

ESTUDO DE CASO DA APLICAÇÃO DE SIMULAÇÃO DE EVENTOS DISCRETOS NUM PROCESSO DE RADIOTERAPIA¹

José Miguel Sanchez Galves Junior^{a*}, Douglas Moura Miranda^a, Mariana Pedrini Moura Miranda^b, Íris Antônio Maeda^b, Ricardo Fernandes Goulart^b

^aInstituto de Ciências Tecnológicas e Exatas, Departamento de Engenharia de Produção
Universidade Federal do Triângulo Mineiro - UFTM, Uberaba-MG, Brasil

^bHospital Hélio Angotti, Departamento de Radioterapia
Uberaba-MG, Brasil

Recebido 18/01/2021, aceito 02/05/2022

RESUMO

Em pacientes oncológicos, o tempo decorrido entre o diagnóstico e o início das sessões de tratamento é uma grande preocupação, considerando sua relação com a qualidade de vida do paciente. Este trabalho concebeu um modelo de simulação da etapa de tratamento de um processo real de radioterapia, com o objetivo de investigar meios de maximizar o desempenho e, conseqüentemente, contribuir para que o início do tratamento ocorra mais cedo. Técnicas de simulação de eventos discretos foram utilizadas para realizar diversas análises no processo. Ao longo do trabalho foram fornecidos detalhes da modelagem computacional, onde foi possível entender como o número de técnicos disponíveis, política de agendamento e demanda, dentre outras variáveis, influenciam o desempenho da operação. Os experimentos permitiram descobrir configurações de tratamento capazes de aumentar substancialmente a produtividade do setor de radioterapia estudado, sendo uma melhoria relevante para a gestão da operação.

Palavras-chave: Simulação de eventos discretos, Radioterapia, Arena, Modelagem computacional.

ABSTRACT

In cancer patients, the time elapsed between diagnosis and the start of treatment sessions is a major concern, considering its relationship with the patient's quality of life. This work conceived a simulation model of the treatment stage of a real radiotherapy process, with the objective of investigating ways to maximize performance and, consequently, contribute to the beginning of treatment to occur earlier. Discrete event simulation techniques were used to perform several analyzes in the system. Throughout the work, details of the computational modeling were provided, where it was possible to understand how the number of available technicians, scheduling policy and demand, among other variables, influence the performance of the operation. The experiments allowed discovering treatment configurations capable of substantially increasing the productivity of the studied radiotherapy sector, being a relevant improvement for the operation management.

Keywords: Discrete event simulation, Radiotherapy, Arena, Computational modelling.

*Autor para correspondência. E-mail: douglas.miranda@uftm.edu.br.

DOI: 10.4322/PODes.2022.005

¹Todos os autores assumem a responsabilidade pelo conteúdo do artigo.

1. Introdução

Existem no Brasil 317 unidades e centros de assistência habilitados no tratamento do câncer, os quais são responsáveis por atender a demanda referente aos atuais e futuros pacientes. Segundo o Instituto Nacional de Câncer, a expectativa é de que haja aproximadamente 625 mil novos casos oncológicos no país no triênio 2020-2022 (INCA, 2020). Considerando que estes centros são ambientes dinâmicos, faz-se importante a utilização de técnicas de planejamento e gestão capazes de facilitar o processo de tomada de decisão e, conseqüentemente, melhorar a qualidade e a produtividade dos processos. Nesta linha, este trabalho tem por objetivo, aperfeiçoar por meio de técnicas de Simulação de Eventos Discretos (SED), a dinâmica operacional do processo de tratamento radioterápico do Hospital Hélio Angotti, localizado em Uberaba – MG.

Inaugurado em 1961, o Hospital Hélio Angotti tornou-se referência nacional no atendimento de alta complexidade, possuindo a proposta de difundir conhecimentos gerais sobre os tipos de câncer, lutar contra a vulgarização de sua profilaxia e promover diagnósticos precoces com realização de campanhas educativas. Hoje, o Hospital conta com cerca de 45 médicos e 433 colaboradores, contribuindo para o impacto social da região de Uberaba, ofertando serviços ambulatoriais, diagnóstico por imagem (capacidade instalada para realizar mais de 7.000 exames/mês), medicina nuclear (cerca de 800 exames/mês), quimioterapia (aproximadamente 400 consultas/mês) e radioterapia (mais de 43.000 aplicações/mês).

SED é uma técnica apropriada para modelar sistemas complexos, dinâmicos, discretos e estocásticos (Law e Kelton, 2000). É comum que tais sistemas apresentem a existência de filas, sendo que estas, são fenômenos regidos por variáveis com comportamento aleatório. Um de seus grandes problemas é que geram tempos de espera e por fim, no contexto de processos hospitalares, acabam causando impacto ao paciente. Segundo Carneiro (2008), as dificuldades em administrar filas acabam gerando um constante dilema para as organizações de serviços, incluindo hospitais. Este dilema está em tomar decisões operacionais para assegurar a prestação de um serviço com qualidade (menor tempo de espera nas filas), mas que seja apropriado em termos de custos.

Neste contexto, o principal objetivo do presente trabalho é melhorar a produtividade da etapa do tratamento dos pacientes no setor de radioterapia do hospital Hélio Angotti, pois quanto mais pacientes forem atendidos diariamente, menor tende a ser o tempo decorrido entre o diagnóstico da doença e o início do tratamento. Por outro lado, este aumento de produtividade não pode ter efeitos colaterais como: aumento no tempo dos pacientes na sala de espera e aumento de horas extras dos funcionários.

