1e+05 | subsample = 0,5 colsample_bytree = 0,6 max_depth = 8 min_child = 1 eta = 0,1 | max_w2 = 1000 input_dropout_ratio = 0 momentum_stable = 0 rate_annealing = 0 rate = 1 rho = 0,9 epsilon = 0 l1 = 0,0001 l2 = 0 epochs = 200 hidden = [20,20] activation = MaxoutWithDropout |
| Métrica avaliação da validação cruzada | RMSE | RMSE | RMSE | RMSE |
| Métrica avaliação(RMSE) dado Teste | 3,87 | 4,12 | 4 | 3,95 |

Para o desenvolvimento do modelo, os *outleirs* não foram usados para treinamento do modelo (tempo de espera > 30 dias).

O RMSE do modelo final para todos os algoritmos ficou próximo de 4 dias e em relação ao RMSE do tempo padrão utilizado atualmente na rotina clínica, os tempos de espera preditos proporcionaram uma melhora de 2 dias dessa métrica de avaliação. Para esses modelos, não foram utilizadas as variáveis referentes ao tempo gasto para o contorno do tumor e órgãos em risco do

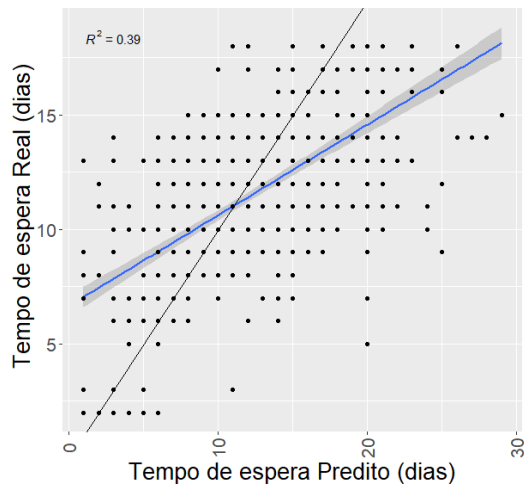
paciente e para planejamento e nem as informações de usuários que realizaram o contorno e planejamento. Essas informações não selecionadas para o modelo não são conhecidas na data de simulação. Porém se existisse um tempo de contorno e planejamento bem definido com poucas variações entre os pacientes, o RMSE do modelo diminuiria dois dias, ficando o RMSE em torno de 2 dias.

Utilizou-se na etapa de aprendizado o método de validação cruzada *k-fold* com *k* igual a cinco. Esse método consiste em dividir os dados em *k* subconjuntos, sendo que, para o treinamento do modelo são utilizados *k*-1 subconjuntos e o conjunto de dados que não foi utilizado para o treinamento faz a avaliação do modelo. Esse processo é repetido *k* vezes, com um subconjunto diferente reservado para avaliação (e excluído do treinamento) a cada vez.


Além do tempo de espera predito pelo modelo e o tempo de referência, foram criados dois tempos de espera provável (IC95% e IC68%) dados pela média e desvio padrão do tempo de espera. Esse tempo provável foi estimado pelo intervalo de confiança, na primeira opção tem-se uma confiabilidade de que 95,5% de que os pacientes não irão ter um tempo de espera real maior que esse tempo provável ($\mu + 1,96 \frac{\sigma}{\sqrt{n}}$, onde μ é a média dos tempos de espera agrupados, σ o desvio padrão e *n* o tamanho da amostra) e na segunda tem-se uma confiabilidade que 68% de que os pacientes não terão um tempo de espera real maior do que esse tempo provável ($\mu + 0,68 \frac{\sigma}{\sqrt{n}}$,) (APÊNDICE C). Por exemplo, os pacientes que tratam a região de mama com técnica 3D e sem serem do convênio têm um tempo provável IC68% de 14 dias e IC95% de 19 dias.

A Figura 44 apresenta os resultados da comparação entre o tempo de espera real e o predito para os diferentes algoritmos.


FIGURA 44 - RESULTADOS DOS MODELOS DE PREDIÇÃO. TEMPO DE ESPERA REAL VERSUS TEMPO DE ESPERA PREDITO EM DIAS. (A) RNA, (B) RF, (C) SVM E (D) XGBOOST. A RETA PRETO REPRESENTA O TEMPO DE ESPERA REAL IGUAL AO TEMPO DE ESPERA PREDITO E A RETA AZUL É O AJUSTE LINEAR DOS DADOS.




(A)



(B)




(C)




(D)


FIGURA 45 - COMPARAÇÃO DOS RESÍDUOS DOS MODELOS ESTUDADOS PARA PREDIÇÃO DO TEMPO DE ESPERA. (A) RNA, (B) RF, (C) SVM E (D) XGBOOST.




(A)



(B)



(C)




(D)

A Figura 44 mostra que o tempo predito segue a tendência do tempo real, porém existe dispersão dos dados em torno da reta que representaria uma previsão perfeita (tempo de espera igual ao tempo predito) e a dispersão é parecida para todas as faixas de tempo de espera. As variáveis com maior importância para o modelo foram o tempo de referência, casos, convênio, número de isocentros e realização de anestesia, técnica e o tipo de tratamento. A Figura 44 também mostra os R^2 dos modelos, para todos os modelos o valor encontrado foi baixo, sendo que o maior valor foi de 0,46 para o *RF* e o menor de 0,36 para o *XGBOOST*. A Figura 45 apresenta os histogramas de resíduos dos modelos, pelos gráficos percebe-se que os desvios próximos de zero são os mais frequentes e que entre os modelos, o algoritmo *RF* apresentou uma distribuição de resíduos mais próxima de uma normal.

Comparando os tempos previstos com os tempos padrões fornecidos para os pacientes, o modelo previu o tempo de espera mais próximo do real do que o tempo padrão, logo existe um impacto positivo para o paciente. A Figura 46 apresenta o resultado do modelo de previsão com a inclusão das variáveis tempo de planejamento e contorno.

FIGURA 46 - RESULTADO DO MODELOS DE PREDIÇÃO COM RF COM A INCLUSÃO DAS VARIÁVEIS TEMPO DE CONTO RNO E TEMPO DE PLANO.



A Figura 46 mostra a melhora do modelo de previsão se fosse considerado o tempo de realização do planejamento e o tempo de contorno, ou seja, se os tempos dessas atividades fossem bem definidos, o modelo de previsão teria um R^2 de 0,72 para o algoritmo *RF*. Esse resultado mostra a importância de definir um tempo apropriado para essas atividades.

Com o intuito de entender melhor a dificuldade do modelo em acertar o tempo de espera real do paciente, realizou-se uma pesquisa com os funcionários responsáveis pelas atividades pré-tratamento para entender quais outros fatores impactam nesse tempo de espera que não estão representados no modelo. Foram apontados alguns itens e os funcionários atribuíram uma pontuação de 1 a 4 para o quanto cada item impactava em atrasos, sendo que 1 representava sem impacto e 4 muito impacto.

Pelos resultados da pesquisa, o fator mais impactante para o atraso na execução do contorno do paciente e na aprovação do plano de tratamento é a falta de estação de trabalho, sendo que 71% dos entrevistados responderam que esse item impacta muito em atrasos no serviço. O segundo lugar foi a falta de profissionais médicos para o número de pacientes atendidos.

Como impacto intermediário em atrasos, tem-se o fato de que, como para a aprovação do plano de tratamento existe uma preferência do médico residente pelo médico assistente que contornou o caso, pode ocorrer uma incompatibilidade de horários o que ocasiona atrasos. Foi citado que quando um médico que não viu o contorno anteriormente vai aprovar um plano, existe uma probabilidade desse médico pedir alterações do contorno e isso também gera atrasos na aprovação.

Em relação a atrasos de contorno, foi citado que o residente tem preferência para mostrar o contorno para certos assistentes médicos e nem todos os assistentes aprovam o contorno de todos os grupos de tratamento.

Também como impacto intermediário para atrasos de aprovação do plano, a pesquisa mostra que 42% dos entrevistados acreditam que a falta de um guia para avaliar se o plano é o melhor possível, gera atrasos de aprovação.

Com impacto intermediário para atrasos de contorno tem-se que 42% dos entrevistados responderam que a falta de um contorno automático para

padronização dos contornos e a falta de um norte de contorno ideal gera atrasos nessa atividade.

No quesito de razões de atrasos de planejamento, o item falta de estação de trabalho ficou em primeiro lugar para 83% dos entrevistados. Para 67% dos entrevistados, não existir uma política eficiente de notas de preferências em relação ao planejamento e não chegar a ficha técnica para a equipe de física dos pacientes, cuja tomografia já foi contornada no sistema de planejamento, impacta muito em atrasos na atividade de planejamento, ou seja, existe uma falha de comunicação entre a equipe física e a médica quanto ao que se espera do planejamento e de quando foi finalizada a etapa de contorno das estruturas para que a fase do planejamento se inicie.

Ainda para atrasos em planejamento, como impactos intermediários tem-se a falta de padronização de contornos para a avaliação se o contorno está adequado para o planejamento e um prazo padrão curto para atividade em alguns tipos de técnicas.

Avaliando os resultados das pesquisas e a melhora do modelo que foi apresentado na Figura 46, seria útil para o departamento a aquisição de ferramentas de contorno automático e ferramentas para avaliar o planejamento, como por exemplo, uma ferramenta de aprendizado de máquina para predição de um histograma de dose mais provável¹³.

5.5 Modelo de Previsão de Tempo de Tratamento

O tempo de sessão de tratamento agendado para o paciente é definido pela equipe técnica no momento do agendamento e vai depender da região a ser tratada, sendo que é múltiplo de 12 min (12, 24, 36, 48...) porém, muitas vezes não corresponde ao tempo de tratamento real. Para esse modelo utilizaram-se 16 variáveis como preditoras (técnica, tipo de tratamento, faixa etária, se o paciente é anestesiado, grupo, equipamento de tratamento, uso de bloco de colimação, uso de filtro de colimação, número de isocentros, unidade monitora, número de campos, dose de tratamento por fração, realização de portal, se é convênio, tempo de referência e dose de tratamento total). A Tabela 17 apresenta os melhores conjuntos de parâmetros encontrados pela técnica de

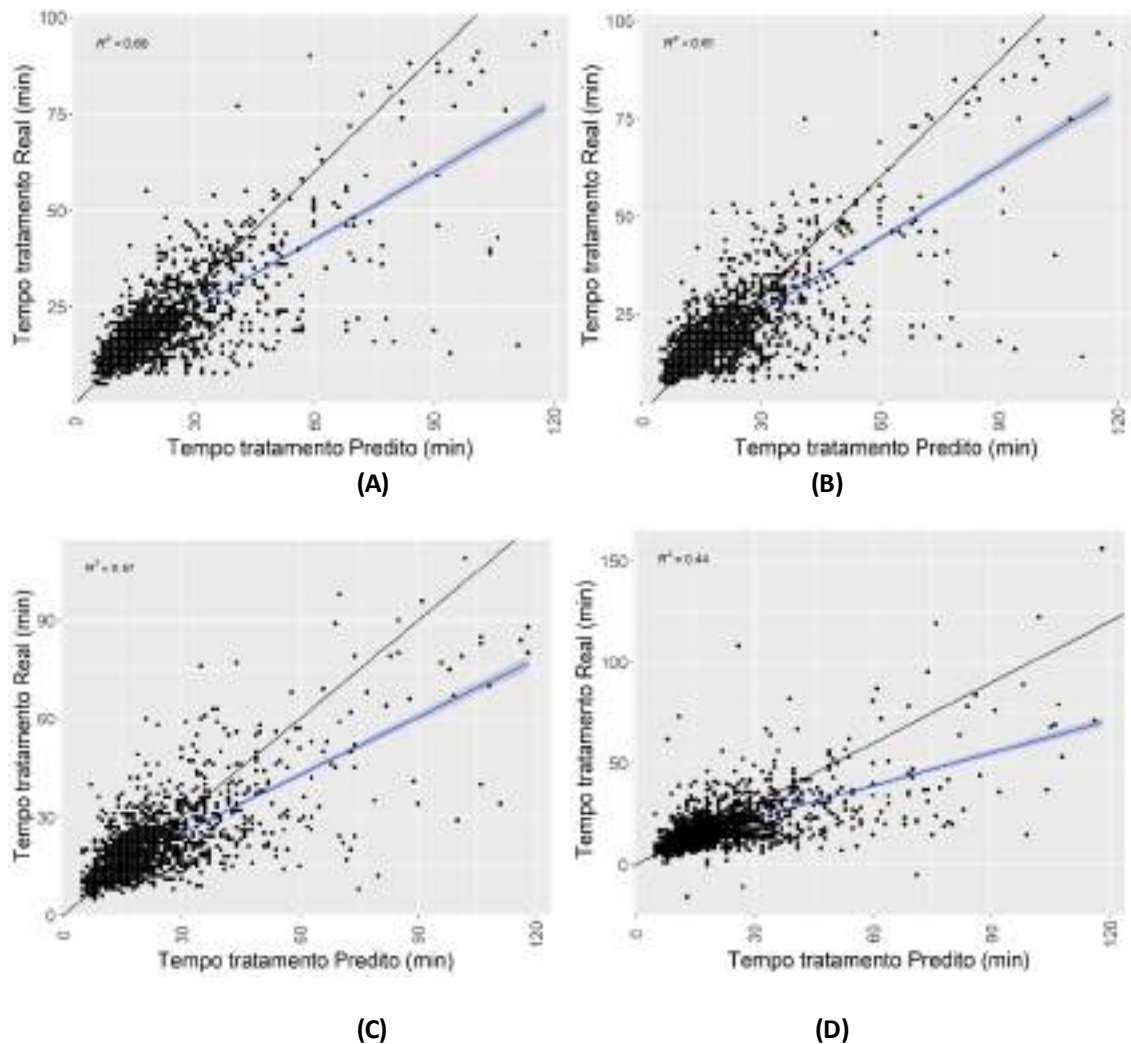
Grid Search para os modelos de predição do tempo de tratamento e apresenta o resultado das etapas de treinamento e avaliação dos modelos preditivos. Assim como para a previsão do tempo pré tratamento utilizou-se *Grid Search* e RMSE para seleção do modelo.

TABELA 17 - RESULTADOS DO MODELO DE PREDIÇÃO TEMPO DE TRATAMENTO.

| Algoritmo | RF | SVM | XGBOST | RNA |
|--|---|--|---|---|
| Pacote | h2o.randomForest | e1071 | Xgboost | h2o.deeplearning |
| Hiperparâmetros (resultados para o melhor modelo) | ntrees = 155 mtries = 9 sample_rate = 0,3 max_depth = 10 min_rows = 3 nbins = 20 | epsilon = 0,1 gamma = 1e-05 cost = 1e-05 | subsample = 0,5 colsample_bytree = 0,5 max_depth = 8 min_child = 1 eta = 0,2 ntrees = 100 | max_w2 = 100 input_dropout_ratio = 0,1 momentum_stable = 0,5 rate_annealing = 0 rate = 0 rho = 0,95 epsilon = 0 l1 = 0 l2 = 0 epochs = 205 hidden = [20] activation = Tanh |
| Métrica avaliação da validação cruzada | RMSE | RMSE | RMSE | RMSE |
| Métrica avaliação (RMSE) dado Teste | 8,5 | 10,29 | 9,09 | 8,6 |


Os RMSE do modelo de RF foi o menor encontrado, 8,5 minutos, mas todos modelos tiveram um ganho em relação ao RMSE do tempo padrão atual que é de 16 minutos. A Figura 47 apresenta as previsões do tempo de tratamento dos modelos comparadas com o tempo de tratamento real. Nesses modelos de previsão também se utilizou validação cruzada com k igual a 5 e a Figura 48 apresenta o histograma de resíduo dos modelos. Para análise do tempo de tratamento foram descartados os dados dos dias em que o paciente demorou mais que 3 vezes do seu tempo médio, ou seja, se tempo médio de de um paciente é de 10 min no dia em que as sessões de tratamento ultrapassaram 30 min, os dados foram descartados.

FIGURA 47 - RESULTADOS DOS MODELOS DE PREDIÇÃO. TEMPO DE TRATAMENTO REAL VERSUS TEMPO DE TRATAMENTO PREDITO EM MINUTOS. (A) RNA, (B) RF, (C) SVM E (D) XGBOOST.



A Figura 47 mostra que para todos os modelos, existem pontos distantes da reta (em preto) que simboliza a previsão perfeita. Foi realizada regressão (reta em azul) entre os tempos de tratamentos predito e real para verificar o R^2 , que quanto mais perto de 1 melhor o modelo. Entre os modelos estudados, o *RF* apresentou o R^2 mais próximo de 1, sendo que o valor encontrado foi de 0,61, um grande ganho em relação ao valor do R^2 da regressão do tempo padrão atual que é de 0,1.

FIGURA 48 - COMPARAÇÃO DOS RESÍDUOS DOS MODELOS ESTUDADOS PARA PREDIÇÃO DO TEMPO DE TRATAMENTO. (A) REDES NEURAIS, (B) RANDOM FOREST, (C) SVM E (D) XGBOOST.



Pela Figura 48, percebe-se que os desvios mais frequentes são próximos de zero e a distribuição dos resíduos do modelo de *random forest* aparenta uma distribuição normal, que é desejável para um modelo de previsão.

Comparado com o tempo de tratamento padrão, o tempo previsto apresentou um menor erro em relação ao tempo de tratamento real. Um tempo mais próximo do real auxilia para não ocorrer atrasos da agenda após o horário comercial.

5.6 Modelo de Previsão de Atrasos

Ao perceber que existem muitas vagas disponíveis diariamente e mesmo assim existem pacientes na lista de espera, foram avaliadas, com o pessoal responsável pelo agendamento, as razões de os pacientes não serem agendados. Logo percebeu-se que o medo de ocasionar atrasos na agenda e ultrapassar o horário comercial deixam bastante horários disponíveis na agenda. Foi realizado um teste de correlação com método *Spearman* para começar a entender as relações de atrasos na agenda, porém não foi encontrada correlação forte entre atraso e as variáveis número de inícios e ocupação do equipamento.

Foi desenvolvido um modelo de classificação para prever esses atrasos. Utilizaram-se como variáveis preditoras fatores como ocupação da agenda, número de inícios de tratamento do dia, número de casos por grupo de tratamento e a soma das unidades monitoras. Por haver uma baixa incidência de dias com atrasos, utilizaram-se métodos de balanceamento de dados. As Tabelas 18,19 e 20 apresentam o resultado das etapas de treinamento e de avaliação dos modelos preditivos.

TABELA 18 - RESULTADOS DO MODELO DE PREVISÃO DE ATRASOS NA AGENDA DIÁRIA COM O PACOTE MLR SEM TÉCNICAS DE BALANCEAMENTO. ACC=ACURÁCIA, S=SENSIBILIDADE, E=ESPECIFICIDADE, VPP=VALOR PREDITO POSITIVO E VPNN= VALOR PREDITO NEGATIVO.

| Algoritmo | RF | SVM | XGBOOST | Regressão Logística | Árvore de decisão |
|---|---|---|---|---|--|
| Pacote | mlr | MLr | mlr | mlr | MLr |
| Parâmetros testados | <i>n</i> tree= [50:500] <i>m</i> try= [2:30] | <i>Cost</i> = 2 ⁻⁸ ,2 ⁻⁴ ,2 ⁻² , 10 ⁻⁸ ,10 ⁻² , 10 ² e 0 <i>Gamma</i> = 2 ⁻⁸ ,2 ⁻⁴ ,2 ⁻² , 10 ⁻⁸ ,10 ⁻² , 10 ² e 0 | <i>max_depth</i> = [3:20] <i>eta</i> = [0,001:0,5] <i>subsample</i> = [0,1:0,8] <i>min_child_weight</i> = [1:5] <i>colsample_bytree</i> = [0,2:0,8] | | <i>Min_sample_split</i> = [10:50] <i>Min_sample_leaf</i> = [5,50] <i>cp</i> = [0.01:0.2] |
| Hiperparâmetros (resultados para o melhor modelo) | <i>n</i> tree= 411 <i>m</i> try= 6 | <i>Cost</i> = 0,25 <i>Gamma</i> = 0,25 | <i>max_depth</i> = 11 <i>eta</i> = 0,03 <i>subsample</i> = 0,29 <i>min_child_weight</i> = 2,18 <i>colsample_bytree</i> = 0,53 | - | <i>Min_sample_split</i> = 37 <i>Min_sample_leaf</i> = 5 <i>cp</i> = 0,01 |
| Métrica avaliação da validação cruzada | ACC | ACC | ACC | ACC | ACC |
| Métrica avaliação dos dado Teste | ACC= 0,92 VPP= 0,98 VPN= 0,22 S= 0,94 E= 0,45 | ACC= 0,91 VPP= 0,99 VPN= 0 S= 0,91 E= 0 | ACC= 0,92 VPP= 0,98 VPN= 0,21 S= 0,93 E= 0,44 | P= 0,91 VPP= 0,98 VPN= 0,22 S= 0,93 E= 0,57 | P= 0,91 VPP= 0,99 VPN= 0,05 S= 0,92 E= 0,25 |

TABELA 19 - RESULTADOS DO MODELO DE PREVISÃO DE ATRASOS NA AGENDA DIÁRIA COM O PACOTE CARET SEM TÉCNICAS DE BALANCEAMENTO. ACC=ACURÁCIA, S=SENSIBILIDADE, E=ESPECIFICIDADE, VPP=VALOR PREDITO POSITIVO E VPNN= VALOR PREDITO NEGATIVO.

| Algoritmo | RF | SVM | XGBOOST | Regressão Logística | Árvore de decisão |
|---|---|--|--|--|---|
| Pacote | caret | caret | caret | caret | Caret |
| Parâmetros testados | <i>m</i> try= [2:30] | <i>Cost</i> = 2 ⁻⁸ ,2 ⁻⁴ , 2 ⁻² , 2 ² , 2, 10 ⁻² , 10 ² e 0 <i>Gamma</i> = 2 ⁻⁸ ,2 ⁻⁴ ,2 ⁻² , 2 ² , 2, 10 ⁻² , 10 ² e 0 | <i>max_depth</i> = [2:10] <i>eta</i> = [0,01:0,5] <i>subsample</i> = [0,1:1] <i>min_child_weight</i> = [1:5] <i>colsample_bytree</i> = [0,2:1] | | <i>Min_sample_split</i> = [10,20,30,40] <i>Min_sample_leaf</i> = [5,10,20] <i>cp</i> = [0.01:0.2] |
| Hiperparâmetros (resultados para o melhor modelo) | <i>m</i> try= 7 | <i>Cost</i> = 4 <i>Gamma</i> = 0,01 | <i>max_depth</i> = 2 <i>eta</i> = 0,025 <i>subsample</i> = 1 <i>min_child_weight</i> = 1 <i>colsample_bytree</i> = 1 | - | <i>Min_sample_split</i> = 30 <i>Min_sample_leaf</i> = 5 <i>cp</i> = 0,01 |
| Métrica avaliação da validação cruzada | ACC | ACC | ACC | ACC | ACC |
| Métrica avaliação dos dado Teste | ACC= 0,91 VPP= 0,98 VPN= 0,25 S= 0,92 E= 0,63 | ACC= 0,90 VPP= 0,98 VPN= 0,18 S= 0,92 E= 0,5 | ACC= 0,92 VPP= 0,99 VPN= 0,14 S= 0,92 E= 0,7 | P= 0,91 VPP= 0,99 VPN= 0,1 S= 0,92 E= 0,43 | P= 0,91 VPP= 0,99 VPN= 0,14 S= 0,92 E= 0,5 |

A Tabela 18, apresenta os parâmetros dos modelos testados e os melhores parâmetros encontrados para o pacote *mlr* e Tabela 19 apresenta os mesmos dados para o pacote *caret*. No modelo de árvore de decisão, ao invés do parâmetro *max_depth* foi utilizado o parâmetro *cp* que representa também um parâmetro de complexidade da árvore, sendo $cp = 0$ para o caso mais complexo, e $cp = 1$ para o caso menos complexo.

