



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DO AGRESTE
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

LARISSA THUANY XAVIER E SILVA FELIX

Análise do Fluxo de Pacientes em Serviços de Diagnóstico por Imagem: Uma
Abordagem Baseada em Simulação Computacional

CARUARU

2026

LARISSA THUANY XAVIER E SILVA FELIX

**Análise do Fluxo de Pacientes em Serviços de Diagnóstico por Imagem: Uma
Abordagem Baseada em Simulação Computacional**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção do Centro Acadêmico do Agreste da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de mestre em Engenharia de Produção Área de concentração: Otimização e Gestão da Produção.

Orientador (a): Caio Bezerra Souto Maior

CARUARU

2026

LARISSA THUANY XAVIER E SILVA FELIX

Análise do Fluxo de Pacientes em Serviços de Diagnóstico por Imagem: Uma Abordagem Baseada em Simulação Computacional

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção do Centro Acadêmico do Agreste da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de mestre em Engenharia de Produção Área de concentração: Otimização e Gestão da Produção.

Aprovada em: 23 de fevereiro de 2026.

BANCA EXAMINADORA

Prof Dr. Caio Bezerra Souto Maior (Orientador)

Universidade Federal de Pernambuco – UFPE

Prof. Dr. Lúcio Câmara e Silva (Examinador Interno)

Universidade Federal de Pernambuco – UFPE

Prof. Dr. Luciano Carlos Azevedo da Costa (Examinador Externo)

Universidade Federal da Paraíba – UFPB

CARUARU

2026

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Félix, Larissa Thuany Xavier e Silva.

Análise do Fluxo de Pacientes em Serviços de Diagnóstico por Imagem: uma abordagem baseada em Simulação Computacional / Larissa Thuany Xavier e Silva Félix. - Recife, 2026.

74f.: il.

Dissertação (Mestrado) - Universidade Federal de Pernambuco, Centro Acadêmico do Agreste, Programa de Pós-Graduação em Engenharia de Produção, 2026.

Orientação: Caio Bezerra Souto Maior.

Inclui Referências.

1. Serviços de saúde; simulação computacional; 2. Ressonância magnética; 3. Otimização de processos. I. Maior, Caio Bezerra Souto. II. Título.

UFPE-Biblioteca Central

AGRADECIMENTOS

Antes de tudo, agradeço a Deus pela força, sabedoria e direção em cada etapa desta caminhada, iluminando meus passos e sustentando minhas escolhas.

À minha família, expresso minha mais profunda gratidão, especialmente ao meu esposo e a minha mãe, pelos incentivos e conselhos que foram fundamentais para que eu pudesse prosseguir com coragem e determinação.

Sou igualmente grata aos amigos que, de diferentes formas, me ofereceram apoio e motivação, tornando esta trajetória mais leve.

De forma especial, agradeço ao meu orientador, Caio Souto Maior, pela dedicação, pelas orientações sempre construtivas, pelas ideias compartilhadas e pelo cuidado atento em cada etapa deste trabalho. Sua empatia, nos meus momentos de fragilidade, e comprometimento foram fundamentais para que esta dissertação se concretizasse.

Estendo meus agradecimentos a todos os que compõem o PPGE-CAA, pelo compromisso com uma formação acadêmica de excelência, pelo acolhimento e pelas oportunidades de crescimento.