Diferentes fatores podem impactar esta produtividade, tais como: a quantidade de pacientes agendados por dia, o tamanho do intervalo de tempo planejado para cada atendimento, a escala de trabalho dos técnicos, dentre outros. Como o processo de tratamento possui um comportamento fortemente probabilístico com variáveis aleatórias, como por exemplo, a fila de espera e a presença de variabilidade nos atendimentos, torna-se difícil para os gestores tomar tais decisões de forma eficiente. Vale ressaltar que os gestores possuem receio de fazer testes práticos na operação, pois caso a alteração falhe, os tempos de espera podem subir de modo a causar superlotações na sala de espera, algo muito inadequado para as condições dos pacientes oncológicos. A simulação permitiu identificar alterações mais promissoras, não apenas acelerando os testes para encontrar cenários de maior produtividade, mas também prevenindo que mudanças ruins sejam testadas na operação real.

As principais contribuições deste artigo são:

1. A modelagem da fase de tratamento de um processo real de radioterapia, fornecendo detalhes de sua implementação.
2. Modelo de simulação mais representativo da realidade do processo em termos de validade e confiabilidade quando comparado com outros da literatura.
3. Realização de diferentes tipos de experimentos para analisar o comportamento da operação para diferentes cenários de modo a prever o comportamento do sistema e identificar oportunidades de melhoria.

Este trabalho está organizado da seguinte forma: a Seção 2 traz uma revisão da literatura, a Seção 3 apresenta o modelo de simulação do processo de radioterapia, incluindo a análise e tratamento dos dados de entrada e a descrição do modelo computacional. A Seção 4 descreve os experimentos realizados, começando pelo dimensionamento do número de replicações, passando pela validação do modelo por meio de uma comparação com o sistema real, e a realização experimentos de comparação de alternativas e experimentos fatoriais. A Seção 5 apresenta as considerações e conclusões do trabalho.

2. Revisão Bibliográfica

A simulação em ambientes hospitalares evoluiu nas últimas décadas, aumentando-se o número de pesquisas nesta área e os benefícios em sua implementação. De acordo com o estudo de Almagoshi (2015), observou-se que a técnica SED e o *Software* ARENA são a combinação mais utilizada em pesquisas aplicando a simulação em hospitais.

Dentre as pesquisas realizadas, algumas são gerais, como Gutiérrez et al. (2009) e Dos Santos et al. (2017) que focam diversos sistemas hospitalares, e algumas são específicas para o setor oncológico, com destaque para a radioterapia e a quimioterapia. A aplicação de simulação na radioterapia é destacada por Werker et al. (2009), Kapamara et al. (2007) e por Sarmento et al. (2018), demonstrando que pequenas alterações podem reduzir o tempo de tratamento e apresentar melhorias no processo. Os autores também mostraram ser possível identificar oportunidades de eliminação de desperdícios, aumentando as chances de sucesso do tratamento do paciente.

A Tabela 1 avalia algumas pesquisas relacionadas ao contexto oncológico e ajuda a situar o presente trabalho na literatura. Nela, descreve-se o *software* utilizado, tipo de simulação realizada, sua aplicação e objetivo. Ao destacar as pesquisas voltadas diretamente à radioterapia, os *softwares* mais utilizados foram o SIMUL8 e o ARENA. Também se observa que SED foi a técnica de simulação mais utilizada. Quanto ao tipo de aplicação, radioterapia e quimioterapia foram os mais comuns. E finalmente, quanto ao contexto do trabalho, destaca-se a redução do tempo de espera do paciente.

Em Werker et al. (2009), o modelo de simulação tem início na criação de imagens, quando os dados estão prontos para o planejamento. Cria-se um plano único para cada paciente, necessitando de um oncologista no processo de verificação, consulta do físico responsável, geração de doses, verificação e aprovação de planos de tratamento. Já Babashov et al. (2017), desenvolve um modelo que tem como objetivo a redução da duração dos dias necessários de todos os exames, planejamento e execução até o primeiro dia em que o paciente é tratado na radioterapia, em média o tempo observado é de 14 dias.

Dentre os trabalhos citados, observa-se algumas limitações, por exemplo, Werker et al. (2009), utiliza tempos sugeridos pela percepção dos técnicos responsáveis, onde esse tempo e porcentagem de ocorrência podem ser diferentes do real, pois não foram cronometrados em loco. Além disto, possui um valor fixo na porcentagem de retrabalhos, apontado por uma entrevista com o físico, o que pode reduzir a representatividade do modelo. Em Babashov et al. (2017), utilizou-se dados de pacientes do período de 2009 a 2010, sendo que o trabalho foi realizado em 2017, ou seja, os dados utilizados provavelmente já não eram mais válidos, ou pelo menos, nada foi argumentado mostrando que tais dados antigos ainda eram válidos para o período em que o estudo foi realizado.

Tabela 1: Literatura relacionada.

Autor (es)	Ano	Software	Tipo de simulação	Tipo de aplicação	Objetivo
Munro e Potter	1994	Excel	Monte Carlo	Radioterapia	Reduzir o tempo de espera para a radioterapia
Kapamara et al.	2007	Simul8	SED	Radioterapia	SED de um processo de radioterapia
Conforti, Guerriero e Guido	2008	Não informado	Não informado	Planejamento	Otimização para agendamento na radioterapia
Barett et al.	2008	Não mencionado	SED	Quimioterapia	SED aplicado à pediatria oncológica
Werker et al.	2009	Arena	SED	Radioterapia	SED em planejamento do processo de radioterapia
Gutiérrez et al.	2009	Simulink	SED	Processos hospitalares	Otimização do sistema hospitalar
Morgan, Howick e Belton	2011	Simul8	SED e SD	Radioterapia	Complementação do uso de SED e Sistemas Dinâmicos
Wang et al.	2012	Simul8	SED	Radioterapia	Análise do fluxo de pacientes na radioterapia
Ceballos et al.	2014	Arena	SED	Geral	SED aplicado a áreas da saúde
Almagooshi	2015	Diversos	Teórico	-	Revisão da literatura de modelos de simulação em ambientes hospitalares
Liang et al.	2015	Anylogic	SED	Quimioterapia	Melhoria do fluxo de pacientes e agendamento na quimioterapia
Marcelino et al.	2015	Arena	SED	Geral	Estudo de caso de um hospital
Dos Santos et al.	2017	Arena	SED	Geral	Análise do tempo de espera em um hospital
Babashov et al.	2017	Simul8	SED	Radioterapia	Redução do tempo de espera e melhoria do planejamento na radioterapia
Sarmento et al.	2018	Arena	SED	Quimioterapia e Radioterapia	Mapeamento do fluxo de valor e simulação em hospital oncológico
Lindberg et al.	2019	Não mencionado	SD	Radioterapia	Modelo dinâmico para melhoria do fluxo de pacientes na radioterapia
Saberi e Awasthi	2019	ARENA	Monte Carlo	Radioterapia	Modelo de otimização para redução do tempo de espera
Presente trabalho	2021	ARENA	SED	Radioterapia	Modelo de otimização para o tratamento diário em radioterapia