A análise individual da métrica acurácia (ACC) dos modelos propostos pode levar a uma escolha enganosa do melhor modelo. Como a variável atraso é desbalanceada, o modelo tende a prever quase tudo como a classe de maior proporção, no caso a variável resposta “não”. Isso leva a ter um baixo índice de especificidade e VPN, ou seja, uma baixa taxa de acerto do modelo em relação aos verdadeiros negativos.

Avaliando as métricas de avaliação da Tabela 18 e da Tabela 19, os melhores modelos são com o algoritmo de RF para o pacote *caret* e com o algoritmo de regressão logística para o pacote *mlr*, já que esses modelos possuem VPP e VPN maiores do que os outros modelos. Para o pacote *mlr*, o modelo de árvore de decisão e SVM apresentaram um VPN baixo. Já em relação ao XGBOOST e RF, a especificidade da regressão logística é ligeiramente maior. Para o pacote *caret*, o VPN do modelo de RF é superior aos outros modelos.

Para tentar contornar esse problema de desbalanceamento, foram realizados modelos com re-amostragem mudança de limiar e com diferentes funções custos. Essa técnica de balanceamento foi realizada nos dois melhores modelos, Tabelas 20 e 21.

TABELA 20 - RESULTADOS DO MODELO DE PREVISÃO DE ATRASOS NA AGENDA DIÁRIA COMO ALGORITMO RANDOM FOREST, PACOTE CARET E COM TÉCNICA DE BALANCIAMENTO. ACC=ACURÁCIA, S=SENSIBILIDADE, E=ESPECIFICIDADE, VP=VALOR PREDITO POSITIVO E VPN=VALOR PREDITO NEGATIVO.

| Algoritmo | RF | RF | RF | RF | RF | RF |
|---|--|---|--|---|---|--|
| Pacote | caret | caret | caret | caret | caret | caret |
| Técnica de Balanciamento | | Reamostragem <i>Undersampling</i> | Reamostragem <i>Oversampling</i> | Ajuste de Custo (2x40) | Limiar (0,8) | Smote |
| Parâmetros testados | mtry=[1:39] | mtry=[1:39] | mtry=[1:39] | mtry=[1:39] | mtry=[1:39] | mtry=[1:39] |
| Hiperparâmetros (resultados para o melhor modelo) | mtry = 4 | mtry = 2 | mtry = 5 | mtry = 2 | mtry = 4 | mtry = 3 |
| Métrica avaliação da validação cruzada | ACC | ACC | ACC | ACC | ACC | ACC |
| Métrica avaliação dos dado Teste | ACC = 0,96 VPP= 0,99 VPN= 0,6 S= 0,96 E= 0,9 | ACC = 0,7 VPP= 0,7 VPN = 0,64 S= 0,95 E= 0,18 | ACC = 0,89 VPP= 0,95 VPN=0,21 S= 0,92 E= 0,3 | ACC = 0,91 VPP= 0,98 VPN= 0,17 S= 0,92 E= 0,5 | ACC = 0,95 VPP= 0,91 VPN= 0,75 S= 0,97 E= 0,7 | ACC= 0,89 VPP= 0,96 VPN= 0,29 S= 0,93 E= 0,4 |

TABELA 21 - RESULTADOS DO MODELO DE PREVISÃO DE ATRASOS NA AGENDA DIÁRIA COM O ALGORITMO REGRESSÃO LOGÍSTICA, PACOTE MLR E COM TÉCNICAS DE BALANCEAMENTO. ACC=ACURÁCIA, S=SENSIBILIDADE, E=ESPECIFICIDADE, VVP=VALOR PREDITO POSITIVO E VPN= VALOR PREDITO NEGATIVO.

| Algoritmo | Regressão Logística | Regressão Logística | Regressão Logística | Regressão Logística | Regressão Logística |
|--|--|---|--|--|--|
| Pacote | mlr | mlr | mlr | mlr | mlr |
| Técnica de Balanciamento | Reamostragem <i>Undersampling</i> | Reamostragem <i>Oversampling</i> | Ajuste de Custo (2x40) | Limiar (0.8) | Smote |
| Métrica avaliação da validação cruzada | ACC | ACC | ACC | ACC | ACC |
| Métrica avaliação dos dado Teste | ACC= 0,89 VPP= 0,995 VPN= 0,15 S= 0,9 E= 0,8 | ACC= 0,89 VPP= 0,96 VPN= 0,31 S= 0,91 E= 0,53 | ACC= 0,87 VPP= 0,88 VPN= 0,57 S= 0,98 E=0,13 | P= 0,86 VPP= 0,9 VPN= 0,42 S= 0,94 E= 0,29 | P= 0,89 VPP= 0,98 VPN= 0,05 S= 0,91 E= 0,2 |

Para construção do modelo de classificação, utilizaram-se os pacotes *caret* e *mlr*, pois eles possibilitam a utilização de muitos algoritmos a partir de uma mesma função, apenas alterando seus parâmetros. Por causa da facilidade de definição das funções, o pacote *caret* é mais fácil para manipular os parâmetros do modelo. O pacote *mlr* permite que mais que um parâmetro do modelo seja otimizado como hiperparâmetro para o algoritmo de AD e RF já o

pacote caret permite apenas um parâmetro. Para os modelos, utilizou-se validação cruzada com 5 *folds*.

A Tabela 20 apresenta os valores testados como hiperparâmetros para o modelo de *RF* e o melhores valores encontrados. As variáveis preditoras foram normalizadas para ter média de 0 e desvio padrão de 1.

Com o re-balanceamento, a taxa de acurácia caiu, porém houve um aumento da taxa de VPN para a mudança de limiar e para a reamostragem-Undersampling, ou seja, o nosso modelo generaliza melhor para a classe dos verdadeiros negativos. Nos modelos de ajuste de peso, foi dada uma recompensa de acerto com valor de 40 para a classe resposta de atraso “SIM” e com valor de 2 para a classe resposta “NÃO”. Foram realizados outros testes de valores, como 2 para 50, 2 para 30, 2 para 10 e 2 para 5, porém aquela foi a melhor combinação encontrada. No modelo de mudança de limiar, a resposta era dada em porcentagem em vez do label SIM e NÃO, portanto em vez de definir uma porcentagem de 50% como limiar de separação entre as classes, foi definida uma porcentagem diferente. Para o modelo de regressão se a porcentagem encontrada fosse menor que 80% o modelo classificaria como “SIM”.

O modelo com mudança do limiar apresentou melhor resultado tanto para os modelos de *RF* quanto para o modelo de regressão logística, Tabelas 20 e 21. O melhor modelo de previsão de atraso foi o de *RF* com ajuste de peso de 0,8, ou seja, se a porcentagem encontrada fosse menor que 80% o modelo classificaria como “SIM” e se maior que esse valor classificaria como “NÃO”.

O valor da acurácia encontrado para esse modelo foi de 0,95, a sensibilidade de 0,97 e especificidade de 0,7. Nesse modelo, quando a variável atraso tinha a resposta real como “SIM”, o modelo classificou corretamente em 75% dos dias e quando a variável atraso tinha a resposta real como “NÃO”, o modelo classificou corretamente em 91% dos dias. Portanto, o modelo ajuda a fornecer a informação sobre se o aparelho vai ultrapassar o horário de expediente. Como o modelo não conseguiu uma especificidade tão boa quanto a sensibilidade, um tempo de tratamento bem definido é essencial para não ocorrerem esses atrasos de expedientes.

5.7 Agendamento

Nessa seção serão apresentados os dados referentes ao modelo de agendamento proposto. É fundamental, para realizar um agendamento automático e eficiente, que exista uma lista de prioridade de pacientes para auxiliar o desenvolvimento do modelo. Portanto, a primeira parte do problema de agendamento é definir uma lista de prioridade.

5.7.1 Priorização

Um formulário tipo Google com uma lista de diferentes regiões de tratamentos foi enviado para os médicos para que definissem uma pontuação de prioridade para as regiões. Foram obtidas 15 respostas e um exemplo do formulário encontra-se na Figura 49.

FIGURA 49 - FORMULÁRIO PARA DEFINIÇÃO DOS GRUPOS E PARA DEFINIÇÃO DAS PRIORIDADE DOS GRUPOS.

The image shows a Google Form titled "Prioridade". The form's purpose is to help decide the priority of starting treatment for different regions based on an algorithm, especially in situations with few visits and many patients. It asks the user to select a priority level for each region, considering factors like tumor size and growth. The form is currently showing the "Faringe" region with five radio button options: "Urgente", "Alta Prioridade", "Intermediária Prioridade", "Baixa Prioridade", and "Outros".

Com as respostas do questionário, foi possível definir tanto a prioridade de tratamento de cada região quanto agrupar algumas regiões em grupos específicos. A maior prioridade ficou com os casos paliativos (hemostático e anti-álgico) e a menor prioridade ficou para casos de fígado, adenoma de baixo grau, próstata, timona, glioma de baixo grau, adenomas de hipófise e malformação arteriovenosa (APÊNDICE D).

5.7.2 Formulação do Modelo

Primeiramente foi definida uma lista de espera de pacientes aptos para serem agendados, ou seja, pacientes para os quais as atividades pré-tratamento foram finalizadas até a data do agendamento. Foi definida uma lista de espera por equipamento. Cada equipamento foi dividido em *slot* de 1 min e quando *slot* consecutivos estavam vagos, juntaram-se os *slots* para formar um bloco de tempo.

Para cada paciente dessa lista foi associada uma pontuação de priorização. Essa pontuação foi calculada baseada na prioridade de tratamento dada pelo prognóstico, no tempo de espera do paciente e no desvio da data prevista.

Para definição de pontuação referente ao desvio da data prevista, normalizaram-se os dias de atrasos da data prevista de cada paciente pelo valor máximo de atraso naquele equipamento. Para a pontuação de tempo de espera, normalizou-se o tempo de espera de cada paciente pela média do tempo de espera dos pacientes com mesma prioridade. Uma pontuação geral foi calculada somando a pontuação de prioridade de tratamento, pontuação do tempo de espera e a pontuação de atrasos com peso 2.

Para o agendamento foi desenvolvido um modelo de programação linear inteira mista com objetivo de maximizar o número de pacientes agendados levando em conta a sua pontuação de prioridade e algumas restrições de agendamento, sendo elas:

- não se pode agendar dois pacientes em um mesmo horário;
- cada paciente é agendado em apenas uma máquina e com apenas um *slot* de tempo do equipamento;
- devem ser agendadas todas as sessões de tratamento do paciente;
- a capacidade do aparelho não deve ser ultrapassada;
- deve-se reservar um *slot* compatível com o requerido pelo paciente e;
- para evitar atrasos, existe uma limitação de número de pacientes que inicia o tratamento em um determinado dia. Isso porque, na sessão inicial não é agendado um horário adicional por ser primeira sessão de tratamento e foi

constatado que existe diferença de tempo nessa aplicação em relação às demais sessões.

A ideia foi introduzir duas variáveis binárias x_{ij} e y_{ij} que são 1 se o paciente i é agendado para o *slot* " j " do equipamento. A diferença entre as variáveis x e y é que a lista de pacientes que fazem parte da variável x , já tiveram suas atividades pré-tratamento finalizadas, então podem ser agendados no equipamento no dia em que o agendamento está sendo proposto e os pacientes que fazem parte da lista y estão na última etapa de atividade pré-tratamento, então foi assumido que provavelmente estarão disponíveis para o agendamento um dia depois do dia em que o agendamento está sendo proposto. Também existem duas matrizes de recompensa $R1_{ij}$ e $R2_{ij}$ associadas a esse agendamento, sendo $R1$ referente ao agendamento atual e $R2$ uma previsão de agendamento para o próximo dia. Essa pontuação é baseada na pontuação de prioridade do paciente. Se o paciente " i " é agendado em um *slot* " j " e esse *slot* " j " que já tem algum paciente previamente agendado, as matrizes $R1_{ij}$ e $R2_{ij}$ retornam um valor de -1.000 e se o *slot* está livre retornam o valor da pontuação de prioridade referente ao paciente i . A matriz $R2$ foi utilizada nessa otimização para que o modelo tenha possibilidade de enxergar um dia após a data de agendamento e avaliar se surgiram, na lista de espera, pacientes com alta prioridade que compense reservar uma vaga para ele no próximo dia. Uma punição de -1 na recompensa é dada para os pacientes da lista x , se eles forem programados para serem agendados no próximo dia em vez da data atual.

O agendamento foi programado para ser realizado no final do dia, pois a cada dia é necessário verificar as faltas dos pacientes em tratamento para verificar as disponibilidades reais de vagas. Então no final do dia " D ", os pacientes são agendados para o dia " $D+1$ ". Após a otimização são definidos os pacientes que serão agendados.

Uma vez agendado o paciente ele fica na agenda do equipamento até terminar suas sessões prescritas de tratamento. Porém os pacientes que ficaram na lista de agendamentos programados ainda não são colocados na agenda, já que para os casos ainda não finalizados é necessário ter a confirmação da finalização da tarefa no próximo dia e para os casos finalizados é preciso confirmar se não surgiram pacientes prontos com maior prioridade do que deles.

No próximo dia de agendamento o processo se repete, os pacientes que tiveram as suas atividades pré-tratamento finalizadas, são assimilados na lista de pacientes da variável x e os quase prontos na lista y. Aqueles pacientes que estavam programados para agendamento no dia D+2 são distribuídos novamente para a lista de pacientes das variáveis x e y, os pacientes que não ficaram prontos ficam novamente na lista y e os prontos vão para lista x. Um detalhe é que os pacientes que já ficaram na lista de pacientes programados para o agendamento, quando mudam da lista de pacientes da variável y para x, ganham 0,5 ponto de recompensa. Para definição do modelo matemático de otimização desse processo foram definidas uma função objetivo e restrições.

A função objetivo tem como finalidade achar a combinação de novos pacientes agendados no equipamento no dia “D”, e colocados na lista de pacientes programados para início no dia “D+1”, que maximize o retorno de pontuação de prioridade. A fórmula matemática para isso é dada por:

$$\text{MAX } \sum_{i=1}^n \sum_{j=1}^m R1_{i,j} x_{i,j} + R2_{i,j} y_{i,j} \quad \text{EQUAÇÃO 11}$$

Como restrições temos:

É proibido agendar o paciente “i” no slot “j” referente ao dia atual e colocá-lo na lista de pacientes programados para o próximo dia.

$$\sum_{i=1}^{n1+n2} \sum_{j=1}^{m1+m2} x_{i,j} + y_{i,j} \leq 1 \quad \text{EQUAÇÃO 12}$$

O paciente assume na agenda apenas uma vaga.

$$\sum_{i=1}^{n1} x_{i,j} \leq 1 \quad J = 1, \dots, M1 \quad \text{EQUAÇÃO 13}$$

O paciente assume na lista de programados para serem agendados apenas uma vaga.

$$\sum_{i=1}^{n2} y_{i,j} \leq 1 \quad J = 1, \dots, M2 \quad \text{EQUAÇÃO 14}$$

O tempo de tratamento varia de paciente para paciente, logo cada paciente vai requerer um tamanho de *slot* específico na agenda e para ocorrer o agendamento esse deve ser compatível com o solicitado.

$$\sum_{j=1}^{m1} x_{i,j} \text{TempoSessao}[j,1] \leq \text{Capacidade1}[i] \quad i = 1, \dots, N1 \quad \text{EQUAÇÃO 15}$$

Na reserva de vaga para o próximo dia essa restrição de tamanho de *slot* específico também deve ser mantida.

$$\sum_{j=1}^{m2} y_{i,j} \text{TempoSessao}[j,1] \leq \text{Capacidade2}[i] \quad i = 1, \dots, N2 \quad \text{EQUAÇÃO 16}$$

Todas as sessões de tratamento do paciente devem ser agendadas, ou seja, se o paciente tiver 25 sessões serão reservados 25 dias consecutivos de *slots* no equipamento. A mesma política serve para o agendamento programado.

$$\sum_{j=1}^{m1} x_{i,j} \text{Sessoes}[j] \leq \text{SessoesDisponiveis1}[i] \quad i = 1, \dots, N1 \quad \text{EQUAÇÃO 17}$$

$$\sum_{j=1}^{m2} y_{i,j} \text{Sessoes}[j] \leq \text{SessoesDisponiveis2}[i] \quad i = 1, \dots, N2 \quad \text{EQUAÇÃO 18}$$

Existe um número máximo de novos pacientes agendados por dia para evitar a extensão do horário após o horário comercial. Lembrando que no primeiro dia do tratamento, o tempo gasto dentro da sala é maior do que os outros dias e não é reservado um tempo maior na agenda para esse dia. Logo, limitando o número de inícios e levando em consideração o tempo adicional de forma que haja *slots* livres no dia afim compensar esse tempo adicional pode-se evitar atrasos de expediente.

$$(\sum_{j=1}^{m1} \sum_{i=1}^{n1} x_{i,j}) * 14 + \sum_{i=1}^{n1} \sum_{j=1}^{m1} x_{i,j} \text{TempoSessao}[j,1] + \leq \text{vagas} \quad \text{EQUAÇÃO 19}$$

Nos agendamentos programados também existe essa limitação de número máximo de pacientes programados para serem agendados.


$$(\sum_{j=1}^{m2} \sum_{i=1}^{n2} y_{i,j}) * 14 + \sum_{i=1}^{n2} \sum_{j=1}^{m2} y_{i,j} \text{TempoSessao}[j,1] + \leq \text{vagas} \quad \text{EQUAÇÃO 20}$$

Foi utilizado o *solver* glpk com o pacote de programação linear ompr para resolução da otimização no *software* r. Nosso trabalho foi conduzido em um computador *desktop* com processador Intel Core i7 e 8GB de memória RAM, rodando com 64-bit versão do *Windows* 10. O modelo não considerou as preferências dos pacientes por faixa de horário de agendamento, pois esta informação não estava registrada no sistema, porém se essa preferência fosse considerada, o valor de recompensa referente ao agendamento do paciente em *slots* do equipamento, que estão dentro da preferência do paciente, teria um valor maior.

5.7.3 Verificação do modelo

Para verificação do modelo, compararam-se os três métodos de agendamento: o agendamento pelo modelo de programação linear empregando o tempo de sessão utilizado atualmente, o agendamento pelo modelo de programação linear utilizando o tempo de sessão previsto pelo modelo de regressão e o agendamento manual. Durante 21 dias seguidos realizou-se o agendamento pelo método manual e pelo modelo de programação linear utilizando o tempo de sessão empregado no método manual e comparou-se o número total de pacientes agendados e o número de pacientes agendados levando em consideração a prioridade do paciente, Figura 50. Para a comparação do modelo de programação linear com tempo de tratamento previsto, foram utilizados 21 dias de tratamentos, Figura 51. Para esses modelos utilizaram-se os dados reais dos pacientes como por exemplo, os dias em que o paciente faltou, dia que o paciente teve seu prontuário pronto para agendamento e priorização do paciente e os agendamentos foram realizados no equipamento 2100 CD.

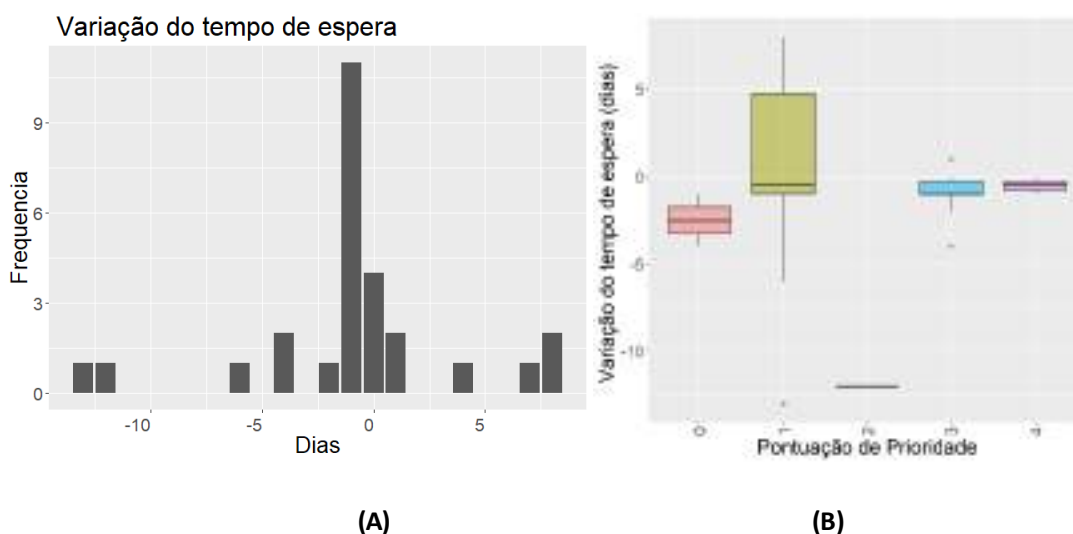
FIGURA 50 - VARIAÇÃO EM DIAS DO TEMPO DE ESPERA DO AGENDAMENTO AUTOMÁTICO COM TEMPO PADRÃO VERSUS O AGENDAMENTO MANUAL. (A) FREQUÊNCIA DAS VARIAÇÕES DO TEMPO DE ESPERA E (B) VARIAÇÃO DO TEMPO DE ESPERA LEVANDO EM CONSIDERAÇÃO A PRIORIZAÇÃO DO PACIENTE.



Pela Figura 50 percebe-se que existe um ganho de tempo de espera no agendamento realizado pelo modelo de programação linear utilizando o tempo de sessão padrão do paciente em comparação com o agendamento manual. O modelo produziu um agendamento médio de inícios de pacientes maior do que o produzido pelo agendamento atual e conseqüentemente possibilitou uma diminuição do tempo de espera dos pacientes.

A Figura 50A mostra que existem dois pacientes que tiveram seu tempo de espera aumentado e isso ocorreu, pois o modelo utiliza a prioridade do paciente para definir a ordem do agendamento e como esses pacientes tinham uma baixa prioridade não foram priorizados pelo modelo. A Figura 51 apresenta os dados para o modelo de agendamento automático com tempo predito com o modelo de *RF*.