RESUMO

Este estudo teve como objetivo modelar e simular o fluxo de pacientes em uma clínica de diagnóstico por imagem, com foco nos exames de ressonância magnética (RM), visando reduzir o tempo de espera e melhorar a eficiência operacional. A pesquisa foi conduzida por meio de estudo de caso com abordagem quantitativa, utilizando Simulação de Eventos Discretos (DES), implementada no software FlexSim Healthcare e parametrizada com dados reais do processo assistencial. Foram avaliados quatro cenários: o modelo atual, um cenário reorganizado com otimização da lógica de agendamento, um cenário de ampliação estrutural com inclusão de uma nova máquina de RM e um cenário financeiro integrando custos e receitas. O modelo permitiu identificar gargalos operacionais e avaliar impactos em indicadores como tempo de permanência no sistema, *throughput* e retorno do investimento. Os resultados indicaram que a reorganização operacional reduziu o tempo médio de permanência dos pacientes de 139 para 119 minutos e elevou o *throughput* mensal de 692 para 765 exames, sem necessidade de investimentos adicionais. Nos cenários com expansão tecnológica, a inclusão de uma nova máquina ampliou a capacidade produtiva, com *throughput* mensal variando entre 976 e 1.120 exames. A análise financeira, considerando custos de recursos humanos, manutenção e depreciação, indicou *payback* simples entre 7,5 e 12,6 meses. Como principal contribuição, o estudo demonstra a aplicabilidade da integração entre simulação computacional e análise financeira como ferramenta de apoio à decisão em clínicas privadas de médio porte, oferecendo um modelo replicável para avaliação conjunta de desempenho operacional e viabilidade econômica.

Palavras-chave: Serviços de saúde; simulação computacional; diagnóstico por imagem; ressonância magnética; otimização de processos.

ABSTRACT

This study aimed to model and simulate patient flow in a diagnostic imaging clinic, focusing on magnetic resonance imaging (MRI) examinations, with the objective of reducing waiting times and improving operational efficiency. A quantitative case study approach was adopted, employing Discrete Event Simulation (DES) implemented in FlexSim Healthcare and parameterized using real operational data from the clinic. Four scenarios were analyzed: the current operational model; a reorganized scenario based on scheduling optimization; a structural expansion scenario involving the addition of a new MRI machine; and a financial scenario integrating cost and revenue analysis. The simulation model enabled the identification of operational bottlenecks and the evaluation of key performance indicators, including time in system, throughput, and return on investment. Results showed that workflow reorganization reduced the average patient time in the system from 139 to 119 minutes and increased monthly throughput from 692 to 765 examinations without additional capital investment. In the expansion scenarios, the introduction of a new MRI unit substantially increased productive capacity, with monthly throughput ranging from 976 to 1,120 examinations. The financial assessment, incorporating staffing costs, maintenance, and equipment depreciation, indicated a simple payback period between 7.5 and 12.6 months. The study demonstrates the value of integrating computational simulation with financial analysis as a decision-support tool for medium-sized private imaging clinics, offering a replicable framework for jointly assessing operational performance and economic feasibility.

Keywords: Healthcare services; computer simulation; diagnostic imaging; magnetic resonance imaging; process optimization.

LISTA DE ILUSTRAÇÕES

Figura 1 - Organização dos níveis de atenção à saúde.....	20
Figura 2 - Abordagens de simulação em saúde.....	23
Figura 3 - Metodologia do estudo.	35
Figura 4 - Mapa do fluxo assistencial.	38
Figura 5 - Frequência de observações por tipo de exame.	40
Figura 6 - Fluxo de execução de exame no Flexsim.	42
Figura 7 - Tempo de permanência no sistema em minutos.....	44
Figura 8 - Quantidade de pessoas atendidas em 5 dias.	44
Figura 9 - Média de tempo de cada setor realizando atividades.....	46
Figura 10 -Tempo de permanência no sistema no cenário 2.	49
Figura 11 - Quantidade de pessoas atendidas no cenário 2.	49
Figura 12 - Média de tempo de cada setor realizando atividades no cenário 2.....	49
Figura 13 - Tempo de permanência no sistema no cenário 3.	51
Figura 14 - Quantidade de pessoas atendidas no cenário 3.	51
Figura 15 - Média de tempo de cada setor realizando atividades no cenário 3.....	52
Figura 16 - Quantidade de pessoas atendidas no cenário 4.	53
Figura 17 - Tempo de permanência no sistema no cenário 4.	53
Figura 18 - Média de tempo de cada setor realizando atividades no cenário 4.....	54