Fonte: Elaborado pelos Autores.

No presente trabalho, todos os dados e os valores de tempo foram obtidos através de observações do sistema real, coletando-se as informações diárias dos pacientes através de estudos

de tempo feitos por meios de cronometragem, buscando refletir a realidade no modelo simulado. Foram realizados diversos experimentos para analisar o comportamento da operação para diferentes cenários de modo a identificar oportunidades de melhoria.

3. Modelo de Simulação

A apresentação do modelo de simulação é dividida em duas partes, o modelo conceitual, que explica o funcionamento do sistema real, e o modelo computacional, onde executa-se a simulação do modelo conceitual.

No modelo conceitual, o processo estudado tem início com a chegada do paciente na sala de espera do setor de radioterapia para o tratamento diário, analisando-se o tempo do paciente na sala de espera e o tempo da sessão de tratamento. Todo paciente possui um horário agendado previamente, sendo que cada janela de agendamento (*slot*) possui duração de 10 minutos. É comum que o tratamento radioterápico de um paciente tenha de 20 a 30 sessões diárias. A janela ou *slot* de agendamento refere-se ao tempo reservado no sistema de agendamento para a realização do tratamento. Como o agendamento possui um horário fixo de 10 minutos, o tempo real da sessão de tratamento pode ser diferente do planejado. Também é possível que um paciente falte, o que em alguns momentos ameniza a formação de filas. Visando prevenir a ociosidade e aumentar a capacidade do sistema de atendimento, os gestores permitem a criação de um *slot* duplicado no agendamento de pacientes, gerando-se um novo *slot* por hora em um mesmo horário já existente.

A chegada dos pacientes é aleatória, portanto, pode ser que se dê de forma antecipada, tardia, no horário agendado ou então pode ocorrer que o paciente não compareça à sessão de tratamento. Os pacientes são atendidos conforme a hora agendada, e não conforme a hora de chegada. Caso um paciente atrase, pode ocorrer de outro paciente ser atendido antes do horário planejado.

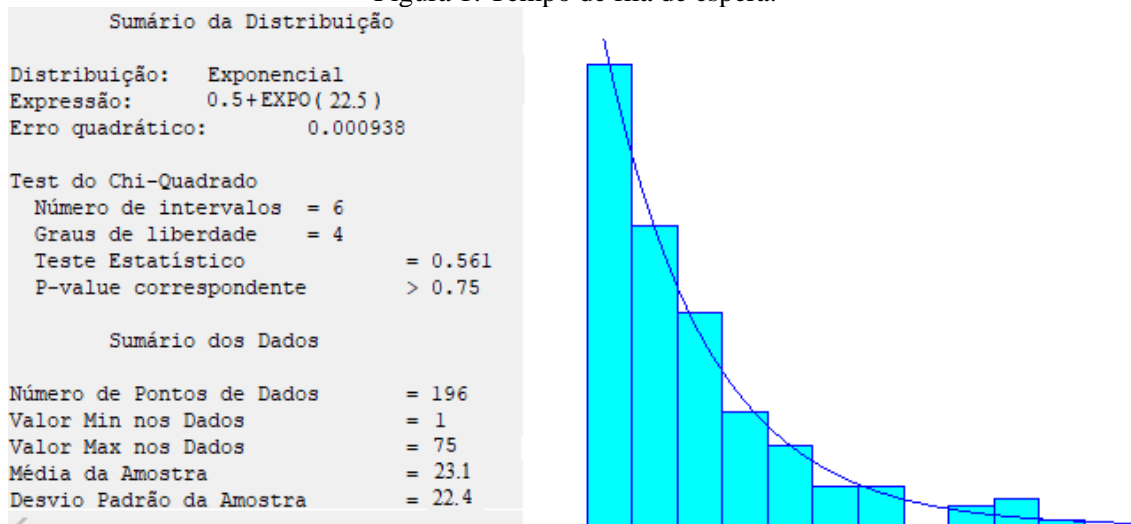
Em relação à equipe de técnicos de radioterapia, em condições ideais, utiliza-se dois técnicos simultaneamente para a execução do processo de forma eficiente, podendo haver mais ou menos técnicos. Há momentos em que é possível haver apenas um técnico, por exemplo, quando há uma sessão de tomografia e este técnico está encarregado de sua execução. Neste caso, o técnico ausenta-se por alguns minutos para realizar a sessão de tomografia, e retorna ao seu posto original de trabalho. Em casos que há apenas um técnico realizando as operações do tratamento radioterápico, foi observado que o tempo de tratamento foi maior do que quando possui dois técnicos trabalhando, porém, não existe diferença significativa de tempo quando há mais do que dois técnicos na atividade. Desta forma, as sessões de tomografia devem ser incluídas no modelo computacional pois interferem no tempo de uma sessão de tratamento.