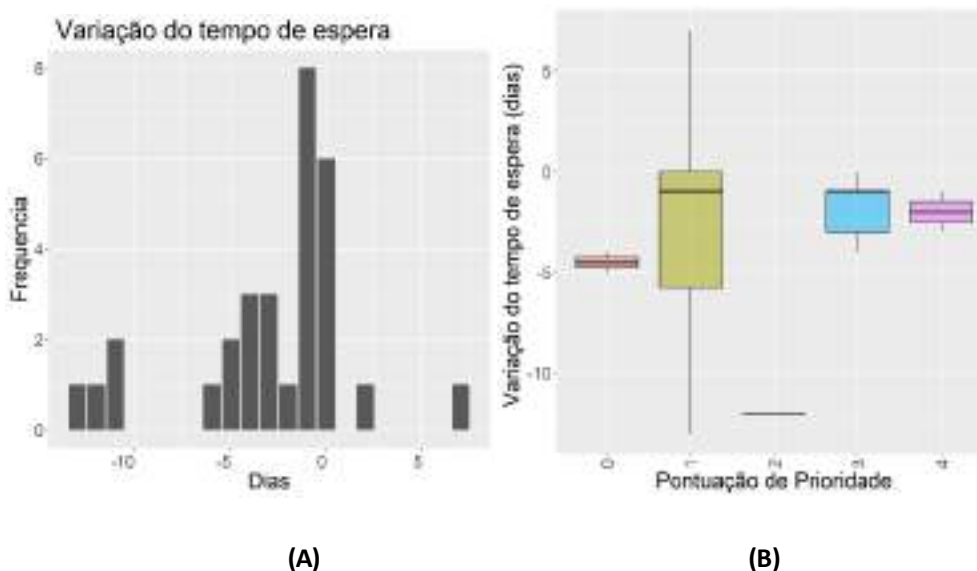
FIGURA 51 - VARIAÇÃO DO TEMPO DE ESPERA DO AGENDAMENTO AUTOMÁTICO COM TEMPO PREDITO EM DIAS VERSUS O AGENDAMENTO MANUAL. (A) FREQUÊNCIA DAS VARIAÇÕES DO TEMPO DE ESPERA E (B) VARIAÇÃO DO TEMPO DE ESPERA LEVANDO EM CONSIDERAÇÃO A PRIORIZAÇÃO DO PACIENTE.



O modelo, por considerar um tempo mais próximo do real e na maioria das vezes esse tempo é maior do que o tempo padrão, agendou 3 pacientes a menos do que o agendamento manual com o tempo padrão, porém ele diminuiu o tempo de espera dos pacientes com mais prioridade e como ele utiliza um tempo de tratamento mais próximo do real, ele influencia no tempo que o paciente espera seu tratamento na recepção, ou seja, os pacientes vão ter um horário de tratamento mais correto, portanto a tendência é ocorrer uma diminuição de atrasos do horário de agendamento e diminuir o problema de tratamento fora do horário comercial. A soma do tempo de tratamento previsto dos pacientes agendados foi 12 minutos maior que a soma do tempo padrão dos pacientes.

Uma solução para aumentar o número de pacientes agendados pelo modelo de programação linear com tempo de tratamento previsto é possibilitar a mudança do horário de agendamento dos pacientes que já estão agendados. Como o modelo considera um tempo de tratamento variável, em vários dias ficam pequenos *slots* de tempo vazio espalhados pela agenda, que são *slots* com um tempo menor do que os tempos de tratamentos requeridos pelos pacientes, logo um modelo alterando o horário do paciente agendado com variação máxima de 5 pacientes foi testado, Figura 52.

FIGURA 52 - VARIAÇÃO DO TEMPO DE ESPERA DO AGENDAMENTO AUTOMÁTICO COM TEMPO PREDITO EM DIAS E POSSIBILIDADE DE MUDANÇA DE HORÁRIO DOS PACIENTES JÁ AGENDADOS VERSUS O AGENDAMENTO MANUAL. (A) FREQUÊNCIA DAS VARIAÇÕES DO TEMPO DE ESPERA E (B) VARIAÇÃO DO TEMPO DE ESPERA LEVANDO EM CONSIDERAÇÃO A PRIORIZAÇÃO DO PACIENTE.



Com esse modelo foi possível ainda priorizar os pacientes com maiores pontuações e agendar o mesmo número de pacientes. Se a mudança de horário dos pacientes já agendados não for uma opção para o serviço, a solução é ao invés de grupos de tratamentos de 12 em 12 minutos fazer a criação de grupos de tempos de tratamentos baseados nos dados analisados, assim o resultado é similar ao da Figura 50, porém o horário reservado na agenda será mais próximo do real.

Foram definidos 9 *clusters* com os dados reais de tempo de tratamento, são eles: 10, 16, 22, 29, 37, 49, 63, 82 e 107 minutos. Para associar algum desses valores para o paciente é necessário avaliar o tempo de referência das características do paciente e definir qual o valor de *cluster* que é o mais próximo, por exemplo, paciente que trata apenas mama sem utilizar anestesia e bloco de colimação com técnica 3D e dose por fração de 267cGy tem um tempo de referência de 13 minutos, portanto esse paciente vai ser associado um tempo de tratamento de 16 minutos. A lista completa dos tempos de referências encontra-se no APÊNDICE E.

6 CONCLUSÕES

Esse trabalho demonstra que a utilização de ciência de dados ajuda a entender os problemas encontrados no setor de radioterapia. Os dados estudados mostram que a proporção de pacientes jovens que utilizam o tratamento de radioterapia vem aumentando, assim como a utilização de técnicas moduladas para o planejamento.

O tempo de espera entre a simulação e o início do tratamento depende principalmente da técnica de planejamento utilizada, do tipo de tratamento e se o paciente é de convênio. A técnica modulada apresenta maior tempo de espera, assim como tratamentos curativos e sem convênio. Vendo que a proporção de técnicas moduladas está crescendo e esses casos são os que requerem maiores tempos de espera, uma busca de soluções para diminuição desse tempo de espera é necessária.

Os dados mostraram que o tempo de espera fornecido para os pacientes de radiocirurgia não são apropriados, a maioria dos pacientes não consegue iniciar seu tratamento na data prevista. Em relação ao tempo de sessão de tratamento, as variáveis que mais impactaram no aumento do tempo de tratamento foram: dose prescrita, utilização de blocos de conformação ao invés de multifolhas acoplado ao equipamento, número de campos de tratamento e o primeiro dia de tratamento. As análises demonstraram que a falta de ferramenta de imagem acoplada ao equipamento aumenta o tempo de tratamento dos pacientes. Testes estatísticos mostraram que na primeira sessão de tratamento, o tempo de sessão aumenta em média 14 minutos e também mostraram que o agendamento seguido de pacientes que tratam a mesma região produz uma diminuição de aproximadamente 2 minutos na sessão de tratamento.

Para a previsão dos tempos de espera e de sessão de tratamento os algoritmos estudados tiveram respostas similares e todos possibilitaram uma previsão de tempo de espera e de tratamento mais próxima da real. Porém, a padronização do tempo de planejamento e contorno é essencial para a melhoria da predição do tempo de espera dos pacientes. Já para o problema de previsão de atrasos, como os dados eram desbalanceados, a utilização da técnica de mudança de limiar para contornar esse problema teve bom resultado.

Com os dados analisados percebe-se que mudanças na rotina são necessárias para facilitar a retirada dos dados do sistema de gerenciamento e dar previsões de tempo de espera para início de tratamento mais próximas do real e assim diminuir a ansiedade do paciente. Um tempo de tratamento mais personalizado, ajuda a diminuir atrasos diários. O agendamento automático possibilitou a diminuição do tempo de espera dos pacientes priorizando os pacientes com pior prognóstico, porém a definição de grupos de tempo de tratamento é importante para que não seja necessária a mudança de horários de pacientes já agendados.

REFERÊNCIAS BIBLIOGRÁFICAS

1. WHO. Cancer. Disponível em: <https://www.who.int/en/news-room/factsheets/detail/cancer> (2021). Acesso: Dez. 2021.
2. Ferlay, J. *et al.* Cancer statistics for the year 2020: An overview. *International journal of cancer* **149**, 778–789 (2021).
3. INCA, Ministério da Saúde. Estimativa/2023 - Incidência de Câncer no Brasil. *INCA – Instituto Nacional de Câncer José Alencar Gomes da Silva* vol. 1 11–120 (2023).
4. GCO. The Global Cancer Observatory Brazil. Disponível em: <https://gco.iarc.fr/today/data/factsheets/populations/76-brazil-factsheets.pdf> (2021). Acesso: Dez. 2021.
5. Soerjomataram, I. & Bray, F. Planning for tomorrow: Global cancer incidence and the role of prevention 2020–2070. *Nature reviews Clinical oncology* **18**, 663–672 (2021).
6. New approaches and procedures for cancer treatment: Current perspectives - PMC.
7. Baskar, R., Lee, K. A., Yeo, R. & Yeoh, K.-W. Cancer and radiation therapy: current advances and future directions. *International journal of medical sciences* **9**, 193 (2012).
8. Khan, F. M. & Gibbons, J. P. *The physics of radiation therapy*. (Lippincott Williams & Wilkins, 2014).
9. Delaney, G., Jacob, S., Featherstone, C. & Barton, M. The role of radiotherapy in cancer treatment: estimating optimal utilization from a review of evidence-based clinical guidelines. *Cancer: Interdisciplinary International Journal of the American Cancer Society* **104**, 1129–1137 (2005).
10. Hanna, T. P. *et al.* The population benefit of evidence-based radiotherapy: 5-year local control and overall survival benefits. *Radiotherapy and oncology* **126**, 191–197 (2018).
11. Mackillop, W. J. Killing time: the consequences of delays in radiotherapy. *Radiotherapy and Oncology* **84**, 1–4 (2007).
12. Feng, M., Valdes, G., Dixit, N. & Solberg, T. D. Machine learning in radiation oncology: opportunities, requirements, and needs. *Frontiers in oncology* **8**, 110 (2018).
13. Vandewinckele, L. *et al.* Overview of artificial intelligence-based applications in radiotherapy: recommendations for implementation and quality assurance. *Radiotherapy and Oncology* **153**, 55–66 (2020).
14. Jarrett, D., Stride, E., Vallis, K. & Gooding, M. J. Applications and limitations of machine learning in radiation oncology. *The British journal of radiology* **92**, 20190001 (2019).
15. Huynh, E. *et al.* Artificial intelligence in radiation oncology. *Nature Reviews Clinical Oncology* **17**, 771–781 (2020).
16. Davenport, T. & Kalakota, R. The potential for artificial intelligence in healthcare. *Future healthcare journal* **6**, 94 (2019).
17. TUGBA CAYIRLI & EMRE VERAL. OUTPATIENT SCHEDULING IN HEALTH CARE: A REVIEW OF LITERATURE. *Production and operations management* **12**, 519–549 (2009).
18. Yu, K.-H., Beam, A. L. & Kohane, I. S. Artificial intelligence in healthcare. *Nature biomedical engineering* **2**, 719–731 (2018).
19. Subrahmanya, S. V. G. *et al.* The role of data science in healthcare advancements: applications, benefits, and future prospects. *Ir J Med Sci* **191**, 1473–1483 (2022).
20. Boehmke, B. & Greenwell, B. *Hands-on machine learning with R*. (Chapman and Hall/CRC, 2019).
21. Sandra de Amo. Técnicas de mineração de dados. *Jornada de Atualização em Informática* 26 (2014).
22. Zumel, N. & Mount, J. *Practical Data Science with R*. 568.
23. Rhys, H. *Machine Learning with R, the tidyverse, and mlr*. (Manning publications, 2020).
24. Arboretti, R., Ceccato, R., Pegoraro, L. & Salmaso, L. Design of Experiments and machine learning for product innovation: A systematic literature review. *Quality and Reliability Engineering International* **38**, 1131–1156 (2022).

25. Giuseppe Bonaccorso. *Machine Learning Algorithms*. (Packt Publishing Ltd, 2017).
26. Obermeyer, Z. & Lee, T. H. Lost in thought: The limits of the human mind and the future of medicine. *N Engl J Med* **377**, 1209–1211 (2017).
27. Marcos Nascimento de Magalhães & Antonio Carlos Pedroso de Lima. *Noções de Probabilidade e Estatística*. (Edusp- Editora da Universidade de São Paulo, 2015).
28. André Filipe . DE MORAES BATISTA & Alexandre Dias Porto CHIAVEGATTO FILHO. Machine Learning aplicado à Saúde. *Sociedade Brasileira de Computação* (2019).
29. Victor Teixeira de Melo Mayrink. Avaliação do algoritmo Gradient Boosting em aplicações de previsão de carga elétrica a curto prazo. Dissertação (Mestrado). Universidade Federal de Juiz de Fora (UFJF) (2016).
30. Cutler, A., Cutler, D. R. & Stevens, J. R. Random Forests. in *Ensemble Machine Learning* (eds. Zhang, C. & Ma, Y.) 157–175 (Springer US, 2012). doi:10.1007/978-1-4419-9326-7_5.
31. Michele Chambers & Thomas W. Dinsmore. *Advanced analytics methodologies: Driving business value with analytics*. (Pearson Education, 2014).
32. Terence Parr & Jeremy Howard. How to explain gradient boosting. Disponível em: <http://explained.ai/gradient-boosting/index.html>. Acesso em Set. 2022.
33. Braga, A. de P., Ludermir, T. B. & Carvalho, A. C. P. de L. F. *Redes neurais artificiais: teoria e aplicações*. (Editora Rio de Janeiro, 2007).
34. DATA SCIENCE ACADEMY. Deep Learning Book. Disponível em: <https://www.deeplearningbook.com.br/cursos-online/>. Acesso em Set. 2022.
35. Fernandes, L. G. L. & Portugal, M. S. Previsão de Séries de Tempo: Redes Neurais Artificiais e Modelos Estruturais. *Nova Economia* 51–73 (1996).
36. Stagge, A. A time series forecasting approach for queue wait-time prediction. (2020).
37. gor Ramalho Pommerenzenbaum. REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DAS PRINCIPAIS SÉRIES DO ÍNDICE IBOVESPA E SUAS APLICAÇÕES EM SISTEMAS AUTOMATIZADOS DE NEGOCIAÇÃO. Dissertação (Mestrado) . Universidade Federal do Rio de Janeiro (2014).
38. Alessia Mammone, Marco Turchi, & Nello Cristianini. Support vector machines. *Wiley Interdisciplinary Reviews: Computational Statistics* **1**, 283–289 (2009).
39. William S Noble. What is a support vector machine? *Nature Biotechnology* vol. 24 1565–1567 (2006).
40. Bernhard Schölkopf & Alexander J. Smola. *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. (MIT Press, 2018).
41. D G FERRARI & L N DE CASTRO SILVA. *Introdução a mineração de dados*. (Saraiva Educação, 2017).
42. Vieira, B., Hans, E. W., van Vliet-Vroegindeweij, C., van de Kamer, J. & van Harten, W. Operations research for resource planning and -use in radiotherapy: a literature review. *BMC Med Inform Decis Mak* **16**, 149 (2016).
43. Cesar Duarte Souto-Maio. *Pesquisa Operacional*. (UNIVERSIDADE FEDERAL DE SANTA CATARINA, 2014).
44. Winston, W. L. & Goldberg, J. B. *Operations Research: Applications and Algorithms*. (Thomson Brooks/Cole, 2004).
45. A. Ravindran, Don T. Phillips, & James J. Solberg. *Operations Research: Principles and Practiced*. (Wiley, 1987).
46. Hulshof, P. J. H., Kortbeek, N., Boucherie, R. J. & Hans, E. W. Taxonomic classification of planning decisions in health care: a review of the state of the art in OR/MS. *New Journal of Physics* (2011).
47. Hans, E. W., van Houdenhoven, M. & Hulshof, P. J. H. A Framework for Healthcare Planning and Control. in *Handbook of Healthcare System Scheduling* (ed. Hall, R.) 303–320 (Springer US, 2012). doi:10.1007/978-1-4614-1734-7_12.
48. Bronson, R. & Naadimuthu, G. *Schaum's Outline of Operations Research*. (McGraw Hill Professional, 1997).
49. Pinto, J. M., Joly, M. & Moro, L. F. L. Planning and scheduling models for refinery operations. *Computers & Chemical Engineering* **24**, 2259–2276 (2000).

50. Gonçalves, R. D. R. MODELOS DE PROGRAMAÇÃO LINEAR INTEIRA MISTA PARA RESOLVER PROBLEMAS DE OTIMIZAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA RADIAIS. Tese (Doutorado em Engenharia Elétrica). Faculdade de Engenharia do Câmpus de Ilha Solteira - UNESP (2013).
51. Luo, Y., Chen, S. & Valdes, G. Machine learning for radiation outcome modeling and prediction. *Med. Phys.* **47**, (2020).
52. Curtis, C., Liu, C., Bollerman, T. J. & Pinykh, O. S. Machine Learning for Predicting Patient Wait Times and Appointment Delays. *Journal of the American College of Radiology* **15**, 1310–1316 (2018).
53. Bleustein, C. *et al.* Wait times, patient satisfaction scores, and the perception of care. *Am J Manag Care* **20**, 393–400 (2014).
54. Joseph, J., Senith, S., Kirubaraj, A. A. & Ramson, J. Machine Learning for Prediction of Wait Times in Outpatient Clinic. *Procedia Computer Science* **215**, 230–239 (2022).
55. Waiting Patiently: An Empirical Study of Queue Abandonment in an Emergency Department. *Management Science* **61**, 39–59 (2015).
56. Jouini, O., Akşin, Z. & Dallery, Y. Call Centers with Delay Information: Models and Insights. *Manufacturing & Service Operations Management* **13**, 534–548 (2011).
57. Lin, W.-C., Goldstein, I. H., Hribar, M. R., Sanders, D. S. & Chiang, M. F. Predicting Wait Times in Pediatric Ophthalmology Outpatient Clinic Using Machine Learning. *AMIA Annu Symp Proc* **2019**, 1121–1128 (2019).
58. Javadifard, H. *et al.* Predicting Patient Waiting Time in Phlebotomy Units Using a Deep Learning Method. in *2019 Innovations in Intelligent Systems and Applications Conference (ASYU)* 1–4 (2019).
59. Pinykh, O. S. & Rosenthal, D. I. Can We Predict Patient Wait Time? *J Am Coll Radiol* **12**, 1058–1066 (2015).
60. Joseph, A., Hijal, T., Kildea, J., Hendren, L. & Herrera, D. Predicting Waiting Times in Radiation Oncology Using Machine Learning. in *2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA)* 1024–1029 (IEEE, 2017).
61. Fortin, B. *et al.* Waiting time for radiation therapy in breast cancer patients in Quebec from 1992 to 1998: a study of surgically treated breast cancer patients in Quebec documents and helps to explain increased waiting times for radiation therapy. *Healthc Policy* **1**, 152–167 (2006).
62. Ogulata, S. N., Cetik, M. O., Koyuncu, E. & Koyuncu, M. A simulation approach for scheduling patients in the department of radiation oncology. *J Med Syst* **33**, 233–239 (2009).
63. Ehr Gott, M. & Holder, A. Operations Research Methods for Optimization in Radiation Oncology. *Mathematical Sciences Technical Reports (MSTR)* (2009).
64. Larsson, S. N. Radiotherapy patient scheduling using a desktop personal computer. *Clin Oncol (R Coll Radiol)* **5**, 98–101 (1993).
65. Lim, K. S. H., Vinod, S. K., Bull, C., O'Brien, P. & Kenny, L. Prioritization of radiotherapy in Australia and New Zealand. *Australas Radiol* **49**, 485–488 (2005).
66. Dodwell, D. & Crellin, A. Waiting for radiotherapy. *BMJ* **332**, 107–109 (2006).
67. Mikeljevic, J. S. *et al.* Trends in postoperative radiotherapy delay and the effect on survival in breast cancer patients treated with conservation surgery. *Br J Cancer* **90**, 1343–1348 (2004).
68. Kapamara, T., Sheibani, K., Haas, O. C. L., Reeves, C. R. & Petrovic, D. A review of scheduling problems in radiotherapy. in (2006).
69. Tao, W., Eric, M. & Pascal, P. Online scheduling for a hadrontherapy treatment center. in *Proceedings of the 30th Chinese Control Conference* 2201–2205 (2011).
70. Proctor, S., Lehaney, B., Reeves, C. & Khan, Z. Modelling Patient Flow in a Radiotherapy Department. *OR Insight* **20**, 6–14 (2007).
71. Petrovic, D., Morshed, M. & Petrovic, S. Multi-objective genetic algorithms for scheduling of radiotherapy treatments for categorised cancer patients. *Expert Systems with Applications* **38**, 6994–7002 (2011).
72. Conforti, D., Guerriero, F. & Guido, R. Optimization models for radiotherapy patient scheduling. *4OR* **6**, 263–278 (2008).