LISTA DE TABELAS

Tabela 1- Comparação das principais abordagens de simulação aplicadas à saúde e suas evidências na literatura.....	28
Tabela 2 - Frequência e distribuição de tempo de setup.....	41
Tabela 3 - Distribuição de tempo de realização de exame.....	41
Tabela 4 - Custos mensais com recursos humanos no cenário com três RM.....	56
Tabela 5 - Parâmetros e cálculo da depreciação unitária das máquinas de RM.....	57
Tabela 6 - Receita mensal estimada por cenário.....	59
Tabela 7- Síntese comparativa de vantagens e restrições dos cenários analisados	61
Tabela 8 - Viabilidade econômica e retorno do investimento	64

SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	CONTRIBUIÇÕES.....	16
1.2	OBJETIVOS.....	17
1.2.1	OBJETIVO GERAL.....	17
1.2.2	OBJETIVOS ESPECÍFICOS.....	17
1.3	ESTRUTURA DO DA DISSERTAÇÃO.....	18
2	FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA.....	19
2.1	PRESTAÇÃO DE SERVIÇOS EM SAÚDE E GESTÃO DE PROCESSOS.....	19
2.2	SIMULAÇÃO COMPUTACIONAL APLICADA À SAÚDE.....	21
2.3	APLICAÇÕES PRÁTICAS DE SIMULAÇÃO EM SERVIÇOS DE SAÚDE.....	30
2.4	LIMITAÇÕES E OPORTUNIDADES DA LITERATURA.....	32
3	METODOLOGIA.....	34
3.1	CARACTERIZAÇÃO DA PESQUISA.....	34
3.2	CARACTERIZAÇÃO DO PROBLEMA.....	35
3.3	ORIGEM E PARAMETRIZAÇÃO DOS DADOS.....	36
3.4	SOFTWARE ESCOLHIDO.....	37
4	APLICAÇÃO NA ÁREA DE SAÚDE.....	38
4.1	CENÁRIO ATUAL.....	38
4.1.1	Modelagem no Flexsim Healthcare.....	42
4.2	CENÁRIO 2: REORGANIZAÇÃO DA SEQUÊNCIA E LÓGICA DE AGENDAMENTO.....	46
4.2.1	Construção do novo fluxo.....	46
4.2.2	Alternância estratégica entre exames curtos e longos.....	47
4.2.3	Estruturação de intervalos operacionais entre blocos.....	48
4.3	CENÁRIO 3: AMPLIAÇÃO DA CAPACIDADE TECNOLÓGICA.....	50

4.4	CENÁRIO 4: ANÁLISE INTEGRADA DE EXPANSÃO ESTRUTURAL E OTIMIZAÇÃO OPERACIONAL	52
4.5	ANÁLISE FINANCEIRA INTEGRADA À SIMULAÇÃO	55
4.5.1	Estrutura de custos considerados	55
4.5.2	Estimativa de receita por throughput.....	57
4.5.3	Análise comparativa dos cenários	59
4.5.4	Viabilidade econômica e retorno do investimento.....	62
5	CONCLUSÃO	66
	REFERÊNCIAS	69

1 INTRODUÇÃO

O propósito fundamental dos sistemas de saúde é proporcionar serviços acessíveis, assegurar atendimentos médicos pontuais e maximizar a satisfação dos pacientes. Esses sistemas têm papel importante no bem-estar da sociedade pois são responsáveis por garantir a manutenção da saúde, a prevenção de doenças e a recuperação dos indivíduos (PORTER, 2010). Além disso, impactam diretamente indicadores sociais e econômicos, como a produtividade da população, a redução da mortalidade evitável e a equidade no acesso aos serviços essenciais (IMPROTA *et al.*, 2020; LARRAIN; GROENE, 2021).

Neste contexto, as organizações de saúde enfrentam desafios crescentes relacionados à gestão operacional, aumentando a busca por métodos que permitam otimizar processos, reduzir custos e aumentar a eficiência dos serviços prestados (BANIK *et al.*, 2023). Entre os principais problemas enfrentados estão o tempo excessivo de espera dos pacientes (AHMAD *et al.*, 2021), alocação ineficiente de recursos humanos e físicos (BAHARI; ASADI, 2020), o desequilíbrio entre demanda e capacidade (SHAKOOR *et al.*, 2021), além da falta de integração entre os diferentes setores dos serviços de saúde (LARRAIN; GROENE, 2021). Tempo de espera no atendimento em serviços de diagnóstico por imagem é influenciado por múltiplos fatores operacionais e clínicos. No caso da ressonância magnética, a complexidade dos exames constitui uma variável crítica, podendo demandar entre 20 e 60 minutos, a depender do protocolo adotado e da necessidade de contraste.