3.1. Análise e Tratamentos dos Dados de Entrada

Foram coletadas, através de cronoanálise, 233 amostras de dados dos pacientes tratados no setor de radioterapia. Com as amostras coletadas, foram feitas análises quanto às seguintes métricas: tempo de espera, tempo de tratamento e o tempo de chegada do paciente em relação ao tempo agendado (atrasos e antecipações). Os dados foram analisados separadamente para cada uma das métricas, fazendo-se um tratamento de dados que consiste na remoção de *outliers* e confirmação de que os dados são independentes e identicamente distribuídos. Para identificar as expressões matemáticas do problema, utilizou-se o *software Input Analyzer*, uma ferramenta estatística presente no ARENA, que permite identificar uma função distribuição de probabilidade que se ajuste adequadamente aos dados.

Pode-se observar na Figura 1, a análise do tempo de espera dos pacientes obtida pelo *Input Analyzer*, onde identifica-se um *p-value* alto e um erro quadrático baixo, evidenciando que os dados são adequadamente representados por uma distribuição exponencial de expressão $0.5 + EXPO(22.5)$ minutos.

Figura 1: Tempo de fila de espera.



Fonte: Elaborado pelos Autores.

Realizando-se as análises da Figura 1 para as demais métricas, observa-se na Tabela 2 a distribuição e a expressão matemática de cada métrica, que serão dados de entrada do modelo computacional.

Tabela 2: Distribuição e expressão.

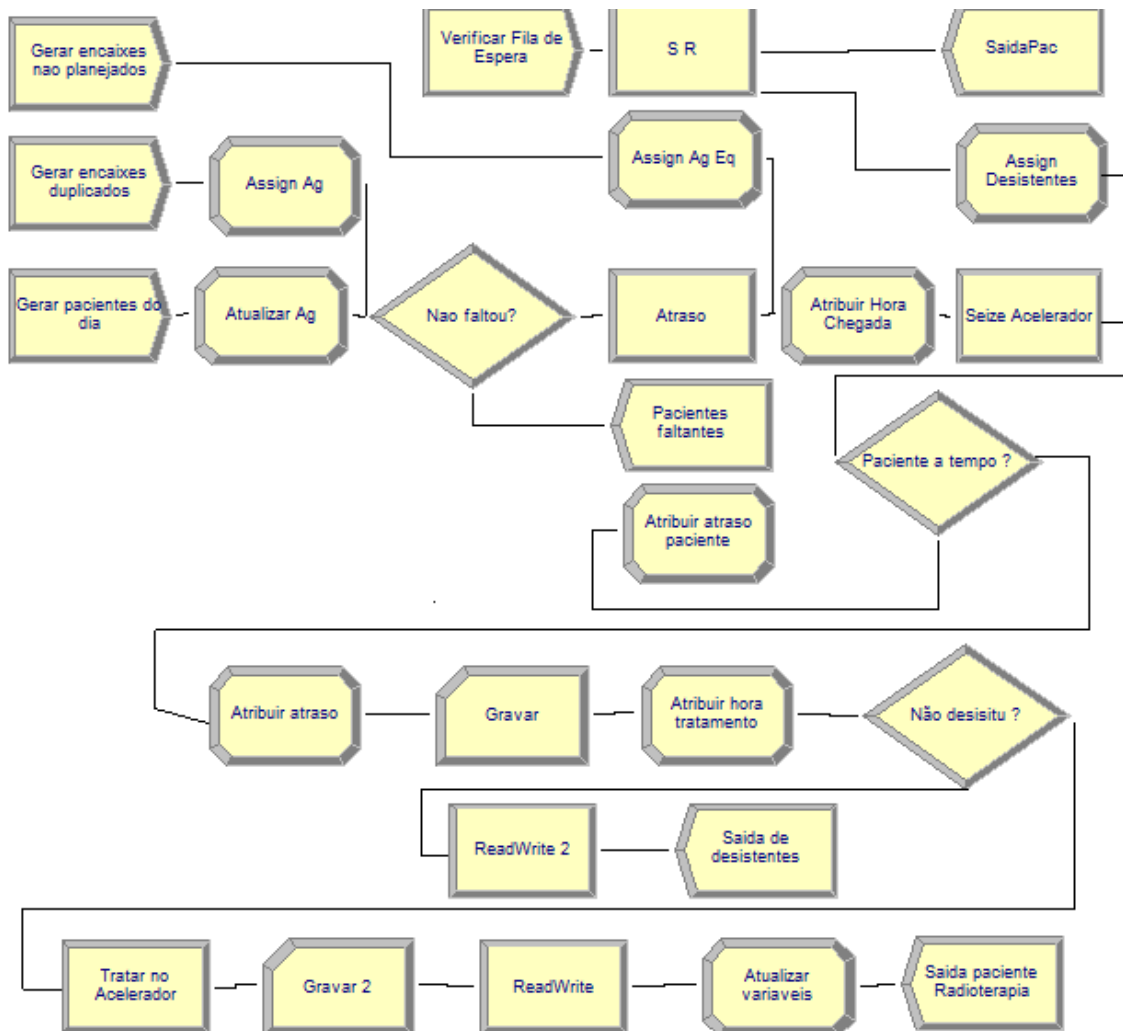
Métricas	Distribuição	Expressão
Tempo de espera	Exponencial	$0.5 + EXPO(22.5)$
Tempo de tratamento	Lognormal	$5.5 + LOGN(3.85, 4.54)$
Tempo de chegada em relação ao tempo agendado	Gama	$0.5 + GAMM(8.64, 1.26)$
Gerar encaixes não planejados	Exponencial	$EXPO(60)$
Atraso para ajustar tempo chegada	Gama	$Hora\ agendada - (-18 + GAMM(19.7, 2.3))$
Tempo da tomografia	Normal	$NORM(12,3)$
Tempo do acelerador p/ 2 técnicos	Beta	$5 + 12 * BETA(1.02, 2.69)$
Tempo do acelerador >2 técnicos	Normal	$NORM(11.5,3)$
Tempo de morning Check Out	Normal	$NORM(15,2)$

Fonte: Elaborado pelos Autores.