73. Conforti, D., Guerriero, F. & Guido, R. Non-block scheduling with priority for radiotherapy treatments. *European Journal of Operational Research* **201**, 289–296 (2010).
74. Conforti, D., Guerriero, F., Guido, R. & Veltri, M. An optimal decision-making approach for the management of radiotherapy patients. *OR Spectrum* **33**, 123–148 (2011).
75. Delaney, G., Rus, M., Gebiski, V., Lunn, A. D. & Lunn, M. Refinement of the basic treatment equivalent model to reflect radiotherapy treatment throughput using Australasian data. *Australas Radiol* **43**, 507–513 (1999).
76. Burnet, N. G. *et al.* A tool to measure radiotherapy complexity and workload: derivation from the basic treatment equivalent (BTE) concept. *Clin Oncol (R Coll Radiol)* **13**, 14–23 (2001).
77. Petrovic, S. & Leite-Rocha, P. Constructive and grasp approaches to radiotherapy treatment scheduling. in *Advances in Electrical and Electronics Engineering-IAENG Special Edition of the World Congress on Engineering and Computer Science 2008* 192–200 (IEEE, 2008).
78. Legrain, A., Fortin, M.-A., Lahrichi, N. & Rousseau, L.-M. Online stochastic optimization of radiotherapy patient scheduling. *Health Care Manag Sci* **18**, 110–123 (2015).
79. Riff, M.-C., Cares, J. P. & Neveu, B. RASON: A new approach to the scheduling radiotherapy problem that considers the current waiting times. *Expert Systems with Applications* **64**, 287–295 (2016).
80. Petrovic, D., Morshed, M. & Petrovic, S. Genetic Algorithm Based Scheduling of Radiotherapy Treatments for Cancer Patients. in *Artificial Intelligence in Medicine* (eds. Combi, C., Shahar, Y. & Abu-Hanna, A.) 101–105 (Springer Berlin Heidelberg, 2009).
81. Petrovic, D., Castro, E., Petrovic, S. & Kapamara, T. Radiotherapy Scheduling. in *Automated Scheduling and Planning: From Theory to Practice* (eds. Uyar, A. S., Ozcan, E. & Urquhart, N.) 155–189 (Springer Berlin Heidelberg, 2013).
82. Sauré, A., Patrick, J., Tyldesley, S. & Puterman, M. L. Dynamic multi-appointment patient scheduling for radiation therapy. *European Journal of Operational Research* **223**, 573–584 (2012).
83. Heger, J., Bani, H. & Scholz-Reiter, B. *Improving Production Scheduling with Machine Learning*. (2012).
84. Agarwal, A., Pirkul, H. & Jacob, V. S. Augmented neural networks for task scheduling. *European Journal of Operational Research* **151**, 481–502 (2003).
85. *Relatório de atividades HCFMUSP Biênio 2021/2020*. Disponível em: <<https://www.hc.fm.usp.br/hc/comunicacao/relatorios>> (2022). Acesso em: Dez. 2022.
86. R Core Team. R: A Language and Environment for Statistical Computing. (2022).
87. Wickham H, Bryan J. readxl: Read Excel Files_. R package version 1.4.1. (2022).
88. Freitas W. bizdays: Business Days Calculations and Utilities_. R package. (2023).
89. Dowle M, Srinivasan A. data.table: Extension of `data.frame`_. R package. (2022).
90. Kuhn M. caret: Classification and Regression Training_. R package version 6.0-93. (2022).
91. Wickham H, François R, Henry L, Müller K. dplyr: A Grammar of Data Manipulation. (2022).
92. Meyer D, Dimitriadou E, Hornik K, Weingessel A, Leisch F. e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien_. R package. (2022).
93. Kaplan J. fastDummies: Fast Creation of Dummy (Binary) Columns and Rows from Categorical Variables_. R package. (2020).
94. Hyndman R, Athanasopoulos G, Bergmeir C, Caceres G, Chhay L, O’Hara-Wild M, Petropoulos F, Razbash S, Wang E, Yasmeeen F. forecast: Forecasting functions for time series and linear models_. R package. (2022).
95. LeDell E, Gill N, Aiello S, Fu A, Candel A, Click C, Kraljevic T, Nykodym T, Aboyoum P, Kurka M, Malohlava M. h2o: R Interface for the ‘H2O’ Scalable Machine Learning Platform_. R package. (2022).
96. Hunt T. ModelMetrics: Rapid Calculation of Model Metrics_. R package. (2020).
97. Fritsch S, Guenther F, Wright M. neuralnet: Training of Neural Networks_. R package. (2019).
98. Schumache. ompr: Model and Solve Mixed Integer Linear Programs_. R package. (2022).
99. Schumacher D. ompr.roi: A Solver for ‘ompr’ that Uses the R Optimization Infrastructure ('ROI')_. R package. (2022).

100. Owen J. rhandsontable: Interface to the 'Handsontable.js' Library_. R package. (2021).
101. Therneau T, Atkinson B. rpart: Recursive Partitioning and Regression Trees_. R. (2022).
102. Wickham H. stringr: Simple, Consistent Wrappers for Common String Operations_. R package. (2022).
103. Chen T, He T, Benesty M, Khotilovich V, Tang Y, Cho H, Chen K, Mitchell R, Cano I, Zhou T, Li M, Xie J, Lin M, Geng Y, Li Y, Yuan J. xgboost: Extreme Gradient Boosting_. R package. (2022).
104. Bischl B, Lang M, Kotthoff L, Schiffner J, Richter J, Studerus E, Casalicchio G, Jones Z. mlr: Machine Learning in R." *Journal of Machine Learning Research*. 1–5 (2016).
105. Patil, I. Visualizations with statistical details: The 'ggstatsplot' approach. *Journal of Open Source Software* (2021).
106. Wickham H, Averick M, Bryan J, Chang W, McGowan LD, François R, Golemund G, Hayes A, Henry L, Hester J, Kuhn M, Pedersen TL, Miller E, Bache SM, Müller K, Ooms J, Robinson D, Seidel DP, Spinu V, Takahashi K, Vaughan D, Wilke C, Woo K, Yutani H. "Welcome to the tidyverse." (2019).
107. Perry PO. utf8: Unicode Text Processing_. R package. (2021).
108. H. Wickham. ggplot2: Elegant Graphics for Data Analysis. (2016).
109. Raschka, S. & Mirjalili, V. *Python machine learning: machine learning and deep learning with Python, scikit-learn, and TensorFlow 2*. (Packt, 2019).
110. Royal College of Radiologists. A national audit of waiting times for radiotherapy. (1998).

APÊNDICE A – Lista dos CIDs que compõe cada Grupo

| Grupo | CID | Grupo | CID |
|---------------------------|---|-------------------------------------|--|
| Abdome (ABD) | C16-C17,C23-C25, K20-K31, K50-K52, K55-K59 , K53,K70-K77 ,K80-93, D01,D13 | Hemato (HEMATO) | C42, C88, C90-C96 ,D45-D51 |
| Figado | C22 | Linfoma (LYMPHOMA) | C81-C85, M959, M965, M967, M969-M972 |
| Apendice | K35-K38 | MAV (MAFORMACAO) | Q00-Q45, Q50-56, Q60-Q99 |
| Articulação (ARTICULACAO) | M00-M99 | Metastase (META) | C77-C80 |
| Osso (BONE) | C40-C41, D16 ,M926 | Partes Moles (MOLES) | C48, C49, D20, D21, M880 - M881, M884, M885, M889, M893, M900, M904-M906, M958 |
| Mama/fsc | C50, D05, D24, N60-N64 | Pescoço e Abdome(NECK AND ABDOMEN) | D00 , D37 |
| Bucal | K00-K14 ,M927 | SN-MENINGIOMAS | M953 |
| Desordem | F00-F99 | SN-Schwannoma | R24 |
| Ouvido (OUVIDO) | H60-H75, H80-H83 , H90-H95 | SN | C47, C69-C72, D31-D33, D42-D43, G10-G13, G20-G26, G30-G47, G50-G64, G70-G73, G80-G83, G90-G99, M938 , M954 |
| Endocrino | E00-E07, E10-E16 ,E20-E35, E40-E46, E50-E79 | Ocular | H00-H06 ,H10-H59 |
| Epiteliais | M800-M801, M805,M809, M12, M14, M839, M843, M844, M850, M855, M856, M859, M868,M872, M949 | Pelve | C18 |
| Esôfago (ESOFAGO) | C15 | Peritonial | K65-K67 |
| Glândulas (GLAND) | C73-C76, D34-D36 ,D44 | PELVE reto/canal anal | C19-21,D12,K60-62 |
| Ginecológico (GINECO) | C51-C58, D06-D09, D25-D28, D39, N70-N99, M910 , M911 | Pele (SKIN) | C43-C44, C46, D03-D04, D17-D19, D22, D23, L00-L14, L20-L30, L40-L45, L50-L75 ,L80-L99 |
| Cabeça e Torax | D02, D14 ,D38 | Torax | C34, C37-C39, C45, D15 |
| CP naso/orofaringe | C10-C14 | Uro Prostata | C61, N40-N42 |
| CP faringe | D10 | Uro | C60,C62-C68, D29-D30, D40-D41,N00-39,N43-N51 |
| CP laringe | C32 | Vascular | I00-I02, I105-I15, I20-I52, I60-I74, I77-I89 ,I95-I99 |
| CP | C00-C14, C30-C33, D11 | Cabeça e Torax (HEAD AND THORAX) | D02,D14 e D38 |

APÊNDICE B – Dicionário das variáveis estudadas

| Variável | Tipo | Descrição | Unidade ou Codificação |
|-------------------|-------------|--|---|
| Nome | Categórica | Nome Completo do paciente | |
| PACS | Categórica | Identificação do paciente | |
| data.nascimento | Data-Time | Data de nascimento do paciente | DD/MM/YYYY |
| data.admissao | Data-Time | Data de admissão do paciente no departamento de radioterapia | DD/MM/YYYY |
| CID | Categórica | Classificação internacional da doença do paciente. Inserido no MOSAIQ em cada curso de tratamento | Tabela CID 10 |
| Rghc | Categórica | Registro interno do paciente no HCFMUSP | |
| Intencao_tto | Categórica | Intenção do tratamento Inserido no MOSAIQ em cada curso de tratamento | Paliativo ; Curativo ; Profilático ; Regime BMT; Neoadjuvante ; Indução; Não definido ; Outros |
| Regiao | Categórica | Região de tratamento Inserido no MOSAIQ em cada curso de tratamento | Abdomen; Ânus; Bexiga; Osso; Cérebro; Mama ; Cervical.; Cólon; Conduto Auditivo; Tecido conjuntivo; Glândulas endócrinas, Esôfago; Gastro-intestinal; Gengiva; Cabeça e pescoço; Coração; Hipofaringe; Rim; Laringe; Leucemia; Lábio; Fígado; Pulmão; Linfoma; Melanona; Mieloma; Céu da boca; Nasofaringe; Orofaringe; Ovário; Palato; Pâncreas; Pelve; Pênis; Pleura; Próstata; Glândulas Salivares ; Sinus ; Pele; Intestino; Estômago; Testículo.; Torax; Tiróide; Língua |
| Data.Sessao | Numérica | Data que foi realizado um agendamento de determinada Atividade no departamento | DD/MM/YYYY |
| Aparelho | Categórica | Local onde foi realizado o agendamento da Atividade em uma determinada data (Data.Sessao) | iX; 2100 CD; Clinac 6EX; Apoio técnico; Sala dos Médicos; Sala da física |
| Nota_agendadiaria | Categórica | Anotações feitas na agenda da sala de simulação -CT para uma determinada data | |
| Captura | Categórica | Sigla que mostra qual status está a atividade que foi agendada na agenda diária | Início(S); Concluída (C) ; Falta (N) ; Manutenção (M); Suspensa (Y); Alta(F) |
| hora.agendamento | Data-time | Horário que esta agendado para o paciente realizar uma determinada atividade em uma determinada data (Data.Sessao) | h:m:s |

| Variável | Tipo | Descrição | Continuação Unidade ou Codificação |
|-------------------|------------|---|---|
| Atividade | Categórica | Atividade realizada. Pode ser relacionada ao tratamento, simulação, QA, retorno e revisão. Um código é capturada para registrar a atividade do paciente | AL FÓTONS E ELETRONS ; AL FÓTONS; RADIO FOT E ELE; RADIO FOT; SRT Fracionada; RADIOCIR ESTERE FRAC; CT SIM; CHECK/FILMSUS ;RADIOCIRURGIA; MASC/VAC FIX/IMOB; PLAN COMPLEXO; PLANEJAMENTO; RADIOCIR UMA OU MAIS; SIMULAÇÃO; Simulation: S; REVISAO SEM; REVISÃO;ISO TC; TTO IMRT; ALTA; IMOB IMRT; CT SIM OSASCO; QA/DOSIMETRIA; TTO NARCOSE; SIM COM NARCOSE; TTO BETA 10 CPS; BETA OFTALMOLÓGICA; TBI CORPO INTEIRO; PLAN TBI; TBI/SUS; TTO SRT IMRT/VMAT; SIM TBI; BETA DERMATOLÓGICA; QA/DOSIMETRIA/SRT; TTO VMAT; QA_PRONTUARIO; QA/DOSIMETRIA/SBRT; QA IMRT;QA VMAT/RapidArc;Sim with Contrast; RETORNO; TTO BETA > 10 CPOS; PLAN 3D; SBRT; RADIOC HIPO; VMAT / IMRT; CONSULTA REVISÃO; QA_PREVENTIVA;QA/DOSIMETRIA/3D; BETA; IRRAD DE MEIO CORPO; PLAN IMRT; Private |
| Nota_agendadiaria | Categórica | Anotações feitas na agenda da sala de simulação -CT para uma determinada data | |
| Data.agendadiaria | Numérica | Data na agenda diária da sala de simulação – CT | DD/MM/YYYY |
| Site.prescricao | Categórica | Nome da prescrição realizada pelo médico | |
| Dose.Total | Numérica | Dose total de tratamento prescrita pelo médico para um determinado Site | cGy |
| Dose.Sessao | Numérica | Dose por Sessão de tratamento prescrita pelo médico para um determinado Site | cGy |
| Tempo.Sessao | Numérica | Tempo de tratamento reservada para o paciente na sala de tratamento | min |
| Tempo | Numérica | Tempo proposto como padrão dado pelo tempo médio do agrupando do grupo, número de isocentros , técnica e anestesia | min |

| Variável | Tipo | Descrição | Continuação Unidade ou Codificação |
|-----------------------------|-------------|---|---|
| Tarefa_QCL | Catagórica | Nome da tarefa pré tratamento | Acompanhar dia de tratamento ; Aprovação contorno ; Aprovação CPOS MQ ; Aprovação de documentos ; Aprovar contorno eclipse; Aprovar Contorno Pediátrico ; Aprovar contornos iplan ; Aprovar planejamento; Aprovar plano; Aquisição CT no TPS .Aquisição RM no TPS; Avaliar QA de IMRT ;Cálculo de Betaterapia; Cálculo ficha ;Checar fusão de imagens ;Check List SRT Conferência de Docs e Agendamentos ; Conferência ficha ; Contorno convênio; Contornos ; Contornos eclipse ;Contornos iplan Controle de Qualidade do Prontuário ; Convocar paciente ;Dados Mosaik;Definição campo tto ; Desenhar Pb pulmão ;Digitalizar Pb;Dosimetria;Enviar paciente para o Exactrac ; Imprimir ficha plane; Imprimir plano;IMRT CQ ; Planejamento 2d ; Planejamento 3D ; Planejamento IMRT ;Planejamento SBRT ; Planejamento SRT ; Preencher planilha ; Preparar QA IMRT ;Preparar QA SBRT ; Prescrição da ficha ; Prescrição ficha; Prescrição Mosaik; Replanejamento; Replanejamento Plano Fisica; Replanejamento Conduta Med ;Replanejamento QAP; Replanejamento Ressim ; SBRT_QA; Solicitar blocos ;SRT_QA ; Teste de colisão ; Tratamento térmico TLD ; Verificar plano Física |
| DataProgramada_QCL | Data-time | Data programada para realização da tarefa pré tratamento | DD/MM/YYYY |
| DataExecutada_QCL | Data-time | Data Executada da tarefa pré tratamento (DD/MM/YYYY) | DD/MM/YYYY |
| VariacaoData_QCL | Data-time | Variação entre a Data programada e executada da tarefa pré tratamento | DD/MM/YYYY |
| UsuarioExecutou_QCL | Catagórica | Usuário que executou a tarefa pré tratamento | |
| Departamento_QCL | Catagórica | Departamento onde a tarefa pré tratamento foi executada | Apoio técnico (AT) ; Sala dos físicos (SF) ; Sala dos médicos (SM) |
| hora.agendamento.tto | Data-time | Horário que está agendado para o paciente realizar o tratamento na sala de tratamento | h:m:s |
| hora.chegada.tto | Data-time | Horário que o paciente chegou no departamentno para realizar o tratamento (h:m:s) | h:m:s |
| Dif.chegada.agendamento.tto | Numérica | Diferença entre o horário de chegada do paciente no departamento com o horário de agendamento | Min |
| tempo.espera.tto | Numérica | Tempo que o paciente esperou para entrar na sala de tratamento | Min |

| Variável | Tipo | Descrição | Unidade ou Codificação |
|----------------------|-------------|--|---|
| tempo.tratamento.tto | Numérica | Tempo que o paciente ficou na sala de tratamento | Min |
| hora.saida.tto | Numérica | Horário que o paciente finalizou o tratamento | h:m:s |
| Energia.Sessao | Categórica | Energia de tratamento usada na sessão de tratamento (MV) | MV |
| UM.Sessao | Numérica | Unidade Monitora usada na sessão de tratamento | |
| Dose.Sessao | Numérica | Dose por campo de tratamento | cGy |
| Filtro.Sessao | Categórica | Acessório filtro utilizado no campo de tratamento | 0- Não Usou 1- Filtro dinâmico 2-Filtro físico |
| Bloco.Sessao | Categórica | Acessório bloco utilizado no campo de tratamento | 0- Não Usou 1- Usou |
| Tempo_sala | Data-time | Horário que foi tratado um determinado campo de tratamento | h:m:s |
| Numero.Sessao | Numérica | O número da sessão de tratamento que o paciente está realizando em um determinado data | |
| Data.Sim | Data-time | Data que foi realizada a simulação do paciente | DD/MM/YYYY |
| Data.Inicio | Data-time | Data que o paciente iniciou o tratamento | DD/MM/YYYY |
| TEC | Categórica | Técnica de tratamento do paciente | 2d;3D; 3D REF; 3D SRS ; ELETRONS ; IMRT IMRT; REF IMRT ; SRS; TBI ; VMAT |
| Isocentros | Numérica | Número de isocentros de tratamento num determinado curso de tratamento do paciente | |
| campos.Sessao | Numérica | Número de campos de tratamento do paciente | |
| ANESTESIA | Numérica | Verifica a realização de anestesia no paciente | 0- Não 1-Sim |
| INICIO | Numérica | Verifica se a data é o primeiro dia de tratamento | 0- Não 1-Sim |
| Portais | Numérica | Verifica a realização de imagens de verificação em uma determinada data de tratamento | 0- Não 1-Sim |
| Faixa | Categórica | Faixa etária do paciente | criança; adolescente; adulto e idoso |
| CONVENIO | Numérica | Verifica se o paciente é convênio | 0- Não 1-Sim |
| Tempo.tto_medio | Numérica | Média do tempo de tratamento excluindo os dias que o tempo de tratamento foi 3 vezes maior que o tempo de tratamento médio | min |
| TempoRef | Numérica | Tempo de tratamento médio do paciente | min |

| Variável | Tipo | Descrição | Continuação Unidade ou Codificação |
|--------------------|-------------|--|---|
| Grupo | Categórica | Grupo de especialidade do paciente | ABD; ARTICULACAO;BONE;bone pelve; CP; CP faringe; CP laringe;CP naso/orofaringe; EPITELIAIS ; ESOFAGO ; Fígado; GINECO; GLAND;HEAD AND THORAX; HEMATO;LYMPHOMA ; MAFORMACAO; mama/fsc; META CEREBRAL; META OSSEA ; META SRS ; META TORAX; METASTASE; MOLES ; NECK AND ABDOMEN ;OCULAR; Ossificação; OUVIDO; PELVE ;PELVE reto/canal anal; SKIN;SN ;SN-MENINGIOMAS; SN-Schw annoma GINECO ;SN Craniofaringioma;SN Hipófise;SN NEURINOMA;SN Schw annoma;SRS-MENINGIOMAS;SRS-Schw annoma; SRS Hipófise; SRS MAV;SRS NEURINOMA;TBI; Torax; Urgencia; URO ; URO prostata; VASCULAR |
| Intervalo | Data-time | Intervalo de data de tratamento do paciente | DD/MM/YYYY - DD/MM/YYYY |
| Idade | Numérica | idade do paciente | |
| Data.Min | Data-time | Data mínima de tratamento do paciente | DD/MM/YYYY |
| Data.Max | Data-time | Data máxima de tratamento do paciente | DD/MM/YYYY |
| REP | Numérica | Número de novos tratamentos por paciente | |
| Data_Conf | Data-time | Data que foi executada a conferência da ficha técnica do paciente | DD/MM/YYYY |
| Data_ProgConf | Data-time | Data programada da conferência da ficha técnica do paciente | DD/MM/YYYY |
| Dif | Numérica | Tempo gasto na etapa pré tratamento esperado do paciente | dias |
| DataProgramada_QCL | Data-time | Data programada do planejamento do paciente | DD/MM/YYYY |
| OBS | Categórica | Observações adicionais | |
| Espera | Numérica | Tempo de espera real do paciente | dias |
| Grupo_Seguido | Categórica | Verifica se o paciente tratou em seguida de um paciente do mesmo grupo em um determinado dia de tratamento | 0- Não 1-Sim |
| ocupação | Numérica | Porcentagens de vagas ocupadas no aparelho | % |
| Atraso | Categórica | Verificação de atraso no tempo de espera no paciente | 0- Não 1-Sim |
| Ano | Numérica | Ano de tratamento do paciente | Ano |
| mes | Numérica | Mês de tratamento do paciente | mês |
| Sazonalidade | Categórica | Junção do Mês e Ano do tratamento do paciente | |

| Variável | Tipo | Descrição | Unidade ou Codificação |
|---------------------------|-------------|---|--|
| Faixa_etaria1 | Catégorica | Formação de grupos de idades de 9 em 9 anos | 0-9; 10-19; 20-29;30-39;40-49;50-59;60-69;70-79;80-89;90-99 |
| tempo.plano | Numérica | Tempo real gasto no planejamento | dias |
| tempo.planopadrao | Numérica | Tempo esperado na execução do planejamento | dias |
| UsuarioPlano | Catégorica | Usuário que executou o Plano do paciente | |
| tempo.contorno | Numérica | Tempo real gasto no contorno | dias |
| tempo.contornopadrao | Numérica | Tempo esperado na execução do contorno | dias |
| UsuarioContorno | Catégorica | Usuário que executou o contorno | |
| DataAprovContorno | Data-time | Data que foi realizada a aprovação do contorno | DD/MM/YYYY |
| tempo.aprovcontorno | Numérica | Tempo gasto para aprovação do contorno | dias |
| tempo.aprovcontornopadrao | Numérica | Tempo esperado de aprovação do contorno | dias |
| tempo.aprovarplano | Numérica | Tempo gasto para a aprovação do plano | dias |
| DataAprovplano | Data-time | Data que foi realizada a aprovação do plano | DD/MM/YYYY |
| tempo.aprovarplanopadrao | Numérica | Tempo para aprovação do plano esperado | dias |
| tempo.calculo | Numérica | Tempo gasta para cálculo real | dias |
| tempo.calculopadrao | Numérica | Tempo esperado para cálculo | dias |
| DataCal | Data-time | Data que foi realizado o cálculo da ficha | DD/MM/YYYY |
| DataConf | Data-time | Data que foi executada a conferência da ficha | DD/MM/YYYY |
| tempo,confpadrao | Numérica | Tempo esperado para conferência | dias |
| tempo.espera | Numérica | Tempo de espera real | dias |
| tempo,esperapadrao | Numérica | Tempo de espera esperado | dias |
| Feriado | Numérica | Verificação se a data prevista para início é feriado | 0- Não 1-Sim |
| Casos | Numérica | Número de simulações realizadas nos 7 dias antes da data da simulação do paciente | |
| Ds | Catégorica | Dia da semana | Segunda-feira; Terça feira; Quarta-feira;Quinra-feira;Sexta-feira;Sabado;Domingo |
| tempo,conf | Númeric | Tempo gasto na conferência da ficha | dias |
| DifEspera | Numérica | Diferença do tempo de espera previsto e real | dias |
| PrazoConf | Data-time | Data de Conferência prevista | DD/MM/YYYY |
| Atividade | Numérica | Difrença entre a Data de conferência prevista e a real | dias |

| Variável | Tipo | Descrição | Unidade ou Codificação | Continuação |
|------------------|-------------|---|-------------------------------|--------------------|
| atraso.agenda | | Ocorreu hora extra de tratamento | 0- Não 1-Sim | |
| Prazo2 | | Verifica se ocorreu atraso na conferência da ficha | 0- Não 1-Sim | |
| Score | Numérica | Prioridade do paciente para ser agendado no equipa,ento | 1; 2; 3; 4 | |
| AGENDADO | Numérica | Verificação se o paciente já esta agendado no equipamento | 0- Não 1-Sim | |
| Prazo | Numérica | Verificação se houve atraso da data prevista para início | 0- Não 1-Sim | |
| N | Numérica | Número de pacientes agendados em um determinado dia | | |
| Data.InicioAut | Data-time | Data de Inicio do paciente dada pelo modelo | DD/MM/YYYY | |
| Data_Agendamento | Data-time | Data que está sendo realizado o agendamento | DD/MM/YYYY | |
| EsperaTOT | Numérica | Soma do Tempo de espera dos pacientes agendados | | |
| Freq | Numérica | Número de inicio no equipamento em um determinado dia | | |
| UM | Numérica | Soma da UM em um determinado dia | | |