Além disso, a variabilidade do perfil dos pacientes impacta significativamente o processo: idosos, indivíduos com mobilidade reduzida ou condições clínicas específicas exigem maior tempo de preparação, enquanto situações como claustrofobia podem levar à repetição ou interrupção do exame (SHAKOOR *et al.*, 2021). Soma-se a isso o tempo de setup entre procedimentos, que envolve limpeza da sala, troca de bobinas e ajustes técnicos no equipamento, acrescentando minutos relevantes ao ciclo operacional e gerando períodos alternados de sobrecarga e ociosidade (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012). O efeito acumulado dessas variabilidades impacta diretamente a capacidade produtiva da clínica: em unidades privadas de médio porte, um equipamento de ressonância magnética

realiza, em média, entre 15 e 25 exames por dia, dependendo da eficiência do agendamento e da disponibilidade da equipe (CAI; JIA, 2019). Quando falhas de gestão ocorrem como atrasos, sobreposição de agendamentos ou indisponibilidade de recursos, surgem gargalos que reduzem o *throughput* diário, comprometem a sustentabilidade financeira do serviço e prejudicam a experiência do paciente. Esses fatores comprometem tanto a qualidade do atendimento quanto a sustentabilidade financeira das instituições o que demanda soluções analíticas mais robustas, como a simulação computacional, que permite explorar cenários hipotéticos e apoiar decisões baseadas em dados (ROY; SHAH; GAJJAR, 2021; WANG; DEMEULEMEESTER, 2023).

Neste cenário, a modelagem e a simulação computacional surgem como ferramentas para avaliar cenários complexos sem interferência direta no ambiente real, além de apoiar decisões estratégicas baseadas em evidências (BANIK *et al.*, 2023). Essas ferramentas vêm sendo utilizadas na área da saúde para analisar e melhorar processos assistenciais e administrativos. A simulação permite representar de forma realista o comportamento dinâmico dos sistemas de saúde, testando diferentes cenários sem risco aos pacientes ou à operação real (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).

No âmbito do agendamento de exames, busca-se definir a alocação eficiente de pacientes em horários estratégicos durante um período de planejamento, com o intuito de garantir a disponibilidade adequada de recursos nos momentos de maior demanda (ALA; CHEN, 2022; KUIPER *et al.*, 2023). Esse arranjo impacta diretamente a redução dos tempos de espera, a equidade no acesso e a percepção de qualidade do atendimento prestado (AHMAD *et al.*, 2021).

Nas modelagens e simulação na saúde, as abordagens podem variar conforme o nível de detalhe e os objetivos da análise, ou seja, não existe um único método adequado para todos os problemas, uma vez que cada técnica possui potencialidades e limitações. Assim, a Simulação de Eventos Discretos (em inglês, *Discrete Event Simulation*, DES) é eficaz em cenários onde os processos são sequenciais e baseados em fluxos bem definidos como no caso de clínicas e hospitais que lidam com filas, tempos de espera e alocação de recursos (AHMAD *et al.*, 2021; ROY;

SHAH; GAJJAR, 2021). Quando o foco está em compreender a dinâmica de sistemas complexos com múltiplos agentes interativos, como políticas públicas de saúde ou redes regionais de atendimento, metodologias como a Dinâmica de Sistemas (em inglês, *System Dynamics*, SD) e a Simulação Baseada em Agentes (em inglês, *Agent Based Simulation*, ABS) são mais apropriadas (LARRAIN; GROENE, 2021; MITROPOULOS; ADAMIDES; MITROPOULOS, 2023). Essas técnicas permitem simular comportamentos adaptativos, interdependência entre elementos do sistema e efeitos de longo prazo. Seu uso é valorizado por apoiar o desenvolvimento de sistemas de saúde mais responsivos e sustentáveis, além de oferecer uma base sólida para avaliar intervenções antes de sua aplicação prática (SOORAPANTH; ELDABI; YOUNG, 2023; WANG; DEMEULEMEESTER, 2023). No entanto, quando o objetivo é analisar detalhadamente o fluxo operacional de pacientes, os tempos de espera e a utilização de recursos em processos assistenciais bem definido, a DES se mostra a abordagem mais adequada ao representar com precisão eventos que ocorrem em momentos específicos e apoiar decisões voltadas à eficiência operacional (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; SHAKOOR *et al.*, 2021).