3.2. Modelo de Simulação

O modelo computacional é dado pela Figura 2. O modelo foi criado a partir do modelo conceitual, implementando-se suas regras lógicas no *software* de simulação Arena. O modelo desenvolvido possui quatro entradas de dados principais, sendo elas: gerar pacientes do dia, gerar encaixes duplicados, gerar encaixes não planejados, verificar fila de espera.

Figura 2: Modelo computacional.



Fonte: Elaborado pelos Autores.

O fluxo principal começa com o módulo “Gerar pacientes do dia”, onde é atribuído a chegada do paciente na sala de espera da radioterapia, sendo seu horário agendado de tratamento atualizado no módulo “Atualizar Ag”. Caso o paciente agendado não tenha faltado, o módulo “Atraso” do tipo *delay* atribui um atraso à entidade de valor conforme a métrica “Atraso para ajustar tempo chegada” da Tabela 2; a seguir atribui-se a hora de chegada do paciente à respectiva entidade e então o módulo “Seize Acelerador” marca o início da utilização do acelerador linear de tratamento pelo paciente. Caso o paciente tenha chegado ao setor após o horário agendado, calcula-se o atraso do paciente, e o módulo “Atribuir atraso” calcula o atraso do processo. Os módulos “Gravar” e “Atribuir hora tratamento” armazenam o tempo decorrido desde a chegada do paciente e o momento de início do tratamento. Caso o paciente que compareceu não tenha desistido de esperar na sala de espera, o módulo “Tratar no acelerador” simula o tempo de tratamento no acelerador, e os módulos seguintes armazenam num arquivo Excel as estatísticas utilizadas na análise.

Ainda na Figura 2, o módulo “Gerar encaixes duplicados”, gera os *slots* duplicados de planejamento, ou seja, permite-se agendar dois pacientes no mesmo horário no último *slot* de cada hora. O módulo “Gerar encaixes não planejados” é responsável pela criação de *slots* onde o paciente não possui um horário fixo, como em casos de pacientes urgentes que estão internados. O módulo “Verificar fila de espera” é utilizado para observar se o paciente chegou no horário, observando o comportamento da fila de espera do tratamento, iniciando o módulo “*search and remove*”, abreviado no sistema por “S R”, que consistem em tratar o caso em que o paciente vai

para o hospital, mas após esperar por tempo muito longo, desiste de realizar a sessão daquele dia. Caso o paciente espere mais de 60 a 90 minutos há 30% de chance de desistência, caso espere mais de 90 minutos há 70% de chance.

O sistema possui mecanismos para observar se o paciente faltou ou se chegou atrasado, ajuste do sistema de filas para os pacientes que não estavam planejados naquele horário, adiantamento de paciente caso outro tenha faltado, entre outros. Essas funcionalidades são importantes para que o modelo simulado tenha um comportamento equivalente ao real.

4. Experimentos

Este tópico descreve os experimentos realizados, começando pelo dimensionamento do número de replicações, passando pela validação do modelo por meio de uma comparação com o sistema real; e a realização de experimentos de comparação de alternativas e fatoriais.

4.1. Estudo Preliminar

No modelo elaborado, é possível identificar e determinar o número de replicações necessárias para a execução do modelo computacional, de forma que, seja capaz de atender as especificações de confiança estatística. Para isso, utilizamos a equação (1), baseada em Truong et al. (2015), onde N é o número de replicações necessárias, s é o desvio padrão, \bar{x} é a média da amostra, ε é o erro percentual máximo da média, $t_{N-1, 1-\alpha/2}$ é o valor da estatística na tabela da distribuição *t-Student* bicaudal, com $N - 1$ graus de liberdade.

$$N = \left\lceil \left(\frac{st_{N-1, 1-\alpha/2}}{\bar{x}\varepsilon} \right)^2 \right\rceil \quad (1)$$

Para o cálculo da quantidade necessária de replicações da simulação, foi utilizado a saída do último paciente, que representa o horário em minutos da saída do último paciente atendido na radioterapia, levando em consideração que o tempo inicial 0 refere-se ao início do sistema real, no caso, 06:30 da manhã.

Tabela 3: Replicações necessárias.

Métrica	Tempos
Média	777,43
Desvio padrão	53,45
Z	2,09
Erro % máximo	0,025
Replicações (N)	33,12

Fonte: Elaborado pelos Autores.

Foi obtido o valor de N igual a 33,12, com isso, realizou-se 34 replicações da simulação, como podemos observar na Tabela 3.

4.2. Validação do Modelo Computacional

Para validar o modelo computacional, comparou-se o sistema real com o simulado através da comparação de três métricas, sendo elas: tempo de saída do último paciente, proporção de pacientes com espera e proporção de pacientes com espera entre 0 e 30 minutos.

A simulação foi realizada utilizando os dados de 2020, onde a média de tratamentos diários foi de 73 pacientes, utilizando 10 técnicos de radioterapia e *slot* de tratamento de 10 minutos. Os resultados da simulação e a comparação com os dados do sistema real são apresentados na Tabela

4. O momento de saída do último paciente é contabilizado em minutos de forma corrida, sendo o minuto 0 dado pelo momento de início do primeiro turno de trabalho.

Tabela 4: Comparação do sistema real e simulado.

RESULTADO	REAL	SIMULADO
Momento de saída do último paciente (minutos)	774,9	777,0
Desvio-padrão do Tempo de saída do último paciente (minutos)	17,0	15,7
Proporção de pacientes com espera	31,04%	31,10%
Proporção de pacientes com espera entre 0 e 30 minutos.	30,62%	31,06%

Fonte: Elaborado pelos Autores.