APÊNDICE C- Tempo de Espera ideal levando em consideração as variáveis: grupo, se o paciente é pediátrico, se o paciente é convênio e a técnica de tratamento. O IC(95%) é o tempo de espera em dias que deveria ser fornecido para o paciente para que 95% dos pacientes não ultrapassem o tempo de espera previsto e o IC(68%) é o tempo de espera em dias que deveria ser fornecido para o paciente para que 95% dos pacientes não ultrapassem o tempo de espera previsto.

| Grupo | Faixa etária | CONVÊNIO | Técnica | IC (68%) | IC (95%) |
|--------------------|---------------------|-----------------|----------------|-----------------|-----------------|
| ABD | adulto | 0 | 3D | 14 | 20 |
| ABD | adulto | 0 | ELETRONS | 12 | 18 |
| ABD | adulto | 0 | IMRT | 20 | 27 |
| ABD | adulto | 0 | VMAT | 19 | 28 |
| ABD | adulto | 1 | 3D | 1 | 1 |
| ABD | ped | 0 | 3D | 14 | 19 |
| ABD | ped | 0 | IMRT | 21 | 29 |
| ABD | ped | 0 | VMAT | 21 | 29 |
| ARTICULACAO | adulto | 0 | 3D | 10 | 14 |
| ARTICULACAO | adulto | 0 | IMRT | 15 | 20 |
| ARTICULACAO | adulto | 0 | VMAT | 19 | 27 |
| ARTICULACAO | ped | 0 | 3D | 8 | 8 |
| BONE | adulto | 0 | 3D | 11 | 16 |
| BONE | adulto | 0 | VMAT | 27 | 37 |
| BONE | ped | 0 | 3D | 20 | 23 |
| CP | adulto | 0 | 3D | 15 | 22 |
| CP | adulto | 0 | 3D SRS | 13 | 16 |
| CP | adulto | 0 | ELETRONS | 15 | 22 |
| CP | adulto | 0 | IMRT | 19 | 25 |
| CP | adulto | 0 | VMAT | 20 | 27 |
| CP | ped | 0 | 3D | 14 | 18 |
| CP | ped | 0 | IMRT | 21 | 25 |
| CP | ped | 0 | VMAT | 19 | 24 |
| CP faringe | adulto | 0 | 3D | 10 | 13 |
| CP faringe | adulto | 0 | IMRT | 25 | 35 |
| CP faringe | adulto | 0 | VMAT | 22 | 31 |
| CP faringe | ped | 0 | VMAT | 19 | 26 |
| CP laringe | adulto | 0 | 3D | 16 | 23 |
| CP laringe | adulto | 0 | VMAT | 21 | 29 |
| CP laringe | adulto | 1 | 3D | 6 | 9 |
| CP naso/orofaringe | adulto | 0 | 3D | 15 | 20 |
| CP naso/orofaringe | adulto | 0 | IMRT | 21 | 27 |
| CP naso/orofaringe | adulto | 0 | VMAT | 19 | 25 |
| ESOFAGO | adulto | 0 | 3D | 13 | 18 |

| Grupo | Faixa etária | CONVÊNIO | Técnica | IC (68%) | Continuação |
|---------------|--------------|----------|----------|----------|-------------|
| | | | | | IC (95%) |
| GINECO | adulto | 0 | 3D | 14 | 17 |
| GLAND | adulto | 0 | 3D | 15 | 19 |
| GLAND | adulto | 0 | IMRT | 18 | 26 |
| GLAND | adulto | 0 | VMAT | 20 | 25 |
| GLAND | adulto | 1 | IMRT | 12 | 19 |
| GLAND | ped | 0 | VMAT | 23 | 31 |
| HEMATO | adulto | 0 | 3D | 13 | 19 |
| LYMPHOMA | adulto | 0 | 3D | 14 | 20 |
| LYMPHOMA | adulto | 0 | ELETRONS | 15 | 23 |
| LYMPHOMA | adulto | 0 | IMRT | 18 | 22 |
| LYMPHOMA | adulto | 0 | VMAT | 19 | 25 |
| LYMPHOMA | ped | 0 | VMAT | 15 | 15 |
| META CEREBRAL | adulto | 0 | 2d | 3 | 5 |
| META CEREBRAL | adulto | 0 | 3D | 12 | 19 |
| META CEREBRAL | adulto | 0 | VMAT | 18 | 22 |
| META CEREBRAL | ped | 0 | 2d | 1 | 1 |
| META CEREBRAL | ped | 0 | 3D | 13 | 17 |
| META OSSEA | adulto | 0 | 2d | 2 | 4 |
| META OSSEA | adulto | 0 | 3D | 11 | 17 |
| META OSSEA | adulto | 0 | ELETRONS | 10 | 16 |
| META OSSEA | adulto | 0 | VMAT | 14 | 21 |
| META OSSEA | adulto | 1 | 3D | 6 | 10 |
| META OSSEA | ped | 0 | 2d | 4 | 6 |
| META OSSEA | ped | 0 | 3D | 19 | 20 |
| META SRS | adulto | 0 | 3D | 15 | 22 |
| META SRS | adulto | 0 | 3D REF | 14 | 20 |
| META SRS | adulto | 0 | 3D SRS | 11 | 17 |
| META SRS | adulto | 0 | IMRT REF | 16 | 23 |
| META SRS | adulto | 0 | IMRT SRS | 11 | 17 |
| META SRS | adulto | 0 | VMAT | 19 | 21 |
| META SRS | adulto | 1 | 3D SRS | 19 | 32 |
| META SRS | adulto | 1 | IMRT REF | 9 | 14 |
| META TORAX | adulto | 0 | 3D | 13 | 20 |
| METASTASE | adulto | 0 | 3D | 9 | 13 |
| METASTASE | adulto | 0 | 3D REF | 14 | 23 |
| METASTASE | adulto | 0 | IMRT REF | 19 | 28 |
| MOLES | adulto | 0 | 3D | 14 | 21 |
| MOLES | adulto | 0 | ELETRONS | 13 | 13 |
| MOLES | adulto | 0 | VMAT | 24 | 32 |
| MOLES | ped | 0 | 3D | 8 | 10 |
| MOLES | ped | 0 | IMRT | 17 | 19 |

| Grupo | Faixa etária | CONVÊNIO | Técnica | IC (68%) | Continuação |
|-----------------------|--------------|----------|----------|----------|-------------|
| | | | | | IC (95%) |
| PELVE reto/canal anal | adulto | 0 | 3D | 10 | 14 |
| PELVE reto/canal anal | adulto | 0 | VMAT | 17 | 19 |
| SKIN | adulto | 0 | 3D | 13 | 19 |
| SKIN | adulto | 0 | ELETRONS | 18 | 28 |
| SKIN | adulto | 0 | IMRT | 20 | 28 |
| SKIN | adulto | 0 | VMAT | 20 | 28 |
| SN | adulto | 0 | 3D | 16 | 23 |
| SN | adulto | 0 | 3D REF | 17 | 21 |
| SN | adulto | 0 | IMRT | 17 | 23 |
| SN | adulto | 0 | IMRT REF | 12 | 16 |
| SN | adulto | 0 | VMAT | 17 | 23 |
| SN | adulto | 1 | IMRT | 18 | 23 |
| SN | ped | 0 | 3D | 19 | 25 |
| SN | ped | 0 | IMRT | 17 | 25 |
| SN | ped | 0 | VMAT | 17 | 24 |
| SN Craniofaringioma | adulto | 0 | 3D | 19 | 21 |
| SN Craniofaringioma | adulto | 0 | IMRT | 19 | 22 |
| SN Hipófise | adulto | 0 | 3D | 17 | 25 |
| SN Hipófise | adulto | 0 | IMRT | 17 | 23 |
| SN Hipófise | adulto | 1 | IMRT | 17 | 23 |
| SN NEURINOMA | adulto | 0 | 3D | 12 | 20 |
| SN NEURINOMA | adulto | 0 | IMRT | 23 | 34 |
| SN Schwannoma | adulto | 0 | 3D | 15 | 20 |
| SN Schwannoma | adulto | 0 | IMRT | 22 | 31 |
| SN-MENINGIOMAS | adulto | 0 | 3D | 20 | 29 |
| SN-MENINGIOMAS | adulto | 0 | IMRT | 21 | 29 |
| SN-MENINGIOMAS | adulto | 0 | VMAT | 17 | 21 |
| SN-MENINGIOMAS | adulto | 1 | 3D | 4 | 6 |
| SRS Hipófise | adulto | 0 | 3D SRS | 10 | 14 |
| SRS Hipófise | adulto | 0 | IMRT SRS | 12 | 16 |
| SRS MAV | adulto | 0 | 3D | 14 | 23 |
| SRS MAV | adulto | 0 | 3D REF | 17 | 21 |
| SRS MAV | adulto | 0 | 3D SRS | 11 | 16 |
| SRS MAV | adulto | 0 | IMRT REF | 27 | 35 |
| SRS MAV | adulto | 0 | IMRT SRS | 17 | 26 |
| SRS MAV | ped | 0 | 3D SRS | 7 | 9 |
| SRS NEURINOMA | adulto | 0 | 3D REF | 18 | 28 |
| SRS NEURINOMA | adulto | 0 | 3D SRS | 23 | 40 |
| SRS NEURINOMA | adulto | 0 | IMRT REF | 11 | 13 |
| SRS-MENINGIOMAS | adulto | 0 | 3D REF | 14 | 17 |

| Grupo | Faixa etária | CONVÊNIO | Técnica | IC (68%) | Continuação |
|-----------------|--------------|----------|----------|----------|-------------|
| | | | | | IC (95%) |
| SRS-MENINGIOMAS | adulto | 0 | 3D SRS | 13 | 17 |
| SRS-Schwannoma | adulto | 0 | 3D REF | 13 | 14 |
| SRS-Schwannoma | adulto | 0 | 3D SRS | 11 | 17 |
| SRS-Schwannoma | adulto | 0 | IMRT REF | 19 | 27 |
| SRS-Schwannoma | adulto | 0 | IMRT SRS | 11 | 15 |
| TBI | adulto | 0 | TBI | 3 | 4 |
| TBI | adulto | 1 | TBI | 7 | 13 |
| TBI | ped | 0 | TBI | 1 | 2 |
| Torax | adulto | 0 | 3D | 14 | 20 |
| Torax | adulto | 0 | IMRT | 18 | 26 |
| Torax | adulto | 0 | VMAT | 15 | 17 |
| Torax | adulto | 1 | 3D | 6 | 12 |
| Torax | ped | 0 | 3D | 9 | 12 |
| Torax | ped | 0 | IMRT | 22 | 23 |
| Torax | ped | 0 | VMAT | 20 | 31 |
| URO | adulto | 0 | 3D | 15 | 24 |
| URO | adulto | 0 | IMRT | 14 | 22 |
| URO | adulto | 0 | VMAT | 16 | 22 |
| URO | adulto | 1 | 3D | 14 | 25 |
| URO | ped | 0 | 3D | 8 | 11 |
| URO | ped | 0 | VMAT | 22 | 30 |
| URO prostata | adulto | 0 | 3D | 14 | 19 |
| URO prostata | adulto | 0 | IMRT | 20 | 27 |
| URO prostata | adulto | 0 | VMAT | 17 | 24 |
| URO prostata | adulto | 1 | 3D | 11 | 15 |
| URO prostata | adulto | 1 | IMRT | 19 | 31 |
| URO prostata | adulto | 1 | VMAT | 15 | 22 |
| bone pelve | adulto | 0 | 2d | 1 | 2 |
| bone pelve | adulto | 0 | 3D | 10 | 15 |
| mama/fsc | adulto | 0 | 2d | 3 | 6 |
| mama/fsc | adulto | 0 | 3D | 14 | 19 |
| mama/fsc | adulto | 0 | ELETRONS | 14 | 21 |
| mama/fsc | adulto | 0 | IMRT | 21 | 28 |
| mama/fsc | adulto | 0 | VMAT | 21 | 24 |
| mama/fsc | adulto | 1 | 3D | 9 | 13 |
| mama/fsc | ped | 0 | IMRT | 15 | 20 |

APÊNDICE D- Regiões que compõem cada grupo de prioridade.

| Região | Pontuação | Prioridade |
|--|-----------|------------|
| Paliativos outros (hemostática, anti-álgica) | 38 | 5 |
| metástases cerebrais (C793) | 29 | 4 |
| Osso (C795) | 25,5 | 4 |
| Laringe | 24 | 4 |
| Glioma de alto grau | 23,5 | 4 |
| Faringe | 22,5 | 4 |
| Pulmão | 22,5 | 4 |
| Células germinativas/germinomas | 22,5 | 4 |
| Cavidades Nasais e Para-Nasais | 22 | 4 |
| Cólon e Reto | 22 | 4 |
| Neuroectodármico primitivo/Meduloblastomas | 21,5 | 4 |
| Lábio e Cavidade Oral | 21 | 4 |
| Canal Anal | 21 | 4 |
| Colo Uterino | 21 | 4 |
| Melanoma Maligno do Trato Aerodigestivo Superior | 20,5 | 3 |
| Glândula Tireoide | 20 | 3 |
| Esôfago | 20 | 3 |
| Orbita/Retina/Conjuntiva/glandula lacrimal | 20 | 3 |
| mieloma múltiplo | 19,5 | 3 |
| Partes Moles (Sarcomas)/RMA/Osteo/Ewing | 19,5 | 3 |
| Duodeno/Ampola de Vater | 19 | 3 |
| Linfomas não Hodgkin | 19 | 3 |
| Leucemias | 19 | 3 |
| Mesotelioma Pleural | 18,5 | 2 |
| Pênis | 18,5 | 2 |

| Continuação | | |
|-------------------------------|------------------|-------------------|
| Região | Pontuação | Prioridade |
| Uretra | 18,5 | 2 |
| Linfoma de Hodgkin | 18,5 | 2 |
| Glândulas Salivares | 18 | 2 |
| Pâncreas | 18 | 2 |
| Corpo Uterino | 18 | 2 |
| Estômago | 17,5 | 2 |
| Vesícula Biliar/Vias biliares | 17,5 | 2 |
| Vulva | 17,5 | 2 |
| Vagina | 17,5 | 2 |
| Testículo | 17,5 | 2 |
| Rim/pelve renal/ureter | 17,5 | 2 |
| Craniofaringiomas | 17,5 | 2 |
| Pele/pálpebra | 17 | 2 |
| Mama | 17 | 2 |
| Bexiga Urinária | 17 | 2 |
| Ovário, anexos | 16 | 2 |
| plasmocitoma solitário | 15,5 | 1 |
| Timoma | 15 | 1 |
| Fígado | 14,5 | 1 |
| Prostata | 14 | 1 |
| Glioma de baixo grau | 14 | 1 |
| Adenomas de hipófise | 12,5 | 1 |
| Malformações Arteriovenosas | 12,5 | 1 |
| Schwannoma Vestibular | 12 | 1 |
| Meningioma | 11,5 | 1 |