Logo, este estudo propõe o desenvolvimento de modelo de simulação para avaliar e recomendar melhorias no processo de atendimento em uma clínica de diagnósticos por imagem no interior de Pernambuco. Tal contexto se justifica pela relevância do serviço de diagnóstico na jornada do paciente e pelo impacto direto que a espera prolongada pode causar em termos clínicos, econômicos e de experiência do usuário.

1.1 CONTRIBUIÇÕES

Do ponto de vista científico, este trabalho propõe uma metodologia e simulação aplicada aos serviços de saúde construídas a partir de dados reais de uma clínica de diagnóstico por imagem, contexto ainda pouco explorado pois a maior parte dos estudos concentra-se em hospitais de grande porte ou em análises macroestruturais. Além disso, a padronização proposta, que inclui desde a coleta de dados até a construção e validação do modelo, contribui para a replicabilidade e comparação de novos estudos, o que servirá de base para investigações futuras em cenários semelhantes.

Na perspectiva prática, o estudo fornece evidências quantitativas sobre gargalos operacionais e ineficiências na gestão de processos de unidades de diagnóstico por imagem, especificamente no setor de ressonância magnética, identificando oportunidades de melhoria e propondo soluções para redução de tempos de espera, melhoria da utilização de equipamentos de alto custo e qualificação do trabalho das equipes. A análise de cenários alternativos, construída por meio de simulação, permite que gestores testem mudanças sem impactar diretamente a rotina assistencial, favorecendo a tomada de decisão baseada em dados. Essa contribuição está alinhada à premissa de geração de valor em saúde ao associar melhores resultados assistenciais a uma gestão eficiente de recursos. Assim, simultaneamente se insere no debate acadêmico, ampliando a compreensão sobre a aplicação da simulação computacional em saúde, e oferece subsídios concretos para a melhoria da qualidade e da eficiência dos serviços de diagnóstico, reforçando sua relevância científica e social.

1.2 OBJETIVOS

1.2.1 OBJETIVO GERAL

Modelar e simular o processo de atendimento de uma clínica de diagnóstico por imagem, com foco na identificação de gargalos e proposição de estratégias que promovam a redução do tempo de espera dos pacientes e a melhoria da eficiência operacional.

1.2.2 OBJETIVOS ESPECÍFICOS

Para o alcance do objetivo geral, tem-se os seguintes objetivos específicos:

- A) Mapear e descrever as etapas do processo de atendimento da clínica, identificando os principais pontos críticos relacionados ao tempo de espera;
- B) Coletar dados operacionais relevantes como, tempo de execução, recursos disponíveis, volume de atendimentos;
- C) Desenvolver um modelo de simulação utilizando a abordagem de DES;
- D) Testar cenários alternativos de atendimento, avaliando o impacto de diferentes estratégias operacionais;

- E) Avaliar os ganhos potenciais em termos de tempo de espera, capacidade de atendimento e uso de recursos;
- F) Propor melhorias com base nos resultados da simulação, considerando aspectos como agendamento, alocação de pessoal e recursos físicos;
- G) Documentar o processo de modelagem, simulação, análise e recomendação, contribuindo para replicabilidade futura.

1.3 ESTRUTURA DO DA DISSERTAÇÃO

Este trabalho está estruturado em outros cinco capítulos a seguir:

O Capítulo II trata da fundamentação teórica sobre a qual foi desenvolvida esta dissertação. Inclui também uma revisão de literatura.

O Capítulo III apresenta os procedimentos metodológicos desse estudo.

O Capítulo IV apresenta a aplicação do método e os resultados encontrados.