Para comparar as médias do tempo de saída, inicialmente fez-se um teste de Levene para comparar as variâncias. Dado que o teste mostrou não haver diferença significativa ($p - \text{valor} = 0,696$), prosseguiu-se com o teste *t-Student* para comparar as médias, assumindo-se variância iguais.

Tabela 5: Comparação de médias e proporções.

MÉTRICA	P-valor	IC
Média do Tempo de saída do último paciente (minutos)	0,599	(-10,03; 5,83)
Proporção de pacientes com espera	0,6146	(-0,022; 0,037)
Proporção de pacientes com espera entre 0 e 30 minutos.	0,7966	(-0,210; 0,273)

Fonte: Elaborado pelos Autores.

A Tabela 5 mostra o p-valor e o intervalo de confiança (IC) para a diferença. Nela vemos que não há diferenças estatísticas significativas entre o sistema real e simulado, evidenciando que o comportamento do modelo de simulação é equivalente ao sistema real.

4.3. Comparação de Alternativas

Realizou-se dois tipos de experimentos. O processo utiliza 10 minutos como tempo planejado para cada paciente, e os gestores consideram importante saber como seria o comportamento do processo para diferentes valores já que possuem receio de fazer testes diretamente na prática, considerando o grau de sensibilidade dos pacientes caso um teste seja mal sucedido. Os gestores também deixaram claro que o objetivo é aumentar a quantidade de pacientes atendidos diariamente, sem prejudicar o tempo de espera. Assim, o primeiro experimento, apresentado na Tabela 6, buscou identificar o melhor tempo de *slot*, fixando-se o número de pacientes e de técnicos nos níveis atualmente encontrados na operação, e alterando-se apenas o tempo de *slot*. Como resposta, comparou-se o tempo de saída do último paciente, a porcentagem de pacientes com espera e a porcentagem de pacientes com espera de 0 a 30 minutos. Surpreendentemente, os resultados mostram que o melhor desempenho ocorreu para o *slot* de 10 minutos, já utilizado pela operação, que obteve o tempo de saída mais cedo do último paciente, com um tempo de espera ainda adequado, com pouquíssimos pacientes aguardando mais de 30 minutos ($31,93\% - 31,57\% = 0,36\%$).

Tabela 6: Comparação de tempo de *slot*.

	Métrica	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Entradas	# Pacientes (quantidade)	73	73	73	73
	# Técnicos (quantidade)	9	9	9	9
	Tempo <i>slot</i> (minutos)	10	9	11	8
	<i>Slot</i> duplicado	sim	sim	sim	sim
Saídas	Saída do último paciente (minuto)	774,54	777,02	840,17	841,63
	% Pacientes com Espera	31,93	60,37	26,62	71,92
	% Pacientes com Espera de até 30 minutos	31,57	52,29	26,38	46,81

Fonte: Elaborado pelos Autores.

Considerando-se também o desejo dos gestores em aumentar a capacidade da operação, o segundo experimento teve como objetivo identificar o melhor número de técnicos caso haja necessidade de aumentar o número de pacientes agendados por dia (de 73 para 95), mantendo-se constante o tempo de *slot* e o número de pacientes, como observado na Tabela 7.

Tabela 7: Comparação de técnicos de radioterapia.

	Métrica	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Entradas	# Pacientes (quantidade)	95	95	95	95
	# Técnicos (quantidade)	9	10	11	12
	Tempo <i>slot</i> (minutos)	10	10	10	10
	<i>Slot</i> duplicado	sim	sim	sim	sim
Saídas	Saída do último paciente (minutos)	897,98	900,6	901,49	900,59
	% Pacientes com Espera	55,81	54,3	55,65	55,26
	% Pacientes com Espera de até 30 minutos	43,45	45,42	46,48	43,97

Fonte: Elaborado pelos Autores.

De acordo com os resultados obtidos, a alteração do número de técnicos no intervalo [9,12] não interfere de forma significativa no tempo de saída do último paciente e nas porcentagens de pacientes com espera. Os técnicos da radioterapia podem ser alocados de modo que o primeiro turno comece às 6:30 e o terceiro turno termine às 21:42, totalizando 912 minutos. Ou seja, os resultados da Tabela 7, referentes à métrica “Saída do último paciente” não resultam em horas extras.

4.4. Experimentos Fatoriais

Com a intenção de entender a significância de cada fator relacionado ao sistema, foi realizado um experimento fatorial 2^3 , considerando como fatores: o número de pacientes, o número de técnicos, e se haverá ou não a utilização de *slot* duplicado (ou seja, se será ou não permitido agendar dois pacientes no mesmo horário uma vez a cada hora do dia).

Os valores dos fatores podem ser observados na Tabela 8, e as interações e o resultado do último paciente atendido na Tabela 9.

Tabela 8: Valores dos fatores.

Fator	Pacientes	Técnicos	Slot duplicado
-	73	9	Não
+	95	12	Sim

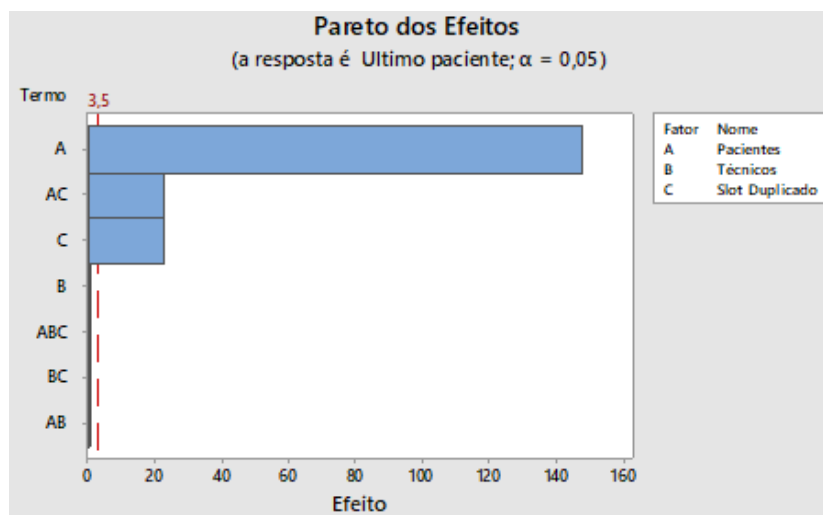
Fonte: Elaborado pelos Autores.