APÊNDICE E – Tempo de tratamento de referência

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Tempo (min) |
|-------|----------|---|-----------|--------------|-------------------|-------------|
| ABD | 2d | 1 | 0 | 0 | 100 | 38 |
| ABD | 2d | 1 | 0 | 0 | 300 | 31 |
| ABD | 2d | 1 | 0 | 0 | 400 | 12 |
| ABD | 2d | 1 | 0 | 0 | 500 | 13 |
| ABD | 2d | 2 | 0 | 0 | 1200 | 39 |
| ABD | 2d | 2 | 0 | 0 | 800 | 62 |
| ABD | 2d | 3 | 0 | 0 | 1700 | 22 |
| ABD | 2d | 3 | 0 | 0 | 400 | 27 |
| ABD | 2d | 3 | 0 | 0 | 1200 | 32 |
| ABD | 2d | 7 | 0 | 0 | 400 | 52 |
| ABD | 3D | 1 | 0 | 0 | 150 | 19 |
| ABD | 3D | 1 | 0 | 0 | 180 | 13 |
| ABD | 3D | 1 | 0 | 0 | 200 | 16 |
| ABD | 3D | 1 | 0 | 0 | 250 | 16 |
| ABD | 3D | 1 | 0 | 0 | 300 | 16 |
| ABD | 3D | 1 | 0 | 0 | 400 | 12 |
| ABD | 3D | 1 | 0 | 0 | 600 | 10 |
| ABD | 3D | 1 | 0 | 1 | 150 | 12 |
| ABD | 3D | 1 | 0 | 1 | 180 | 14 |
| ABD | 3D | 1 | 0 | 1 | 300 | 36 |
| ABD | 3D | 1 | 1 | 0 | 150 | 13 |
| ABD | 3D | 1 | 1 | 0 | 180 | 19 |
| ABD | 3D | 1 | 1 | 1 | 150 | 15 |
| ABD | 3D | 1 | 1 | 1 | 180 | 16 |
| ABD | 3D | 2 | 0 | 0 | 150 | 40 |
| ABD | 3D | 2 | 0 | 0 | 180 | 19 |
| ABD | 3D | 2 | 0 | 0 | 300 | 13 |
| ABD | 3D | 2 | 0 | 0 | 360 | 22 |
| ABD | 3D | 2 | 0 | 1 | 150 | 28 |
| ABD | 3D | 3 | 0 | 0 | 180 | 29 |
| ABD | 3D | 3 | 0 | 1 | 150 | 47 |
| ABD | 3D | 4 | 0 | 1 | 150 | 26 |
| ABD | ELETRONS | 1 | 0 | 0 | 180 | 25 |
| ABD | ELETRONS | 1 | 0 | 0 | 200 | 10 |
| ABD | ELETRONS | 1 | 0 | 0 | 300 | 20 |
| ABD | ELETRONS | 2 | 0 | 0 | 300 | 42 |
| ABD | IMRT | 1 | 0 | 0 | 150 | 32 |
| ABD | IMRT | 1 | 0 | 0 | 180 | 19 |
| ABD | IMRT | 1 | 0 | 0 | 200 | 16 |
| ABD | IMRT | 1 | 1 | 0 | 150 | 20 |
| ABD | IMRT | 2 | 0 | 0 | 180 | 32 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|-------------|------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| ABD | VMAT | 1 | 0 | 0 | 150 | 28 |
| ABD | VMAT | 1 | 0 | 0 | 180 | 19 |
| ABD | VMAT | 1 | 0 | 0 | 200 | 18 |
| ABD | VMAT | 1 | 0 | 0 | 300 | 17 |
| ABD | VMAT | 1 | 1 | 0 | 150 | 19 |
| ABD | VMAT | 2 | 0 | 0 | 150 | 41 |
| ARTICULACAO | 2d | 1 | 0 | 0 | 300 | 10 |
| ARTICULACAO | 3D | 1 | 0 | 0 | 100 | 28 |
| ARTICULACAO | 3D | 1 | 0 | 0 | 150 | 55 |
| ARTICULACAO | 3D | 1 | 0 | 0 | 180 | 15 |
| ARTICULACAO | 3D | 1 | 0 | 0 | 200 | 17 |
| ARTICULACAO | 3D | 1 | 0 | 1 | 200 | 12 |
| ARTICULACAO | 3D | 1 | 1 | 0 | 150 | 16 |
| ARTICULACAO | 3D | 2 | 1 | 0 | 300 | 13 |
| ARTICULACAO | IMRT | 1 | 0 | 0 | 180 | 22 |
| ARTICULACAO | IMRT | 1 | 0 | 0 | 200 | 34 |
| ARTICULACAO | VMAT | 1 | 0 | 0 | 150 | 31 |
| ARTICULACAO | VMAT | 1 | 0 | 0 | 180 | 17 |
| ARTICULACAO | VMAT | 1 | 0 | 0 | 200 | 10 |
| ARTICULACAO | VMAT | 1 | 0 | 0 | 212 | 12 |
| ARTICULACAO | VMAT | 1 | 1 | 0 | 180 | 17 |
| BONE | 3D | 1 | 0 | 0 | 180 | 15 |
| BONE | 3D | 1 | 0 | 0 | 200 | 12 |
| BONE | 3D | 1 | 0 | 0 | 300 | 20 |
| BONE | 3D | 1 | 0 | 1 | 250 | 13 |
| BONE | 3D | 2 | 0 | 0 | 150 | 17 |
| BONE | 3D | 2 | 0 | 0 | 180 | 16 |
| BONE | 3D | 2 | 0 | 0 | 250 | 22 |
| BONE | 3D | 2 | 0 | 0 | 360 | 13 |
| BONE | 3D | 3 | 0 | 0 | 360 | 31 |
| BONE | 3D | 3 | 0 | 0 | 540 | 39 |
| BONE | IMRT | 1 | 0 | 0 | 180 | 31 |
| BONE | IMRT | 1 | 0 | 0 | 200 | 36 |
| BONE | IMRT | 1 | 1 | 0 | 180 | 28 |
| BONE | VMAT | 1 | 0 | 0 | 180 | 20 |
| BONE | VMAT | 1 | 0 | 0 | 200 | 14 |
| BONE | VMAT | 3 | 0 | 0 | 180 | 31 |
| bone pelve | 2d | 1 | 0 | 0 | 200 | 9 |
| bone pelve | 2d | 1 | 0 | 0 | 300 | 10 |
| bone pelve | 2d | 1 | 0 | 0 | 400 | 9 |
| bone pelve | 2d | 1 | 0 | 1 | 300 | 13 |
| bone pelve | 2d | 1 | 0 | 1 | 400 | 16 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|------------|------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| bone pelve | 2d | 2 | 0 | 0 | 250 | 44 |
| bone pelve | 2d | 2 | 0 | 0 | 300 | 16 |
| bone pelve | 2d | 2 | 0 | 0 | 800 | 24 |
| bone pelve | 2d | 2 | 0 | 1 | 250 | 18 |
| bone pelve | 2d | 2 | 0 | 1 | 400 | 39 |
| bone pelve | 2d | 3 | 0 | 0 | 300 | 21 |
| bone pelve | 2d | 3 | 0 | 1 | 300 | 25 |
| bone pelve | 2d | 4 | 1 | 0 | 200 | 42 |
| bone pelve | 3D | 1 | 0 | 0 | 180 | 22 |
| bone pelve | 3D | 1 | 0 | 0 | 200 | 16 |
| bone pelve | 3D | 1 | 0 | 0 | 240 | 15 |
| bone pelve | 3D | 1 | 0 | 0 | 250 | 18 |
| bone pelve | 3D | 1 | 0 | 0 | 300 | 11 |
| bone pelve | 3D | 1 | 0 | 0 | 400 | 26 |
| bone pelve | 3D | 1 | 0 | 1 | 300 | 13 |
| bone pelve | 3D | 1 | 0 | 1 | 400 | 50 |
| bone pelve | 3D | 2 | 0 | 0 | 300 | 26 |
| bone pelve | 3D | 3 | 0 | 0 | 300 | 28 |
| bone pelve | 3D | 3 | 0 | 1 | 300 | 56 |
| bone pelve | VMAT | 1 | 1 | 0 | 180 | 30 |
| CP | 2d | 1 | 0 | 0 | 200 | 7 |
| CP | 2d | 1 | 0 | 0 | 300 | 30 |
| CP | 2d | 1 | 0 | 0 | 400 | 20 |
| CP | 2d | 1 | 0 | 1 | 300 | 58 |
| CP | 2d | 2 | 0 | 0 | 300 | 17 |
| CP | 2d | 3 | 0 | 0 | 1200 | 34 |
| CP | 2d | 5 | 0 | 0 | 200 | 36 |
| CP | 3D | 1 | 0 | 0 | 180 | 13 |
| CP | 3D | 1 | 0 | 0 | 200 | 14 |
| CP | 3D | 1 | 0 | 0 | 201 | 13 |
| CP | 3D | 1 | 0 | 0 | 240 | 14 |
| CP | 3D | 1 | 0 | 0 | 250 | 17 |
| CP | 3D | 1 | 0 | 0 | 300 | 14 |
| CP | 3D | 1 | 0 | 1 | 180 | 16 |
| CP | 3D | 1 | 0 | 1 | 200 | 28 |
| CP | 3D | 1 | 0 | 1 | 250 | 18 |
| CP | 3D | 1 | 0 | 1 | 300 | 21 |
| CP | 3D | 1 | 0 | 1 | 400 | 110 |
| CP | 3D | 1 | 0 | 1 | 500 | 22 |
| CP | 3D | 1 | 1 | 1 | 180 | 12 |
| CP | 3D | 2 | 0 | 0 | 150 | 19 |
| CP | 3D | 2 | 0 | 0 | 180 | 18 |
| CP | 3D | 2 | 0 | 0 | 200 | 14 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|-------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| CP | 3D | 2 | 0 | 0 | 250 | 17 |
| CP | 3D | 2 | 0 | 0 | 300 | 15 |
| CP | 3D | 2 | 0 | 0 | 360 | 14 |
| CP | 3D | 2 | 0 | 0 | 400 | 15 |
| CP | 3D | 2 | 0 | 0 | 500 | 22 |
| CP | 3D | 2 | 0 | 0 | 600 | 16 |
| CP | 3D | 2 | 0 | 0 | 800 | 46 |
| CP | 3D | 2 | 0 | 1 | 180 | 16 |
| CP | 3D | 2 | 1 | 0 | 180 | 40 |
| CP | 3D | 3 | 0 | 0 | 400 | 36 |
| CP | 3D | 3 | 0 | 0 | 180 | 22 |
| CP | 3D | 3 | 0 | 0 | 200 | 20 |
| CP | 3D | 3 | 0 | 0 | 270 | 54 |
| CP | 3D | 3 | 0 | 0 | 300 | 39 |
| CP | 3D | 3 | 1 | 0 | 180 | 53 |
| CP | 3D | 4 | 0 | 0 | 150 | 26 |
| CP | 3D | 4 | 0 | 0 | 180 | 23 |
| CP | 3D | 4 | 0 | 0 | 200 | 20 |
| CP | 3D | 4 | 0 | 0 | 360 | 22 |
| CP | 3D | 6 | 0 | 0 | 180 | 30 |
| CP | ELETRONS | 1 | 0 | 0 | 200 | 12 |
| CP | ELETRONS | 1 | 0 | 0 | 250 | 8 |
| CP | ELETRONS | 1 | 0 | 0 | 267 | 82 |
| CP | ELETRONS | 1 | 0 | 0 | 300 | 13 |
| CP | ELETRONS | 2 | 0 | 0 | 200 | 13 |
| CP | ELETRONS | 2 | 0 | 0 | 250 | 15 |
| CP | ELETRONS | 2 | 0 | 0 | 360 | 14 |
| CP | ELETRONS | 3 | 0 | 0 | 400 | 21 |
| CP | ELETRONS | 5 | 0 | 0 | 450 | 34 |
| CP | IMRT | 1 | 0 | 0 | 150 | 17 |
| CP | IMRT | 1 | 0 | 0 | 180 | 17 |
| CP | IMRT | 1 | 0 | 0 | 200 | 17 |
| CP | IMRT | 1 | 0 | 0 | 250 | 25 |
| CP | IMRT | 1 | 0 | 0 | 300 | 22 |
| CP | IMRT | 2 | 0 | 0 | 180 | 32 |
| CP | IMRT | 2 | 0 | 0 | 212 | 20 |
| CP | IMRT | 3 | 0 | 0 | 180 | 39 |
| CP | IMRT REF | 1 | 0 | 0 | 500 | 70 |
| CP | IMRT REF | 2 | 0 | 0 | 500 | 52 |
| CP | VMAT | 1 | 0 | 0 | 180 | 16 |
| CP | VMAT | 1 | 0 | 0 | 182 | 14 |
| CP | VMAT | 1 | 0 | 0 | 200 | 13 |
| CP | VMAT | 1 | 0 | 0 | 206 | 14 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|--------------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| CP | VMAT | 1 | 0 | 0 | 212 | 15 |
| CP | VMAT | 1 | 0 | 0 | 213 | 18 |
| CP | VMAT | 1 | 0 | 0 | 250 | 14 |
| CP | VMAT | 1 | 0 | 0 | 300 | 18 |
| CP | VMAT | 1 | 1 | 0 | 180 | 33 |
| CP | VMAT | 2 | 0 | 0 | 180 | 20 |
| CP faringe | 3D | 1 | 0 | 0 | 200 | 11 |
| CP faringe | 3D | 1 | 0 | 0 | 250 | 12 |
| CP faringe | 3D | 1 | 0 | 0 | 300 | 36 |
| CP faringe | 3D | 1 | 0 | 1 | 250 | 20 |
| CP faringe | IMRT | 1 | 0 | 0 | 180 | 18 |
| CP faringe | IMRT | 1 | 0 | 0 | 200 | 20 |
| CP faringe | VMAT | 1 | 0 | 0 | 180 | 16 |
| CP faringe | VMAT | 1 | 0 | 0 | 200 | 16 |
| CP faringe | VMAT | 1 | 0 | 0 | 212 | 15 |
| CP laringe | 3D | 1 | 0 | 0 | 200 | 13 |
| CP laringe | 3D | 1 | 0 | 0 | 220 | 10 |
| CP laringe | 3D | 1 | 0 | 0 | 225 | 12 |
| CP laringe | 3D | 1 | 0 | 0 | 250 | 9 |
| CP laringe | 3D | 1 | 0 | 0 | 300 | 9 |
| CP laringe | 3D | 1 | 0 | 1 | 300 | 14 |
| CP laringe | 3D | 1 | 0 | 1 | 500 | 22 |
| CP laringe | 3D | 2 | 0 | 0 | 425 | 32 |
| CP laringe | 3D | 2 | 0 | 0 | 200 | 14 |
| CP laringe | 3D | 2 | 0 | 0 | 400 | 12 |
| CP laringe | 3D | 2 | 0 | 0 | 425 | 25 |
| CP laringe | 3D | 3 | 0 | 0 | 200 | 16 |
| CP laringe | ELETRONS | 2 | 0 | 0 | 400 | 13 |
| CP laringe | ELETRONS | 2 | 0 | 0 | 200 | 14 |
| CP laringe | ELETRONS | 2 | 0 | 0 | 400 | 17 |
| CP laringe | ELETRONS | 3 | 0 | 0 | 400 | 17 |
| CP laringe | IMRT | 1 | 0 | 0 | 200 | 14 |
| CP laringe | VMAT | 1 | 0 | 0 | 180 | 11 |
| CP laringe | VMAT | 1 | 0 | 0 | 200 | 15 |
| CP laringe | VMAT | 1 | 0 | 0 | 212 | 14 |
| CP laringe | VMAT | 1 | 0 | 0 | 225 | 13 |
| CP naso/orofaringe | 2d | 1 | 0 | 0 | 300 | 9 |
| CP naso/orofaringe | 2d | 2 | 0 | 0 | 400 | 19 |
| CP naso/orofaringe | 3D | 1 | 0 | 0 | 189 | 24 |
| CP naso/orofaringe | 3D | 1 | 0 | 0 | 200 | 14 |
| CP naso/orofaringe | 3D | 1 | 0 | 0 | 250 | 16 |
| CP naso/orofaringe | 3D | 1 | 0 | 0 | 300 | 15 |
| CP naso/orofaringe | 3D | 1 | 0 | 1 | 250 | 15 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|--------------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| CP naso/orofaringe | 3D | 1 | 0 | 1 | 300 | 28 |
| CP naso/orofaringe | 3D | 2 | 0 | 0 | 200 | 12 |
| CP naso/orofaringe | 3D | 2 | 0 | 0 | 400 | 11 |
| CP naso/orofaringe | 3D | 3 | 0 | 0 | 200 | 18 |
| CP naso/orofaringe | 3D | 4 | 0 | 0 | 200 | 27 |
| CP naso/orofaringe | ELETRONS | 1 | 0 | 0 | 200 | 14 |
| CP naso/orofaringe | ELETRONS | 2 | 0 | 0 | 200 | 13 |
| CP naso/orofaringe | ELETRONS | 2 | 0 | 0 | 400 | 10 |
| CP naso/orofaringe | ELETRONS | 3 | 0 | 0 | 400 | 18 |
| CP naso/orofaringe | ELETRONS | 4 | 0 | 0 | 400 | 27 |
| CP naso/orofaringe | IMRT | 1 | 0 | 0 | 180 | 18 |
| CP naso/orofaringe | IMRT | 1 | 0 | 0 | 200 | 18 |
| CP naso/orofaringe | IMRT | 1 | 0 | 0 | 212 | 23 |
| CP naso/orofaringe | IMRT | 1 | 0 | 0 | 250 | 19 |
| CP naso/orofaringe | VMAT | 1 | 0 | 0 | 180 | 15 |
| CP naso/orofaringe | VMAT | 1 | 0 | 0 | 200 | 15 |
| CP naso/orofaringe | VMAT | 1 | 0 | 0 | 212 | 16 |
| EPITELIAIS | 3D | 2 | 0 | 0 | 800 | 18 |
| EPITELIAIS | IMRT | 1 | 0 | 0 | 180 | 62 |
| ESOFAGO | 3D | 1 | 0 | 0 | 179 | 70 |
| ESOFAGO | 3D | 1 | 0 | 0 | 180 | 11 |
| ESOFAGO | 3D | 1 | 0 | 0 | 200 | 14 |
| ESOFAGO | 3D | 1 | 0 | 0 | 300 | 13 |
| ESOFAGO | 3D | 1 | 0 | 0 | 360 | 8 |
| ESOFAGO | 3D | 1 | 0 | 0 | 400 | 19 |
| ESOFAGO | 3D | 1 | 0 | 1 | 300 | 18 |
| ESOFAGO | 3D | 1 | 0 | 1 | 400 | 26 |
| ESOFAGO | 3D | 2 | 0 | 0 | 300 | 19 |
| ESOFAGO | 3D | 2 | 0 | 0 | 360 | 14 |
| ESOFAGO | IMRT | 1 | 0 | 0 | 180 | 19 |
| ESOFAGO | IMRT | 1 | 0 | 0 | 200 | 14 |
| Figado | 3D | 1 | 0 | 0 | 150 | 15 |
| Figado | 3D | 2 | 0 | 0 | 400 | 20 |
| Figado | IMRT | 1 | 0 | 0 | 180 | 12 |
| Figado | VMAT | 1 | 0 | 0 | 216 | 41 |
| Figado | VMAT | 1 | 1 | 0 | 150 | 29 |
| GINECO | 2d | 1 | 0 | 0 | 400 | 27 |
| GINECO | 3D | 1 | 0 | 0 | 180 | 13 |
| GINECO | 3D | 1 | 0 | 0 | 200 | 15 |
| GINECO | 3D | 2 | 0 | 0 | 180 | 25 |
| GINECO | 3D | 2 | 0 | 0 | 200 | 25 |
| GINECO | 3D REF | 2 | 0 | 0 | 1000 | 33 |
| GINECO | ELETRONS | 2 | 0 | 0 | 180 | 25 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|----------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| GINECO | IMRT | 1 | 0 | 0 | 180 | 20 |
| GINECO | VMAT | 1 | 0 | 0 | 180 | 22 |
| GINECO | VMAT | 2 | 0 | 0 | 216 | 26 |
| GLAND | 2d | 1 | 0 | 0 | 200 | 46 |
| GLAND | 2d | 4 | 0 | 0 | 800 | 35 |
| GLAND | 3D | 1 | 0 | 0 | 180 | 30 |
| GLAND | 3D | 1 | 0 | 0 | 200 | 14 |
| GLAND | 3D | 1 | 0 | 1 | 300 | 18 |
| GLAND | 3D | 1 | 1 | 1 | 150 | 26 |
| GLAND | 3D | 2 | 0 | 0 | 300 | 22 |
| GLAND | 3D | 2 | 0 | 0 | 360 | 19 |
| GLAND | 3D | 2 | 0 | 1 | 150 | 28 |
| GLAND | ELETRONS | 4 | 0 | 0 | 400 | 20 |
| GLAND | IMRT | 1 | 0 | 0 | 180 | 24 |
| GLAND | IMRT | 1 | 1 | 0 | 180 | 42 |
| GLAND | VMAT | 1 | 0 | 0 | 150 | 13 |
| GLAND | VMAT | 1 | 0 | 0 | 180 | 13 |
| GLAND | VMAT | 1 | 0 | 0 | 200 | 14 |
| GLAND | VMAT | 1 | 1 | 0 | 180 | 43 |
| GLAND | VMAT | 1 | 1 | 0 | 500 | 41 |
| HEMATO | 2d | 1 | 0 | 0 | 100 | 11 |
| HEMATO | 2d | 1 | 0 | 0 | 200 | 10 |
| HEMATO | 3D | 1 | 0 | 0 | 150 | 23 |
| HEMATO | 3D | 1 | 0 | 0 | 180 | 18 |
| HEMATO | 3D | 1 | 0 | 0 | 200 | 15 |
| HEMATO | 3D | 1 | 0 | 0 | 250 | 8 |
| HEMATO | 3D | 1 | 0 | 1 | 100 | 57 |
| HEMATO | 3D | 1 | 0 | 1 | 150 | 14 |
| HEMATO | 3D | 1 | 0 | 1 | 180 | 8 |
| HEMATO | 3D | 1 | 0 | 1 | 200 | 17 |
| HEMATO | 3D | 1 | 1 | 0 | 150 | 24 |
| HEMATO | 3D | 2 | 0 | 0 | 600 | 28 |
| HEMATO | 3D | 4 | 0 | 0 | 400 | 49 |
| HEMATO | ELETRONS | 1 | 0 | 0 | 200 | 9 |
| HEMATO | IMRT | 1 | 0 | 0 | 180 | 18 |
| HEMATO | IMRT | 1 | 0 | 0 | 200 | 18 |
| HEMATO | TBI | 1 | 0 | 0 | 100 | 11 |
| HEMATO | TBI | 2 | 0 | 0 | 200 | 16 |
| HEMATO | TBI | 2 | 0 | 1 | 100 | 86 |
| HEMATO | TBI | 2 | 0 | 1 | 200 | 99 |
| HEMATO | VMAT | 1 | 0 | 0 | 180 | 11 |
| HEMATO | VMAT | 1 | 0 | 0 | 300 | 13 |
| LYMPHOMA | 2d | 1 | 0 | 0 | 180 | 7 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| LYMPHOMA | 2d | 1 | 0 | 0 | 200 | 14 |
| LYMPHOMA | 2d | 5 | 0 | 0 | 800 | 36 |
| LYMPHOMA | 3D | 1 | 0 | 0 | 150 | 18 |
| LYMPHOMA | 3D | 1 | 0 | 0 | 180 | 13 |
| LYMPHOMA | 3D | 1 | 0 | 0 | 200 | 14 |
| LYMPHOMA | 3D | 1 | 0 | 1 | 180 | 18 |
| LYMPHOMA | 3D | 2 | 0 | 0 | 150 | 30 |
| LYMPHOMA | 3D | 2 | 0 | 0 | 180 | 18 |
| LYMPHOMA | 3D | 2 | 0 | 0 | 200 | 17 |
| LYMPHOMA | 3D | 2 | 0 | 0 | 250 | 23 |
| LYMPHOMA | 3D | 2 | 0 | 0 | 300 | 20 |
| LYMPHOMA | 3D | 2 | 0 | 0 | 349 | 24 |
| LYMPHOMA | 3D | 2 | 0 | 0 | 360 | 17 |
| LYMPHOMA | 3D | 2 | 0 | 0 | 400 | 19 |
| LYMPHOMA | 3D | 3 | 0 | 0 | 90 | 54 |
| LYMPHOMA | 3D | 3 | 0 | 0 | 180 | 28 |
| LYMPHOMA | 3D | 3 | 0 | 0 | 200 | 39 |
| LYMPHOMA | 3D | 3 | 0 | 0 | 360 | 21 |
| LYMPHOMA | 3D | 4 | 0 | 0 | 360 | 28 |
| LYMPHOMA | 3D | 5 | 0 | 0 | 150 | 34 |
| LYMPHOMA | 3D | 6 | 0 | 0 | 720 | 30 |
| LYMPHOMA | ELETRONS | 1 | 0 | 0 | 180 | 9 |
| LYMPHOMA | ELETRONS | 1 | 0 | 0 | 200 | 6 |
| LYMPHOMA | ELETRONS | 2 | 0 | 0 | 180 | 24 |
| LYMPHOMA | ELETRONS | 2 | 0 | 0 | 200 | 17 |
| LYMPHOMA | ELETRONS | 3 | 0 | 0 | 180 | 20 |
| LYMPHOMA | ELETRONS | 5 | 0 | 0 | 150 | 34 |
| LYMPHOMA | IMRT | 1 | 0 | 0 | 180 | 21 |
| LYMPHOMA | IMRT | 1 | 0 | 0 | 182 | 20 |
| LYMPHOMA | IMRT | 1 | 0 | 0 | 200 | 22 |
| LYMPHOMA | IMRT | 1 | 0 | 0 | 240 | 27 |
| LYMPHOMA | IMRT | 2 | 0 | 0 | 180 | 33 |
| LYMPHOMA | VMAT | 1 | 0 | 0 | 150 | 15 |
| LYMPHOMA | VMAT | 1 | 0 | 0 | 180 | 15 |
| LYMPHOMA | VMAT | 1 | 0 | 0 | 200 | 17 |
| MAFORMACAO | 3D | 1 | 0 | 0 | 180 | 11 |
| MAFORMACAO | IMRT REF | 1 | 0 | 0 | 500 | 26 |
| mama/fsc | 2d | 1 | 0 | 0 | 300 | 13 |
| mama/fsc | 2d | 1 | 0 | 0 | 400 | 21 |
| mama/fsc | 2d | 1 | 0 | 1 | 300 | 27 |
| mama/fsc | 2d | 2 | 0 | 0 | 534 | 14 |
| mama/fsc | 2d | 2 | 0 | 0 | 800 | 39 |
| mama/fsc | 2d | 2 | 0 | 0 | 1200 | 20 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|----------|-----|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| mama/fsc | 2d | 3 | 0 | 0 | 1200 | 73 |
| mama/fsc | 2d | 4 | 0 | 0 | 800 | 35 |
| mama/fsc | 2d | 5 | 0 | 0 | 800 | 38 |
| mama/fsc | 2d | 7 | 0 | 0 | 1600 | 52 |
| mama/fsc | 3D | 1 | 0 | 0 | 180 | 13 |
| mama/fsc | 3D | 1 | 0 | 0 | 200 | 12 |
| mama/fsc | 3D | 1 | 0 | 0 | 240 | 14 |
| mama/fsc | 3D | 1 | 0 | 0 | 250 | 35 |
| mama/fsc | 3D | 1 | 0 | 0 | 265 | 18 |
| mama/fsc | 3D | 1 | 0 | 0 | 267 | 13 |
| mama/fsc | 3D | 1 | 0 | 0 | 300 | 16 |
| mama/fsc | 3D | 1 | 0 | 0 | 400 | 14 |
| mama/fsc | 3D | 1 | 0 | 0 | 500 | 21 |
| mama/fsc | 3D | 1 | 0 | 0 | 520 | 16 |
| mama/fsc | 3D | 1 | 0 | 0 | 533 | 15 |
| mama/fsc | 3D | 1 | 0 | 0 | 534 | 27 |
| mama/fsc | 3D | 1 | 0 | 0 | 570 | 24 |
| mama/fsc | 3D | 1 | 0 | 0 | 600 | 44 |
| mama/fsc | 3D | 1 | 0 | 1 | 200 | 17 |
| mama/fsc | 3D | 1 | 0 | 1 | 250 | 25 |
| mama/fsc | 3D | 1 | 0 | 1 | 267 | 10 |
| mama/fsc | 3D | 1 | 0 | 1 | 300 | 18 |
| mama/fsc | 3D | 2 | 0 | 0 | 400 | 18 |
| mama/fsc | 3D | 2 | 0 | 0 | 534 | 20 |
| mama/fsc | 3D | 2 | 0 | 0 | 1140 | 19 |
| mama/fsc | 3D | 2 | 0 | 0 | 600 | 21 |
| mama/fsc | 3D | 2 | 0 | 0 | 667 | 27 |
| mama/fsc | 3D | 2 | 0 | 0 | 150 | 12 |
| mama/fsc | 3D | 2 | 0 | 0 | 180 | 16 |
| mama/fsc | 3D | 2 | 0 | 0 | 200 | 16 |
| mama/fsc | 3D | 2 | 0 | 0 | 250 | 23 |
| mama/fsc | 3D | 2 | 0 | 0 | 267 | 27 |
| mama/fsc | 3D | 2 | 0 | 0 | 300 | 17 |
| mama/fsc | 3D | 2 | 0 | 0 | 360 | 18 |
| mama/fsc | 3D | 2 | 0 | 0 | 390 | 18 |
| mama/fsc | 3D | 2 | 0 | 0 | 399 | 22 |
| mama/fsc | 3D | 2 | 0 | 0 | 400 | 18 |
| mama/fsc | 3D | 2 | 0 | 0 | 520 | 35 |
| mama/fsc | 3D | 2 | 0 | 0 | 525 | 16 |
| mama/fsc | 3D | 2 | 0 | 0 | 530 | 17 |
| mama/fsc | 3D | 2 | 0 | 0 | 534 | 19 |
| mama/fsc | 3D | 2 | 0 | 0 | 600 | 26 |
| mama/fsc | 3D | 2 | 0 | 0 | 800 | 22 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|----------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| mama/fsc | 3D | 2 | 0 | 0 | 801 | 21 |
| mama/fsc | 3D | 2 | 0 | 0 | 1140 | 30 |
| mama/fsc | 3D | 2 | 0 | 1 | 180 | 16 |
| mama/fsc | 3D | 3 | 0 | 0 | 534 | 16 |
| mama/fsc | 3D | 3 | 0 | 0 | 267 | 35 |
| mama/fsc | 3D | 3 | 0 | 0 | 300 | 37 |
| mama/fsc | 3D | 3 | 0 | 0 | 400 | 54 |
| mama/fsc | 3D | 3 | 0 | 0 | 415 | 61 |
| mama/fsc | 3D | 3 | 0 | 0 | 420 | 24 |
| mama/fsc | 3D | 3 | 0 | 0 | 500 | 25 |
| mama/fsc | 3D | 3 | 0 | 0 | 600 | 26 |
| mama/fsc | 3D | 3 | 0 | 0 | 667 | 36 |
| mama/fsc | 3D | 3 | 0 | 0 | 787 | 36 |
| mama/fsc | 3D | 3 | 0 | 0 | 801 | 28 |
| mama/fsc | 3D | 3 | 0 | 0 | 1000 | 27 |
| mama/fsc | 3D | 4 | 0 | 0 | 180 | 28 |
| mama/fsc | 3D | 4 | 0 | 0 | 200 | 20 |
| mama/fsc | 3D | 4 | 0 | 0 | 360 | 22 |
| mama/fsc | 3D | 4 | 0 | 0 | 534 | 51 |
| mama/fsc | 3D | 4 | 0 | 0 | 800 | 28 |
| mama/fsc | 3D | 4 | 0 | 0 | 801 | 39 |
| mama/fsc | 3D | 4 | 0 | 0 | 1068 | 44 |
| mama/fsc | 3D | 5 | 0 | 0 | 600 | 25 |
| mama/fsc | 3D REF | 1 | 0 | 0 | 400 | 10 |
| mama/fsc | 3D REF | 1 | 0 | 0 | 500 | 32 |
| mama/fsc | ELETRONS | 1 | 0 | 0 | 180 | 15 |
| mama/fsc | ELETRONS | 1 | 0 | 0 | 200 | 8 |
| mama/fsc | ELETRONS | 1 | 0 | 0 | 250 | 16 |
| mama/fsc | ELETRONS | 1 | 0 | 0 | 267 | 9 |
| mama/fsc | ELETRONS | 1 | 0 | 0 | 300 | 9 |
| mama/fsc | ELETRONS | 2 | 0 | 0 | 267 | 38 |
| mama/fsc | ELETRONS | 2 | 0 | 0 | 300 | 20 |
| mama/fsc | ELETRONS | 2 | 0 | 0 | 400 | 16 |
| mama/fsc | ELETRONS | 2 | 0 | 0 | 800 | 17 |
| mama/fsc | ELETRONS | 3 | 0 | 0 | 185 | 27 |
| mama/fsc | ELETRONS | 3 | 0 | 0 | 500 | 27 |
| mama/fsc | ELETRONS | 3 | 0 | 0 | 1000 | 25 |
| mama/fsc | ELETRONS | 4 | 0 | 0 | 267 | 39 |
| mama/fsc | ELETRONS | 5 | 0 | 0 | 200 | 25 |
| mama/fsc | IMRT | 1 | 0 | 0 | 180 | 21 |
| mama/fsc | IMRT | 1 | 0 | 0 | 200 | 20 |
| mama/fsc | IMRT | 1 | 0 | 0 | 267 | 23 |
| mama/fsc | IMRT | 1 | 1 | 0 | 180 | 24 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|---------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| mama/fsc | IMRT | 4 | 0 | 0 | 180 | 18 |
| mama/fsc | IMRT REF | 1 | 0 | 0 | 600 | 30 |
| mama/fsc | VMAT | 1 | 0 | 0 | 180 | 14 |
| mama/fsc | VMAT | 1 | 0 | 0 | 200 | 22 |
| mama/fsc | VMAT | 1 | 0 | 0 | 250 | 11 |
| mama/fsc | VMAT | 1 | 1 | 0 | 180 | 30 |
| mama/fsc | VMAT | 2 | 0 | 0 | 180 | 18 |
| mama/fsc | VMAT | 3 | 1 | 0 | 180 | 40 |
| META CEREBRAL | 2d | 1 | 0 | 0 | 150 | 10 |
| META CEREBRAL | 2d | 1 | 0 | 0 | 240 | 11 |
| META CEREBRAL | 2d | 1 | 0 | 0 | 250 | 9 |
| META CEREBRAL | 2d | 1 | 0 | 0 | 300 | 13 |
| META CEREBRAL | 2d | 1 | 0 | 0 | 400 | 10 |
| META CEREBRAL | 2d | 1 | 0 | 1 | 150 | 19 |
| META CEREBRAL | 2d | 1 | 0 | 1 | 180 | 11 |
| META CEREBRAL | 2d | 1 | 0 | 1 | 250 | 23 |
| META CEREBRAL | 2d | 1 | 0 | 1 | 300 | 15 |
| META CEREBRAL | 2d | 1 | 1 | 0 | 150 | 26 |
| META CEREBRAL | 2d | 2 | 0 | 0 | 300 | 19 |
| META CEREBRAL | 2d | 2 | 0 | 1 | 300 | 33 |
| META CEREBRAL | 2d | 3 | 0 | 0 | 300 | 19 |
| META CEREBRAL | 2d | 3 | 0 | 1 | 300 | 31 |
| META CEREBRAL | 3D | 1 | 0 | 0 | 150 | 15 |
| META CEREBRAL | 3D | 1 | 0 | 0 | 180 | 10 |
| META CEREBRAL | 3D | 1 | 0 | 0 | 200 | 9 |