No Capítulo V são descritas as conclusões e sugestões de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA

Este capítulo tem como objetivo apresentar a fundamentação teórica e a revisão bibliográfica que sustentam esta pesquisa, abordando (i) inicialmente os desafios da prestação de serviços de saúde e da gestão de processos em sistemas complexos, caracterizados por restrições de recursos, alta demanda e necessidade de eficiência; (ii) as principais metodologias de simulação computacional aplicadas à saúde, destacando definições, estruturas, vantagens, limitações e aplicações práticas; (iii) estudos aplicados que evidenciam a relevância da simulação na melhoria de fluxos assistenciais, na alocação de recursos e na redução de gargalos em serviços de saúde; e (iv) a análise crítica da literatura aponta lacunas, como a escassez de pesquisas em clínicas especializadas, a integração entre diferentes técnicas de simulação e a ausência de estudos que considerem simultaneamente eficiência operacional e experiência do paciente.


2.1 PRESTAÇÃO DE SERVIÇOS EM SAÚDE E GESTÃO DE PROCESSOS

A prestação de serviços de saúde constitui um dos pilares essenciais da sociedade, englobando ações de promoção, prevenção, recuperação e reabilitação da saúde, sempre com foco no acesso e na qualidade do cuidado ofertado (MINISTÉRIO DA SAÚDE, 2010). No entanto, os sistemas de saúde apresentam crescente complexidade, impulsionada pelo aumento da demanda, pela limitação de recursos humanos e tecnológicos e pela pressão por custos cada vez mais controlados. Nesse cenário, a gestão eficiente de processos torna-se indispensável para garantir a sustentabilidade e a resolutividade desses serviços (WANG; DEMEULEMEESTER, 2023).

Segundo o Ministério da Saúde (2010), os sistemas de saúde podem ser organizados em diferentes níveis de atenção (Figura 19), cada um com papéis e desafios específicos. O nível primário compreende ações de atenção básica, como consultas médicas gerais, acompanhamento de condições crônicas e programas de promoção da saúde, é nele que ocorre o primeiro contato do paciente com o sistema, funcionando como porta de entrada e coordenador do cuidado. O nível secundário corresponde a serviços de média complexidade, incluindo especialidades médicas,

exames laboratoriais e de imagem, além de atendimentos ambulatoriais especializados. Já o nível terciário concentra procedimentos de alta complexidade, como cirurgias de grande porte, internações hospitalares especializadas e serviços de terapia intensiva. Cada um desses níveis depende de recursos distintos, fluxos de atendimento integrados e mecanismos eficientes de regulação para garantir continuidade e qualidade no cuidado prestado.

Figura 1 - Organização dos níveis de atenção à saúde.



Fonte: (Felix e Maior, 2025)

Os serviços de saúde configuram sistemas altamente complexos e interdependentes, nos quais a variabilidade da demanda e a escassez de recursos influenciam diretamente a qualidade do atendimento. Essa realidade é evidenciada em serviços ambulatoriais e de média complexidade, como clínicas de diagnóstico por imagem, onde a gestão do fluxo de pacientes, da agenda de exames e do uso de equipamentos impacta diretamente indicadores de desempenho, como o tempo médio de espera, a taxa de ocupação de recursos e o tempo total de permanência no sistema (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012). A ineficiência em qualquer dessas etapas pode gerar atrasos, gargalos e comprometimento da experiência do paciente.

Embora o treinamento da equipe seja importante para reduzir variabilidades e padronizar fluxos, a literatura mostra que a evolução tecnológica dos equipamentos exerce papel ainda mais determinante para ganhos expressivos de eficiência. Novas

gerações de aparelhos de imagem permitem maior velocidade de aquisição e *softwares* de reconstrução mais ágeis, reduzindo significativamente os tempos de exame e aumentando a capacidade de atendimento por turno (WANG; DEMEULEMEESTER, 2023).

Além da eficiência operacional, é fundamental que os serviços de saúde gerem valor para o paciente. Conforme discutido por Porter (2010), o valor em saúde deve ser mensurado pela relação entre os resultados clínicos obtidos e os custos necessários para alcançá-los. Isso significa que a redução de tempos de espera, a otimização da utilização de equipamentos e a melhor alocação da equipe não apenas aumentam a eficiência do serviço, mas também contribuem para entregar um cuidado mais acessível, assertivo e focado no paciente.