Tabela 9: Interações.

Paciente	Técnico	Slot Duplicado	Último paciente
-	-	-	775,33
+	-	-	944,56
-	+	-	775,64
+	+	-	947,03
-	-	+	775,31
+	-	+	900,60
-	+	+	775,64
+	+	+	900,59

Fonte: Elaborado pelos Autores.

Figura 3: Pareto de Efeitos.



Fonte: Elaborado pelos Autores.

A partir dos resultados da Tabela 9, por meio do *software* estatístico MINITAB, gerou-se a Figura 3. Nele, ficou evidente que os fatores que influenciam de forma mais significativa no sistema são: o número de pacientes planejados para o tratamento diário, a utilização do *slot* duplicado e a interação do *slot* duplicado com o número de pacientes. Além disso, o fator “número de pacientes planejados para o tratamento diário” possui significância aproximadamente 5 vezes maior que os outros dois fatores significantes.

Esta descoberta motivou a realização de um novo experimento, variando-se o número de pacientes planejados no intervalo de 70 a 110 pacientes, em incrementos de 5 pacientes, utilizando-se *slots* duplicando e 9 técnicos, obtendo-se os resultados apresentados na Tabela 10 e nas regressões da Figura 4.

De acordo com a Tabela 10 e a Figura 4, quanto maior o número de pacientes agendados, maior é o tempo de saída do último paciente. Algo semelhante ocorre para a proporção de pacientes que precisam esperar para serem atendidos. Estas duas métricas foram adequadamente aproximadas por uma regressão linear. Já em relação ao tempo de espera entre 0 e 30 minutos, a regressão é não linear. Isto faz sentido pois a proporção de espera cresce à medida que número de pacientes cresce até um certo ponto, a partir do qual, a espera irá superar os 30 minutos e consequentemente a proporção dentro do intervalo [0,30] irá diminuir. Estas regressões permitem à operação estimar o que ocorrerá com o processo para uma quantidade planejada de pacientes entre 70 e 110, quanto à proporção de esperas e o horário de término do último paciente, sendo este relacionado às horas extras na operação. Neste estudo de regressões, não se identificou anomalias em relação aos resíduos.


Tabela 10: Resultados para diferentes quantidades de pacientes planejados diariamente.

Pacientes planejados	Saída do último paciente atendido do dia, em minutos	Proporção de pacientes com espera	Proporção de pacientes com espera entre 0 e 30 minutos.
70	803,27	33,35%	33,35%
75	788,13	39,22%	37,15%
80	806,28	41,28%	36,86%
85	843,38	37,79%	36,07%
90	883,45	42,34%	39,47%
95	899,66	49,74%	40,31%
100	923,22	67,61%	42,88%
105	934,04	74,90%	33,62%
110	946,00	76,13%	26,69%

Fonte: Elaborado pelos Autores.

Os resultados da Tabela 10 mostram ser possível atender 95 pacientes por dia, com uma proporção aceitável de tempo de espera e sem hora extra; já que o tempo médio de saída do último paciente ocorre no minuto 899,96 e o horário de atendimento tem uma duração de 912 minutos.

Figura 4: Regressões polinomiais.



Fonte: Elaborado pelos Autores.

5. Conclusões

A utilização de Simulação de Eventos Discretos é uma importante ferramenta para apoiar tomadas de decisão na gestão de operações, entre elas, a área de radioterapia, como demonstrado neste trabalho. Inicialmente realizou-se a descrição do sistema e sua modelagem computacional, encontrou-se o dimensionamento adequado do número de replicações e em seguida foi feita a validação do sistema computacional em relação ao real, realizando-se testes estatísticos que demonstraram que os resultados da simulação são equivalentes ao sistema real.

Uma série de experimentos foram realizados para estudar-se diferentes alternativas para o sistema, contribuindo no entendimento e comportamento das variáveis. Descobriu-se que para o nível atual de demanda, o tamanho de *slot* mais adequado é de 10 minutos. A seguir, os experimentos que testaram aumentar a quantidade de técnicos mostraram que não houve melhorias significativas no tempo de saída dos pacientes e proporção de pacientes com espera. Os experimentos fatoriais permitiram identificar que o número de pacientes planejados possui uma significância muito maior que os demais fatores. Motivado por esta descoberta, realizou-se um

experimento para medir com mais clareza a relação entre o número de pacientes e as variáveis de resposta.

Os resultados permitiram aos gestores da operação aprender que convém trabalhar com slots de 10 minutos e que é possível aumentar a quantidade diária de pacientes agendados de 73 para 95 pacientes, sem impactos significativos no tempo de espera e nas horas extras, um aumento de aproximadamente 30%. Descobrir que uma variável em particular (quantidade de pacientes planejados) tem muito mais peso que as demais, tornou possível fazer regressões lineares que permitem aos gestores estimar o desempenho da operação.

Trabalhos futuros podem incluir a aplicação da simulação envolvendo múltiplos aceleradores no sistema e o uso de algoritmos de otimização para encontrar a melhor configuração dos parâmetros de entrada. Também pode-se desenvolver uma automação cuja interface permita aos gestores da operação fazerem simulações sem necessidade de interagir diretamente com o modelo do Arena.