| META CEREBRAL | 3D | 1 | 0 | 0 | 300 | 13 |
| META CEREBRAL | 3D | 1 | 0 | 0 | 400 | 18 |
| META CEREBRAL | 3D | 1 | 0 | 0 | 500 | 33 |
| META CEREBRAL | 3D | 1 | 0 | 1 | 150 | 14 |
| META CEREBRAL | 3D | 1 | 0 | 1 | 180 | 11 |
| META CEREBRAL | 3D | 1 | 0 | 1 | 200 | 34 |
| META CEREBRAL | 3D | 1 | 0 | 1 | 300 | 15 |
| META CEREBRAL | 3D | 1 | 0 | 1 | 400 | 15 |
| META CEREBRAL | 3D | 2 | 0 | 0 | 150 | 30 |
| META CEREBRAL | 3D | 2 | 0 | 0 | 180 | 31 |
| META CEREBRAL | 3D | 2 | 0 | 0 | 300 | 21 |
| META CEREBRAL | 3D | 2 | 0 | 1 | 300 | 24 |
| META CEREBRAL | 3D | 3 | 0 | 0 | 180 | 36 |
| META CEREBRAL | 3D | 3 | 0 | 0 | 300 | 33 |
| META CEREBRAL | 3D | 3 | 0 | 1 | 400 | 42 |
| META CEREBRAL | ELETRONS | 1 | 0 | 0 | 20 | 24 |
| META CEREBRAL | ELETRONS | 1 | 0 | 0 | 400 | 22 |
| META CEREBRAL | ELETRONS | 2 | 0 | 0 | 300 | 9 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|---------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| META CEREBRAL | IMRT | 1 | 0 | 0 | 200 | 12 |
| META CEREBRAL | IMRT REF | 1 | 0 | 0 | 500 | 38 |
| META CEREBRAL | VMAT | 1 | 0 | 0 | 180 | 27 |
| META CEREBRAL | VMAT | 1 | 0 | 0 | 200 | 10 |
| META CEREBRAL | VMAT | 1 | 0 | 0 | 300 | 20 |
| META CEREBRAL | VMAT | 1 | 0 | 0 | 400 | 18 |
| META OSSEA | 2d | 1 | 0 | 0 | 150 | 11 |
| META OSSEA | 2d | 1 | 0 | 0 | 200 | 23 |
| META OSSEA | 2d | 1 | 0 | 0 | 300 | 12 |
| META OSSEA | 2d | 1 | 0 | 0 | 400 | 12 |
| META OSSEA | 2d | 1 | 0 | 0 | 500 | 24 |
| META OSSEA | 2d | 1 | 0 | 0 | 600 | 23 |
| META OSSEA | 2d | 1 | 0 | 1 | 150 | 11 |
| META OSSEA | 2d | 1 | 0 | 1 | 180 | 14 |
| META OSSEA | 2d | 1 | 0 | 1 | 300 | 14 |
| META OSSEA | 2d | 1 | 0 | 1 | 400 | 12 |
| META OSSEA | 2d | 2 | 0 | 0 | 700 | 20 |
| META OSSEA | 2d | 2 | 0 | 0 | 200 | 34 |
| META OSSEA | 2d | 2 | 0 | 0 | 300 | 15 |
| META OSSEA | 2d | 2 | 0 | 0 | 400 | 27 |
| META OSSEA | 2d | 2 | 0 | 0 | 600 | 17 |
| META OSSEA | 2d | 2 | 0 | 0 | 700 | 20 |
| META OSSEA | 2d | 2 | 0 | 0 | 800 | 18 |
| META OSSEA | 2d | 2 | 0 | 0 | 1000 | 25 |
| META OSSEA | 2d | 2 | 0 | 1 | 300 | 31 |
| META OSSEA | 2d | 2 | 0 | 1 | 600 | 30 |
| META OSSEA | 2d | 2 | 0 | 1 | 800 | 27 |
| META OSSEA | 2d | 3 | 0 | 0 | 300 | 17 |
| META OSSEA | 2d | 3 | 0 | 0 | 500 | 44 |
| META OSSEA | 2d | 3 | 0 | 0 | 600 | 21 |
| META OSSEA | 2d | 3 | 0 | 0 | 800 | 27 |
| META OSSEA | 2d | 3 | 0 | 0 | 900 | 41 |
| META OSSEA | 2d | 3 | 0 | 0 | 1000 | 71 |
| META OSSEA | 2d | 3 | 0 | 0 | 1200 | 24 |
| META OSSEA | 2d | 4 | 1 | 0 | 900 | 42 |
| META OSSEA | 2d | 5 | 0 | 0 | 400 | 38 |
| META OSSEA | 2d | 5 | 0 | 0 | 2000 | 51 |
| META OSSEA | 2d | 6 | 0 | 0 | 800 | 16 |
| META OSSEA | 2d | 6 | 0 | 0 | 2400 | 40 |
| META OSSEA | 3D | 1 | 0 | 0 | 150 | 20 |
| META OSSEA | 3D | 1 | 0 | 0 | 180 | 12 |
| META OSSEA | 3D | 1 | 0 | 0 | 200 | 10 |
| META OSSEA | 3D | 1 | 0 | 0 | 250 | 14 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|------------|--------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| META OSSEA | 3D | 1 | 0 | 0 | 300 | 16 |
| META OSSEA | 3D | 1 | 0 | 0 | 400 | 17 |
| META OSSEA | 3D | 1 | 0 | 0 | 500 | 16 |
| META OSSEA | 3D | 1 | 0 | 0 | 600 | 24 |
| META OSSEA | 3D | 1 | 0 | 1 | 300 | 22 |
| META OSSEA | 3D | 1 | 0 | 1 | 400 | 16 |
| META OSSEA | 3D | 1 | 1 | 0 | 300 | 35 |
| META OSSEA | 3D | 2 | 0 | 0 | 150 | 30 |
| META OSSEA | 3D | 2 | 0 | 0 | 180 | 33 |
| META OSSEA | 3D | 2 | 0 | 0 | 200 | 19 |
| META OSSEA | 3D | 2 | 0 | 0 | 250 | 42 |
| META OSSEA | 3D | 2 | 0 | 0 | 300 | 20 |
| META OSSEA | 3D | 2 | 0 | 0 | 320 | 20 |
| META OSSEA | 3D | 2 | 0 | 0 | 398 | 16 |
| META OSSEA | 3D | 2 | 0 | 0 | 400 | 24 |
| META OSSEA | 3D | 2 | 0 | 0 | 500 | 24 |
| META OSSEA | 3D | 2 | 0 | 0 | 600 | 24 |
| META OSSEA | 3D | 2 | 0 | 0 | 700 | 21 |
| META OSSEA | 3D | 2 | 0 | 0 | 800 | 45 |
| META OSSEA | 3D | 2 | 0 | 1 | 300 | 31 |
| META OSSEA | 3D | 2 | 0 | 1 | 400 | 32 |
| META OSSEA | 3D | 2 | 0 | 1 | 600 | 31 |
| META OSSEA | 3D | 2 | 0 | 1 | 800 | 25 |
| META OSSEA | 3D | 2 | 0 | 0 | 1500 | 77 |
| META OSSEA | 3D | 3 | 0 | 0 | 300 | 32 |
| META OSSEA | 3D | 3 | 0 | 0 | 360 | 36 |
| META OSSEA | 3D | 3 | 0 | 0 | 400 | 29 |
| META OSSEA | 3D | 3 | 0 | 0 | 600 | 33 |
| META OSSEA | 3D | 3 | 0 | 0 | 700 | 49 |
| META OSSEA | 3D | 3 | 0 | 0 | 800 | 47 |
| META OSSEA | 3D | 3 | 0 | 0 | 900 | 32 |
| META OSSEA | 3D | 3 | 0 | 0 | 1100 | 25 |
| META OSSEA | 3D | 3 | 0 | 1 | 600 | 35 |
| META OSSEA | 3D | 3 | 0 | 1 | 800 | 42 |
| META OSSEA | 3D | 3 | 0 | 1 | 900 | 40 |
| META OSSEA | 3D | 3 | 1 | 0 | 180 | 53 |
| META OSSEA | 3D | 4 | 0 | 0 | 180 | 19 |
| META OSSEA | 3D | 4 | 0 | 0 | 400 | 56 |
| META OSSEA | 3D | 4 | 0 | 0 | 1600 | 28 |
| META OSSEA | 3D | 4 | 0 | 1 | 1200 | 49 |
| META OSSEA | 3D | 5 | 0 | 0 | 900 | 35 |
| META OSSEA | 3D REF | 1 | 0 | 0 | 400 | 8 |
| META OSSEA | 3D REF | 2 | 0 | 0 | 400 | 25 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| META OSSEA | 3D REF | 2 | 0 | 0 | 600 | 35 |
| META OSSEA | ELETRONS | 1 | 0 | 0 | 300 | 10 |
| META OSSEA | ELETRONS | 1 | 0 | 0 | 400 | 8 |
| META OSSEA | ELETRONS | 1 | 0 | 0 | 500 | 7 |
| META OSSEA | ELETRONS | 1 | 0 | 0 | 600 | 24 |
| META OSSEA | ELETRONS | 2 | 0 | 0 | 180 | 11 |
| META OSSEA | ELETRONS | 2 | 0 | 0 | 200 | 36 |
| META OSSEA | ELETRONS | 2 | 0 | 0 | 300 | 15 |
| META OSSEA | ELETRONS | 2 | 0 | 0 | 400 | 16 |
| META OSSEA | ELETRONS | 2 | 0 | 0 | 500 | 24 |
| META OSSEA | IMRT | 1 | 0 | 0 | 180 | 15 |
| META OSSEA | IMRT | 1 | 0 | 0 | 200 | 18 |
| META OSSEA | IMRT | 1 | 0 | 0 | 300 | 80 |
| META OSSEA | IMRT REF | 1 | 0 | 0 | 500 | 27 |
| META OSSEA | IMRT SRS | 1 | 0 | 0 | 700 | 27 |
| META OSSEA | IMRT SRS | 1 | 0 | 0 | 750 | 41 |
| META OSSEA | VMAT | 1 | 0 | 0 | 180 | 13 |
| META OSSEA | VMAT | 1 | 0 | 0 | 200 | 10 |
| META OSSEA | VMAT | 1 | 0 | 0 | 240 | 19 |
| META OSSEA | VMAT | 1 | 0 | 0 | 300 | 12 |
| META OSSEA | VMAT | 1 | 1 | 0 | 150 | 29 |
| META OSSEA | VMAT | 2 | 0 | 0 | 400 | 65 |
| META SRS | 3D | 1 | 0 | 0 | 500 | 21 |
| META SRS | 3D | 1 | 0 | 0 | 600 | 28 |
| META SRS | 3D | 2 | 0 | 0 | 500 | 29 |
| META SRS | 3D | 2 | 0 | 0 | 600 | 23 |
| META SRS | 3D | 2 | 0 | 0 | 1000 | 42 |
| META SRS | 3D REF | 1 | 0 | 0 | 500 | 33 |
| META SRS | 3D REF | 1 | 0 | 0 | 600 | 35 |
| META SRS | 3D REF | 2 | 0 | 0 | 500 | 40 |
| META SRS | 3D REF | 2 | 0 | 0 | 600 | 53 |
| META SRS | 3D REF | 2 | 0 | 0 | 1000 | 49 |
| META SRS | 3D REF | 2 | 0 | 0 | 1200 | 60 |
| META SRS | 3D REF | 3 | 0 | 0 | 600 | 70 |
| META SRS | 3D SRS | 2 | 0 | 0 | 2000 | 92 |
| META SRS | ELETRONS | 1 | 0 | 0 | 600 | 13 |
| META SRS | IMRT REF | 1 | 0 | 0 | 500 | 39 |
| META SRS | IMRT REF | 1 | 0 | 0 | 600 | 44 |
| META SRS | IMRT REF | 2 | 0 | 0 | 500 | 51 |
| META SRS | IMRT REF | 2 | 0 | 0 | 600 | 50 |
| META SRS | IMRT REF | 2 | 0 | 0 | 1000 | 85 |
| META SRS | VMAT | 1 | 0 | 0 | 500 | 31 |
| META TORAX | 2d | 1 | 0 | 0 | 300 | 15 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| META TORAX | 2d | 1 | 0 | 0 | 400 | 15 |
| META TORAX | 2d | 2 | 0 | 0 | 400 | 20 |
| META TORAX | 3D | 1 | 0 | 0 | 180 | 24 |
| META TORAX | 3D | 1 | 0 | 0 | 200 | 21 |
| META TORAX | 3D | 1 | 0 | 0 | 300 | 11 |
| META TORAX | 3D | 1 | 0 | 0 | 400 | 15 |
| META TORAX | 3D | 1 | 0 | 1 | 400 | 31 |
| META TORAX | 3D | 1 | 0 | 1 | 500 | 22 |
| META TORAX | 3D | 2 | 0 | 0 | 400 | 21 |
| META TORAX | 3D | 3 | 0 | 0 | 150 | 47 |
| META TORAX | 3D | 4 | 0 | 0 | 180 | 19 |
| META TORAX | 3D | 4 | 0 | 0 | 300 | 26 |
| META TORAX | 3D | 4 | 0 | 0 | 400 | 56 |
| META TORAX | ELETRONS | 1 | 0 | 0 | 250 | 8 |
| META TORAX | VMAT | 1 | 0 | 0 | 200 | 10 |
| METASTASE | 2d | 1 | 0 | 0 | 300 | 24 |
| METASTASE | 2d | 2 | 0 | 0 | 250 | 18 |
| METASTASE | 2d | 2 | 0 | 0 | 400 | 31 |
| METASTASE | 2d | 2 | 0 | 0 | 800 | 13 |
| METASTASE | 3D | 1 | 0 | 0 | 180 | 13 |
| METASTASE | 3D | 1 | 0 | 0 | 200 | 12 |
| METASTASE | 3D | 1 | 0 | 0 | 250 | 15 |
| METASTASE | 3D | 1 | 0 | 0 | 300 | 14 |
| METASTASE | 3D | 1 | 0 | 0 | 400 | 13 |
| METASTASE | 3D | 1 | 0 | 1 | 250 | 19 |
| METASTASE | 3D | 1 | 0 | 1 | 300 | 36 |
| METASTASE | 3D | 1 | 0 | 1 | 400 | 62 |
| METASTASE | 3D | 2 | 0 | 0 | 300 | 22 |
| METASTASE | 3D | 2 | 0 | 0 | 400 | 36 |
| METASTASE | 3D | 2 | 0 | 1 | 300 | 33 |
| METASTASE | 3D | 2 | 0 | 1 | 400 | 32 |
| METASTASE | 3D REF | 1 | 0 | 0 | 500 | 21 |
| METASTASE | 3D REF | 3 | 0 | 0 | 600 | 101 |
| METASTASE | ELETRONS | 1 | 0 | 0 | 267 | 11 |
| METASTASE | ELETRONS | 1 | 0 | 0 | 500 | 5 |
| METASTASE | IMRT REF | 1 | 0 | 0 | 500 | 25 |
| METASTASE | IMRT REF | 1 | 0 | 0 | 600 | 26 |
| METASTASE | IMRT REF | 2 | 0 | 0 | 600 | 81 |
| METASTASE | VMAT | 1 | 0 | 0 | 180 | 22 |
| METASTASE | VMAT | 1 | 0 | 0 | 200 | 13 |
| MOLES | 2d | 1 | 0 | 0 | 300 | 6 |
| MOLES | 2d | 2 | 0 | 0 | 800 | 19 |
| MOLES | 3D | 1 | 0 | 0 | 150 | 28 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|-----------------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| MOLES | 3D | 1 | 0 | 0 | 180 | 15 |
| MOLES | 3D | 1 | 0 | 0 | 200 | 17 |
| MOLES | 3D | 1 | 0 | 0 | 250 | 17 |
| MOLES | 3D | 1 | 0 | 0 | 300 | 16 |
| MOLES | 3D | 1 | 0 | 1 | 200 | 18 |
| MOLES | 3D | 1 | 1 | 0 | 180 | 26 |
| MOLES | 3D | 2 | 0 | 0 | 180 | 18 |
| MOLES | 3D | 2 | 0 | 0 | 199 | 16 |
| MOLES | 3D | 2 | 0 | 0 | 200 | 22 |
| MOLES | 3D | 2 | 0 | 0 | 250 | 22 |
| MOLES | 3D | 2 | 0 | 0 | 380 | 25 |
| MOLES | 3D | 2 | 0 | 0 | 400 | 21 |
| MOLES | 3D | 2 | 1 | 0 | 180 | 44 |
| MOLES | ELETRONS | 1 | 0 | 0 | 180 | 26 |
| MOLES | ELETRONS | 1 | 0 | 0 | 200 | 11 |
| MOLES | ELETRONS | 1 | 0 | 0 | 300 | 17 |
| MOLES | IMRT | 1 | 0 | 0 | 200 | 28 |
| MOLES | IMRT | 1 | 1 | 0 | 180 | 44 |
| MOLES | VMAT | 1 | 0 | 0 | 180 | 17 |
| MOLES | VMAT | 1 | 0 | 0 | 200 | 12 |
| MOLES | VMAT | 1 | 0 | 0 | 212 | 12 |
| MOLES | VMAT | 2 | 1 | 0 | 180 | 44 |
| NAO DEF | 3D | 1 | 0 | 0 | 200 | 44 |
| NECK AND ABDOMEN | 3D | 1 | 0 | 0 | 200 | 19 |
| OCULAR | 3D | 1 | 0 | 1 | 200 | 11 |
| OUVIDO | 3D REF | 1 | 0 | 0 | 500 | 21 |
| PELVE GINECO | 3D | 1 | 0 | 0 | 180 | 9 |
| PELVE GINECO | 3D | 2 | 0 | 0 | 200 | 25 |
| PELVE GINECO | IMRT | 1 | 0 | 0 | 180 | 23 |
| PELVE GINECO | VMAT | 1 | 0 | 0 | 200 | 21 |
| PELVE reto/canal anal | 2d | 1 | 0 | 0 | 400 | 10 |
| PELVE reto/canal anal | 3D | 1 | 0 | 0 | 180 | 16 |
| PELVE reto/canal anal | 3D | 1 | 0 | 0 | 200 | 16 |
| PELVE reto/canal anal | 3D | 1 | 0 | 0 | 250 | 16 |
| PELVE reto/canal anal | 3D | 1 | 0 | 0 | 300 | 12 |
| PELVE reto/canal anal | 3D | 1 | 0 | 0 | 400 | 30 |
| PELVE reto/canal anal | 3D | 1 | 0 | 0 | 500 | 14 |
| PELVE reto/canal anal | 3D | 1 | 0 | 1 | 300 | 24 |
| PELVE reto/canal anal | 3D REF | 1 | 0 | 0 | 500 | 57 |
| PELVE reto/canal anal | 3D REF | 2 | 0 | 0 | 600 | 37 |
| PELVE reto/canal anal | IMRT | 1 | 0 | 0 | 180 | 25 |
| PELVE reto/canal anal | IMRT | 1 | 0 | 0 | 200 | 16 |
| PELVE reto/canal anal | IMRT | 1 | 0 | 0 | 210 | 15 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|-----------------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| PELVE reto/canal anal | VMAT | 1 | 0 | 0 | 180 | 16 |
| PELVE reto/canal anal | VMAT | 1 | 0 | 0 | 201 | 13 |
| SKIN | 2d | 1 | 0 | 0 | 200 | 9 |
| SKIN | 2d | 1 | 0 | 0 | 250 | 7 |
| SKIN | 2d | 1 | 0 | 0 | 300 | 9 |
| SKIN | 2d | 1 | 0 | 0 | 400 | 9 |
| SKIN | 2d | 1 | 0 | 0 | 600 | 11 |
| SKIN | 2d | 2 | 0 | 0 | 250 | 44 |
| SKIN | 2d | 2 | 0 | 0 | 400 | 14 |
| SKIN | 2d | 2 | 0 | 0 | 600 | 11 |
| SKIN | 2d | 2 | 0 | 0 | 800 | 17 |
| SKIN | 2d | 3 | 0 | 0 | 800 | 26 |
| SKIN | 2d | 5 | 0 | 0 | 800 | 38 |
| SKIN | 2d | 7 | 0 | 0 | 800 | 52 |
| SKIN | 3D | 1 | 0 | 0 | 180 | 27 |
| SKIN | 3D | 1 | 0 | 0 | 200 | 13 |
| SKIN | 3D | 1 | 0 | 0 | 225 | 35 |
| SKIN | 3D | 1 | 0 | 0 | 240 | 15 |
| SKIN | 3D | 1 | 0 | 0 | 250 | 15 |
| SKIN | 3D | 1 | 0 | 0 | 300 | 16 |
| SKIN | 3D | 1 | 0 | 0 | 400 | 12 |
| SKIN | 3D | 1 | 0 | 0 | 500 | 21 |
| SKIN | 3D | 1 | 0 | 1 | 250 | 18 |
| SKIN | 3D | 1 | 0 | 1 | 300 | 30 |
| SKIN | 3D | 1 | 1 | 1 | 200 | 14 |
| SKIN | 3D | 2 | 0 | 0 | 200 | 16 |
| SKIN | 3D | 2 | 0 | 0 | 250 | 32 |
| SKIN | 3D | 2 | 0 | 0 | 300 | 26 |
| SKIN | 3D | 2 | 0 | 0 | 400 | 22 |
| SKIN | 3D | 2 | 0 | 0 | 480 | 33 |
| SKIN | 3D | 2 | 0 | 0 | 500 | 20 |
| SKIN | 3D | 2 | 0 | 0 | 600 | 24 |
| SKIN | ELETRONS | 1 | 0 | 0 | 200 | 10 |
| SKIN | ELETRONS | 1 | 0 | 0 | 250 | 11 |
| SKIN | ELETRONS | 1 | 0 | 0 | 280 | 7 |
| SKIN | ELETRONS | 1 | 0 | 0 | 300 | 11 |
| SKIN | ELETRONS | 1 | 0 | 0 | 500 | 35 |
| SKIN | ELETRONS | 2 | 0 | 0 | 200 | 16 |
| SKIN | ELETRONS | 2 | 0 | 0 | 250 | 23 |
| SKIN | ELETRONS | 2 | 0 | 0 | 300 | 26 |
| SKIN | ELETRONS | 2 | 0 | 0 | 600 | 16 |
| SKIN | ELETRONS | 2 | 0 | 0 | 1000 | 17 |
| SKIN | IMRT | 1 | 0 | 0 | 180 | 20 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|-------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| SKIN | IMRT | 1 | 0 | 0 | 200 | 16 |
| SKIN | IMRT | 1 | 0 | 0 | 250 | 14 |
| SKIN | IMRT | 2 | 0 | 0 | 200 | 22 |
| SKIN | IMRT REF | 1 | 0 | 0 | 500 | 47 |
| SKIN | VMAT | 1 | 0 | 0 | 200 | 15 |
| SKIN | VMAT | 1 | 0 | 0 | 250 | 16 |
| SKIN | VMAT | 1 | 0 | 0 | 300 | 14 |
| SKIN | VMAT | 1 | 0 | 0 | 600 | 28 |
| SN | 2d | 1 | 0 | 0 | 150 | 9 |
| SN | 2d | 1 | 0 | 0 | 180 | 13 |
| SN | 2d | 1 | 0 | 0 | 200 | 11 |
| SN | 2d | 1 | 0 | 1 | 150 | 9 |
| SN | 3D | 1 | 0 | 0 | 180 | 14 |
| SN | 3D | 1 | 0 | 0 | 200 | 13 |
| SN | 3D | 1 | 0 | 0 | 267 | 16 |
| SN | 3D | 1 | 0 | 0 | 500 | 24 |
| SN | 3D | 1 | 0 | 1 | 180 | 16 |
| SN | 3D | 1 | 0 | 1 | 200 | 15 |
| SN | 3D | 1 | 0 | 1 | 267 | 23 |
| SN | 3D | 1 | 1 | 0 | 150 | 10 |
| SN | 3D | 1 | 1 | 0 | 180 | 17 |
| SN | 3D | 1 | 1 | 0 | 200 | 33 |
| SN | 3D | 1 | 1 | 1 | 200 | 25 |
| SN | 3D | 2 | 0 | 0 | 288 | 85 |
| SN | 3D | 2 | 0 | 0 | 360 | 55 |
| SN | 3D | 2 | 0 | 0 | 150 | 36 |
| SN | 3D | 2 | 0 | 0 | 180 | 25 |
| SN | 3D | 2 | 0 | 0 | 360 | 31 |
| SN | 3D | 2 | 0 | 1 | 360 | 31 |
| SN | 3D | 2 | 1 | 0 | 270 | 23 |
| SN | 3D | 2 | 1 | 0 | 300 | 32 |
| SN | 3D | 2 | 1 | 0 | 360 | 36 |
| SN | 3D | 2 | 1 | 1 | 360 | 43 |
| SN | 3D | 3 | 0 | 0 | 180 | 28 |
| SN | 3D | 3 | 0 | 0 | 360 | 39 |
| SN | 3D | 3 | 0 | 0 | 400 | 41 |
| SN | 3D | 3 | 0 | 0 | 540 | 44 |
| SN | 3D REF | 1 | 0 | 0 | 400 | 22 |
| SN | 3D REF | 1 | 0 | 0 | 500 | 27 |
| SN | ELETRONS | 1 | 0 | 0 | 180 | 7 |
| SN | IMRT | 1 | 0 | 0 | 180 | 23 |
| SN | IMRT | 1 | 0 | 0 | 200 | 16 |
| SN | IMRT | 1 | 1 | 0 | 180 | 30 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|---------------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| SN | IMRT | 2 | 0 | 0 | 180 | 35 |
| SN | IMRT | 2 | 0 | 0 | 360 | 30 |
| SN | IMRT REF | 1 | 0 | 0 | 500 | 31 |
| SN | VMAT | 1 | 0 | 0 | 150 | 14 |
| SN | VMAT | 1 | 0 | 0 | 180 | 16 |
| SN | VMAT | 1 | 0 | 0 | 200 | 14 |
| SN | VMAT | 1 | 0 | 0 | 250 | 24 |
| SN | VMAT | 1 | 0 | 0 | 267 | 17 |
| SN | VMAT | 1 | 1 | 0 | 150 | 23 |
| SN | VMAT | 1 | 1 | 0 | 180 | 20 |
| SN | VMAT | 1 | 1 | 0 | 200 | 27 |
| SN | VMAT | 2 | 0 | 0 | 150 | 56 |
| SN | VMAT | 2 | 0 | 0 | 180 | 22 |
| SN-MENINGIOMAS | 3D | 1 | 0 | 0 | 180 | 21 |
| SN-MENINGIOMAS | 3D | 1 | 0 | 0 | 500 | 21 |
| SN-MENINGIOMAS | IMRT | 1 | 0 | 0 | 180 | 20 |
| SN-MENINGIOMAS | VMAT | 1 | 0 | 0 | 180 | 13 |
| SN-MENINGIOMAS | VMAT | 1 | 0 | 0 | 200 | 13 |
| SN-Schwannoma | 3D | 1 | 0 | 0 | 180 | 45 |
| SN-Schwannoma | IMRT REF | 1 | 0 | 0 | 500 | 32 |
| SN Craniofaringioma | 3D | 1 | 0 | 0 | 180 | 14 |
| SN Craniofaringioma | IMRT | 1 | 0 | 0 | 180 | 35 |
| SN Craniofaringioma | IMRT | 1 | 1 | 0 | 180 | 33 |
| SN Craniofaringioma | VMAT | 1 | 0 | 0 | 180 | 15 |
| SN Hipofise | 3D | 1 | 0 | 0 | 180 | 26 |
| SN Hipofise | IMRT | 1 | 0 | 0 | 180 | 27 |
| SN Hipofise | VMAT | 1 | 0 | 0 | 180 | 15 |
| SN NEURINOMA | 3D | 1 | 0 | 0 | 180 | 16 |
| SN NEURINOMA | IMRT | 1 | 0 | 0 | 180 | 17 |
| SN NEURINOMA | IMRT | 2 | 0 | 0 | 180 | 26 |
| SN Schwannoma | 3D | 1 | 0 | 0 | 180 | 31 |
| SN Schwannoma | IMRT | 1 | 0 | 0 | 180 | 30 |
| SN Schwannoma | IMRT | 2 | 0 | 0 | 180 | 25 |
| SN Schwannoma | VMAT | 1 | 0 | 0 | 180 | 19 |
| SRS-MENINGIOMAS | 3D | 1 | 0 | 0 | 500 | 53 |
| SRS-MENINGIOMAS | 3D | 2 | 0 | 0 | 500 | 51 |
| SRS-MENINGIOMAS | 3D REF | 1 | 0 | 0 | 500 | 22 |
| SRS-MENINGIOMAS | IMRT REF | 1 | 0 | 0 | 500 | 39 |
| SRS-MENINGIOMAS | IMRT REF | 1 | 0 | 0 | 600 | 30 |
| SRS-Schwannoma | 3D REF | 1 | 0 | 0 | 500 | 17 |
| SRS-Schwannoma | IMRT REF | 1 | 0 | 0 | 500 | 26 |
| SRS-Schwannoma | IMRT REF | 2 | 0 | 0 | 500 | 38 |
| SRS Hipofise | IMRT REF | 2 | 0 | 0 | 600 | 46 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|---------------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| SRS MAV | 3D | 1 | 0 | 0 | 500 | 23 |
| SRS MAV | 3D | 1 | 0 | 0 | 600 | 29 |
| SRS MAV | 3D REF | 1 | 0 | 0 | 500 | 29 |
| SRS MAV | 3D REF | 1 | 0 | 0 | 600 | 37 |
| SRS MAV | IMRT REF | 1 | 0 | 0 | 500 | 52 |
| SRS MAV | IMRT REF | 1 | 0 | 0 | 550 | 24 |
| SRS MAV | IMRT REF | 1 | 0 | 0 | 600 | 41 |
| SRS MAV | IMRT SRS | 1 | 0 | 0 | 700 | 34 |
| SRS NEURINOMA | 3D | 2 | 0 | 0 | 500 | 39 |
| SRS NEURINOMA | 3D REF | 1 | 0 | 0 | 500 | 31 |
| SRS NEURINOMA | IMRT REF | 1 | 0 | 0 | 500 | 32 |
| TBI | TBI | 1 | 0 | 0 | 200 | 68 |
| TBI | TBI | 1 | 0 | 1 | 200 | 74 |
| TBI | TBI | 1 | 0 | 1 | 400 | 70 |
| TBI | TBI | 2 | 0 | 0 | 200 | 87 |
| TBI | TBI | 2 | 0 | 1 | 100 | 86 |
| TBI | TBI | 2 | 0 | 1 | 150 | 82 |
| TBI | TBI | 2 | 0 | 1 | 200 | 85 |
| TBI | TBI | 2 | 0 | 1 | 225 | 73 |
| TBI | TBI | 2 | 0 | 1 | 300 | 102 |
| Torax | 2d | 1 | 0 | 0 | 200 | 12 |
| Torax | 2d | 1 | 0 | 0 | 300 | 14 |
| Torax | 2d | 1 | 0 | 0 | 400 | 94 |
| Torax | 2d | 1 | 0 | 1 | 300 | 14 |
| Torax | 2d | 2 | 0 | 0 | 300 | 33 |
| Torax | 2d | 3 | 0 | 0 | 200 | 44 |
| Torax | 2d | 3 | 0 | 0 | 300 | 19 |
| Torax | 3D | 1 | 0 | 0 | 150 | 14 |
| Torax | 3D | 1 | 0 | 0 | 180 | 13 |
| Torax | 3D | 1 | 0 | 0 | 200 | 15 |
| Torax | 3D | 1 | 0 | 0 | 250 | 14 |
| Torax | 3D | 1 | 0 | 0 | 275 | 14 |
| Torax | 3D | 1 | 0 | 0 | 300 | 15 |
| Torax | 3D | 1 | 0 | 0 | 350 | 28 |
| Torax | 3D | 1 | 0 | 0 | 400 | 17 |
| Torax | 3D | 1 | 0 | 1 | 250 | 15 |
| Torax | 3D | 1 | 0 | 1 | 300 | 20 |
| Torax | 3D | 1 | 0 | 1 | 400 | 17 |
| Torax | 3D | 1 | 0 | 1 | 500 | 16 |
| Torax | 3D | 1 | 1 | 0 | 150 | 15 |
| Torax | 3D | 2 | 0 | 0 | 150 | 14 |
| Torax | 3D | 2 | 0 | 0 | 180 | 25 |
| Torax | 3D | 2 | 0 | 0 | 200 | 19 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|----------|----------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| Torax | 3D | 2 | 0 | 0 | 250 | 22 |
| Torax | 3D | 2 | 0 | 0 | 267 | 19 |
| Torax | 3D | 2 | 0 | 0 | 300 | 23 |
| Torax | 3D | 2 | 0 | 0 | 360 | 40 |
| Torax | 3D | 2 | 0 | 0 | 400 | 25 |
| Torax | 3D | 2 | 0 | 0 | 600 | 25 |
| Torax | 3D | 2 | 0 | 1 | 300 | 37 |
| Torax | 3D | 2 | 1 | 0 | 180 | 40 |
| Torax | 3D | 3 | 0 | 0 | 180 | 39 |
| Torax | 3D | 3 | 0 | 0 | 200 | 41 |
| Torax | 3D | 3 | 0 | 0 | 300 | 37 |
| Torax | 3D | 3 | 0 | 0 | 520 | 36 |
| Torax | 3D REF | 1 | 0 | 0 | 900 | 43 |
| Torax | IMRT | 1 | 0 | 0 | 180 | 26 |
| Torax | IMRT | 1 | 0 | 0 | 192 | 19 |
| Torax | IMRT | 1 | 0 | 0 | 200 | 18 |
| Torax | IMRT | 1 | 0 | 0 | 275 | 17 |
| Torax | IMRT | 1 | 0 | 0 | 300 | 17 |
| Torax | IMRT | 1 | 1 | 0 | 180 | 27 |
| Torax | TBI | 2 | 0 | 0 | 200 | 16 |
| Torax | VMAT | 1 | 0 | 0 | 180 | 16 |
| Torax | VMAT | 1 | 0 | 0 | 200 | 15 |
| Urgencia | 2d | 1 | 0 | 0 | 300 | 16 |
| URO | 2d | 1 | 0 | 0 | 400 | 27 |
| URO | 2d | 1 | 0 | 0 | 500 | 13 |
| URO | 3D | 1 | 0 | 0 | 150 | 33 |
| URO | 3D | 1 | 0 | 0 | 180 | 15 |
| URO | 3D | 1 | 0 | 0 | 200 | 13 |
| URO | 3D | 1 | 0 | 0 | 250 | 16 |
| URO | 3D | 1 | 0 | 0 | 300 | 12 |
| URO | 3D | 1 | 0 | 0 | 400 | 19 |
| URO | 3D | 1 | 0 | 1 | 200 | 20 |
| URO | 3D | 1 | 1 | 0 | 180 | 10 |
| URO | 3D | 1 | 1 | 1 | 180 | 9 |
| URO | 3D | 2 | 0 | 0 | 360 | 21 |
| URO | 3D | 2 | 0 | 0 | 180 | 24 |
| URO | 3D | 2 | 0 | 0 | 400 | 28 |
| URO | 3D | 3 | 0 | 0 | 200 | 26 |
| URO | IMRT | 1 | 0 | 0 | 180 | 19 |
| URO | IMRT | 1 | 0 | 0 | 200 | 15 |
| URO | IMRT | 1 | 0 | 0 | 250 | 27 |
| URO | IMRT | 2 | 0 | 0 | 180 | 31 |
| URO | IMRT REF | 2 | 0 | 0 | 500 | 46 |