Nas clínicas de diagnóstico por imagem, fatores como atrasos entre agendamentos, tempo de preparação do equipamento e disponibilidade da equipe clínica exercem papel crítico no desempenho do processo assistencial. A ausência de estratégias adequadas de gestão pode resultar em sobrecarga de profissionais, longos períodos de ociosidade de equipamentos ou, ainda, perda de capacidade produtiva. Estudos têm mostrado que a aplicação de métodos quantitativos, como a modelagem e a simulação, permite avaliar diferentes cenários operacionais, identificar gargalos e propor alternativas de melhoria baseadas em evidências (SHAKOOR *et al.*, 2021).

Diante desse cenário, ferramentas de apoio à decisão tornam-se importantes para enfrentar o dinamismo e a incerteza dos serviços de saúde. Nesse sentido, a simulação computacional surge como uma estratégia promissora, pois possibilita a reprodução do funcionamento de sistemas reais, sem a interferência direta nas operações, permitindo testar alternativas, reduzir riscos e apoiar gestores na tomada de decisão (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; WANG; DEMEULEMEESTER, 2023).

2.2 SIMULAÇÃO COMPUTACIONAL APLICADA À SAÚDE

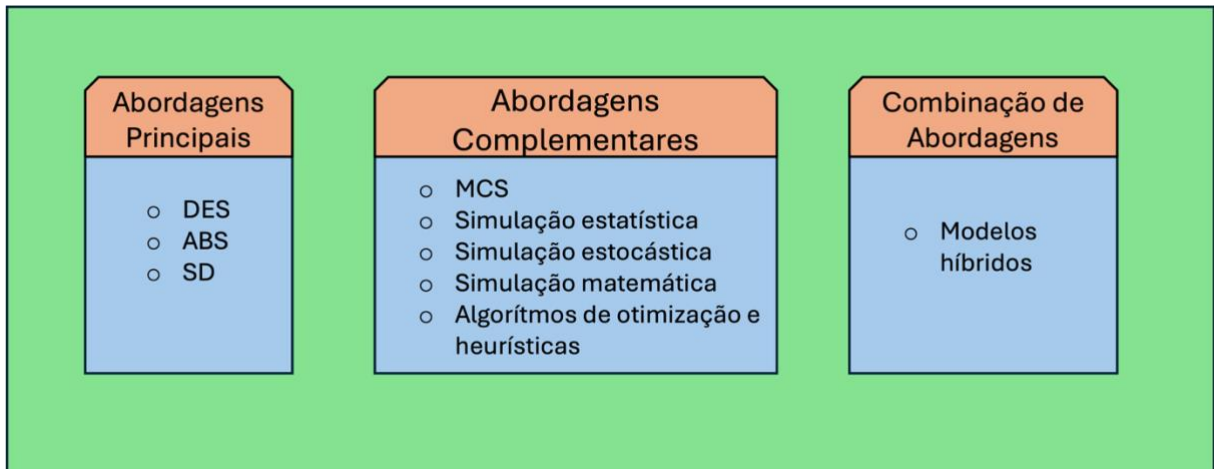
A simulação computacional tem sido utilizada como ferramenta de apoio à decisão na gestão de serviços de saúde. De maneira clássica, segundo Banks (1998), a simulação consiste na reprodução do funcionamento de processos ou sistemas do

mundo real ao longo do tempo, permitindo análises preditivas e avaliação de cenários sem a necessidade de interferir diretamente nas operações reais. Essa definição enfatiza a simulação como uma ferramenta de análise quantitativa, voltada para prever impactos de mudanças operacionais e apoiar decisões baseadas em dados.

Por outro lado, Datta et al. (2012) ressalta que a simulação deve também ser compreendida como uma técnica que substitui ou amplia experiências reais por experiências guiadas, capazes de reproduzir aspectos substanciais do mundo real de maneira interativa. Essa perspectiva amplia a noção clássica, ao considerar a simulação não apenas como uma ferramenta de análise, mas também como um recurso de aprendizagem e treinamento, que permite vivenciar situações complexas em ambiente seguro, reduzindo riscos e facilitando o desenvolvimento de competências práticas.