Agradecimentos. Os autores agradecem o apoio dos colaboradores e pacientes do Hospital Hélio Angotti, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Universidade Federal do Triângulo Mineiro (UFTM) pelo incentivo à pesquisa.

Referências

- Almagoshi, S. Simulation modelling in healthcare: Challenges and trends. *Procedia Manufacturing*, v. 3, p. 301-307, 2015.
- Babashov, V., Aivas, I., Begen, M. A., Cao, J. Q., Rodrigues, G., D'Souza, D. et al. Reducing patient waiting times for radiation therapy and improving the treatment planning process: a discrete-event simulation model (Radiation Treatment Planning). *Clinical Oncology*, v. 29, n. 6, p. 385-391, 2017.
- Barrett, J. S., Skolnik, J. M., Jayaraman, B., Patel, D. e Adamson, P. C. Discrete event simulation applied to pediatric phase I oncology designs. *Clinical Pharmacology & Therapeutics*, v. 84, n. 6, p. 729-733, 2008.
- Carneiro, W. M. Experimentação em um sistema de filas utilizando a simulação computacional: um estudo de caso. In: *Anais do XXVIII Encontro Nacional de Engenharia de Produção*, Rio de Janeiro. ABEPRO, 2008.
- Ceballos, F., Betancur Villegas, J. P. e Betancur Villegas, J. D. Simulación discreta aplicada a los modelos de atención en salud. *Investigación e Innovación en Ingenierías*, v. 2, n. 2, p.10-14, 2014.
- Conforti, D., Guerriero, F. e Guido, R. Optimization models for radiotherapy patient scheduling. *4OR*, v. 6, n. 3, p. 263-278, 2008.
- Dos Santos, M., Grossi, M. D., Santos, F. M. C., Walker, R. A. e Paixão, A. C. Melhoria na qualidade do atendimento em um hospital: análise do waiting time utilizando o software ARENA. In: *Anais do XIII Encontro Mineiro de Engenharia de Produção*, Juiz de Fora. 2017.
- Gutiérrez, S., Recalde, D., Guevara, A. e Rivadeneira, G. Optimización del sistema hospitalario ecuatoriano: estudio, modelización, simulación y minimización de tiempos de espera de pacientes de consulta externa. *Revista Politécnica*, v. 30, n. 1, p. 83-90, 2009.

INCA – Instituto Nacional de Câncer. *Brasil terá 625 mil novos casos de câncer a cada ano do triênio 2020-2022*. 2020. Disponível em: <https://www.inca.gov.br/noticias/brasil-tera-625-mil-novos-casos-de-cancer-cada-ano-do-trienio-2020-2022>. Acesso em: 05/06/2020.

Kapamara, T., Sheibani, K., Petrovic, D., Haas, O. C. L. e Reeves, C. A simulation of a radiotherapy treatment system: A case study of a local cancer centre. In: *Proceedings of the ORP3 Meeting*, Guimarães. 2007. p. 29-35.

Law, A. M. e Kelton, W. D. *Simulation Modeling and Analysis*. 3ª ed. New York: McGraw-Hill, 2000. 784p.

Liang, B., Turkcan, A., Ceyhan, M. E. e Stuart, K. Improvement of chemotherapy patient flow and scheduling in an outpatient oncology clinic. *International Journal of Production Research*, v. 53, n. 24, p. 7177-7190, 2015.

Lindberg, J., Holmström, P., Hallberg, S., Björk-Eriksson, T. e Olsson, C. An analytical approach to aggregate patient workflows for system dynamics modelling of radiotherapy. *Radiotherapy and Oncology*, v. 133, n. 1, p. 626-627, 2019.

Marcelino, D. M., Lopes, P. H., Capocci, N. R., Jesus, M. B. M. e Rodrigues, E. F. Simulação: Um estudo de caso de um hospital municipal no estado de São Paulo. *INOVAE*, v. 3, n. 2, p. 34-45, 2015.

Morgan, J., Howick, S. e Belton, V. Designs for the complementary use of system dynamics and discrete-event simulation. In: *Proceedings of the 2011 Winter Simulation Conference*, Phoenix. IEEE, 2011. p. 2710-2722.

Munro, A. J. e Potter, S. Waiting times for radiotherapy treatment: Not all that mysterious and certainly preventable. *Clinical Oncology*, v. 6, n. 5, p. 314-318, 1994.

Saberi, M. e Awasthi, A. Using of optimal simulation modelling to reduce radiotherapy cancer waiting time and improve survival. In: *Proceedings of the International Conference on Industrial Engineering and Operations Management*, Toronto. IEOM, 2019. p. 1289-1301.

Sarmiento, M. C., Sanches, C. B. e Santos, L. C. Mapeamento do fluxo de valor em operações hospitalares: análise e simulação em um hospital oncológico. *Journal of Lean Systems*, v. 3, n. 4, p. 64-89, 2018.

Truong, L. T., Sarvi, M., Currie, G., e Garoni, T. M. How many simulation runs are required to achieve statistically confident results: a case study of simulation-based surrogate safety measures. In: *Proceedings of the 18th International Conference on Intelligent Transportation Systems*, Gran Canaria. IEEE, 2015. p. 274-278.

Wang, J., Li, J., Campbell, A. T., Prather, K., Johnson, B. e Ross, K. Analysis of patient flow in radiation oncology department of Central Baptist Hospital using discrete event simulations. In: *Proceedings of the IIE Annual IE Conference and Expo 2012*, Orlando. IISE, 2012. p. 1488-1497.

Werker, G., Sauré, A., French, J. e Shechter, S. The use of discrete-event simulation modelling to improve radiation therapy planning processes. *Radiotherapy and Oncology*, v. 92, n. 1, p. 76-82, 2009.