| Grupo | TEC | n | ANESTESIA | Bloco.Sessao | Dose_Fracao (cGy) | Continuação |
|--------------|------|---|-----------|--------------|----------------------|----------------|
| | | | | | | Tempo (min) |
| URO | VMAT | 1 | 0 | 0 | 180 | 17 |
| URO | VMAT | 1 | 0 | 0 | 200 | 20 |
| URO | VMAT | 1 | 0 | 0 | 250 | 15 |
| URO | VMAT | 1 | 0 | 0 | 267 | 15 |
| URO | VMAT | 1 | 1 | 0 | 150 | 40 |
| URO prostata | 2d | 1 | 0 | 1 | 200 | 13 |
| URO prostata | 2d | 1 | 0 | 1 | 250 | 13 |
| URO prostata | 2d | 2 | 0 | 0 | 300 | 13 |
| URO prostata | 3D | 1 | 0 | 0 | 180 | 11 |
| URO prostata | 3D | 1 | 0 | 0 | 199 | 8 |
| URO prostata | 3D | 1 | 0 | 0 | 200 | 12 |
| URO prostata | 3D | 1 | 0 | 0 | 250 | 10 |
| URO prostata | 3D | 1 | 0 | 0 | 300 | 18 |
| URO prostata | 3D | 2 | 0 | 0 | 200 | 18 |
| URO prostata | 3D | 2 | 0 | 0 | 400 | 16 |
| URO prostata | 3D | 3 | 0 | 0 | 300 | 30 |
| URO prostata | 3D | 3 | 0 | 0 | 600 | 16 |
| URO prostata | IMRT | 1 | 0 | 0 | 180 | 17 |
| URO prostata | IMRT | 1 | 0 | 0 | 200 | 15 |
| URO prostata | IMRT | 1 | 0 | 0 | 210 | 15 |
| URO prostata | IMRT | 1 | 0 | 0 | 212 | 11 |
| URO prostata | VMAT | 1 | 0 | 0 | 180 | 13 |
| URO prostata | VMAT | 1 | 0 | 0 | 200 | 13 |
| URO prostata | VMAT | 1 | 0 | 0 | 208 | 16 |
| URO prostata | VMAT | 1 | 0 | 0 | 211 | 12 |
| URO prostata | VMAT | 1 | 0 | 0 | 212 | 13 |
| URO prostata | VMAT | 1 | 0 | 0 | 216 | 14 |
| URO prostata | VMAT | 1 | 0 | 0 | 218 | 11 |
| URO prostata | VMAT | 1 | 0 | 0 | 220 | 24 |
| URO prostata | VMAT | 1 | 0 | 0 | 250 | 16 |
| URO prostata | VMAT | 1 | 0 | 0 | 400 | 86 |

ANEXO 1



Universidade de São Paulo
Faculdade de Medicina
Departamento de Radiologia e Oncologia
Av. Dr. Enéas de Carvalho Aguiar, s/nº - CEP 05403-010
São Paulo - SP
11 2661-7861

DRO - APROVAÇÃO 206/2019

APROVAÇÃO

O Departamento de Radiologia e Oncologia aprovou em 27/03/2019 o projeto de pesquisa: Desenvolvimento e implementação de um algoritmo de agendamento de radioterapia, utilizando a abordagem de aprendizado de máquina e mineração de dados, para diminuição de atrasos e maximização de pacientes atendidos.

Pesquisador(a) Responsável: Edson Gonçalves Moreira

Pesquisador(a) Executante: Caroline Zeppellini dos Santos Emíliozzi

Disciplina: IPEN e Radioterapia-InRad

Finalidade: Mestrado

Responsabilidades do Pesquisador:

- Iniciar as atividades do estudo após aprovação do Comitê de Ética em Pesquisa (CAPPesq, CEP-FMUSP ou CEUA) e instâncias regulatórias, conforme Resolução CNS nº 466/12 e fornecer cópia a este Departamento;
- Apresentar relatório parcial e/ou final do projeto semestralmente;
- Enviar publicação dos resultados finais do estudo.

São Paulo, 27 de março de 2019.

INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES
Diretoria de Pesquisa, Desenvolvimento e Ensino
Av. Prof. Lineu Prestes, 2242 – Cidade Universitária CEP: 05508-000
Fone/Fax(0XX11) 3133-8908
SÃO PAULO – São Paulo – Brasil
<http://www.ipen.br>

O IPEN é uma Autarquia vinculada à Secretaria de Desenvolvimento, associada à Universidade de São Paulo e gerida técnica e administrativamente pela Comissão Nacional de Energia Nuclear, órgão do Ministério da Ciência, Tecnologia, Inovações e Comunicações.