A aplicação da simulação na saúde pode assumir diferentes formas, de acordo com o nível de detalhe necessário e os objetivos do estudo. Conforme a Figura 20 na literatura destacam-se como principais metodologias de simulação aplicadas à saúde a DES, a ABS e a SD. No entanto, outras abordagens, como a Simulação de Monte Carlo (em inglês, *Monte Carlo Simulation*, MCS), modelos estatísticos e estocásticos, simulação matemática e algoritmos de otimização, têm sido utilizadas, especialmente quando integradas às técnicas clássicas, compondo modelos híbridos que buscam explorar os pontos fortes de cada metodologia (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; WANG; DEMEULEMEESTER, 2023). Cada uma dessas metodologias apresenta estrutura própria, vantagens e limitações, sendo aplicadas isoladamente ou de forma integrada conforme a complexidade do problema investigado (LARRAIN, 2021; ROY; SHAH; GAJJAR, 2021).

Figura 2 - Abordagens de simulação em saúde.



Fonte: Autor (2025)

Dentre os diferentes tipos de simulação, a DES é uma das técnicas mais consolidadas em estudos aplicados à saúde pois permite representar sistemas em que o estado muda apenas em instantes específicos no tempo, geralmente desencadeados por eventos como a chegada de pacientes, movimentação entre setores, início ou término de procedimentos e utilização de recursos (ROY; SHAH; GAJJAR, 2021). Sua estrutura básica é composta por três elementos principais: (1) entidades, que representam os pacientes ou recursos em circulação; (2) eventos, que modificam o estado do sistema; e (3) filas, que modelam os tempos de espera e os gargalos existentes no processo. Essa abordagem é utilizada para a análise de serviços hospitalares, pois possibilita mapear com precisão fluxos assistenciais, identificar pontos críticos e testar alternativas operacionais sem interferir diretamente na rotina operacional (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).

Entre as principais vantagens da DES estão a flexibilidade para representar processos bem estruturados, a capacidade de avaliar o impacto de diferentes cenários e o suporte à tomada de decisão baseada em dados. No entanto, sua limitação reside no fato desta ter foco em processos lineares e sequenciais, apresentando menor capacidade para capturar interações sociais complexas, comportamentos adaptativos de profissionais e pacientes ou efeitos de longo prazo, aspectos que podem ser melhor representados por outras metodologias, como a ABS ou a SD (LARRAIN; GROENE, 2021).

A ABS diferencia-se das demais abordagens por modelar o comportamento de unidades autônomas chamadas de agentes, que podem representar pacientes, profissionais de saúde, equipamentos ou até mesmo unidades organizacionais. Cada agente possui regras de decisão próprias e interage com outros agentes e com o ambiente, gerando dinâmicas emergentes que dificilmente seriam previstas apenas pela observação de processos agregados (MITROPOULOS; ADAMIDES; MITROPOULOS, 2023). A estrutura básica de um modelo ABS envolve a definição dos agentes, do ambiente em que atuam e das regras de interação que governam seu comportamento. Entre as vantagens da ABS está a capacidade de representar a heterogeneidade e a descentralização dos sistemas de saúde, capturando fenômenos como diferenças individuais entre pacientes, adesão a tratamentos ou dinâmicas de comunicação entre profissionais. Além disso, essa abordagem é aplicada em contextos em que decisões locais podem impactar significativamente o desempenho global do sistema. Contudo, uma limitação significativa da ABS é complexidade de modelagem, que demanda grande volume de dados e alto poder computacional para validar modelos com múltiplas variáveis, o que pode restringir sua aplicação em ambientes com recursos limitados.

Por outro lado, a SD adota uma perspectiva mais agregada e sistêmica, representando os serviços de saúde a partir de estoques, fluxos e laços de retroalimentação. Diferentemente da DES e da ABS, a SD busca compreender como diferentes variáveis se influenciam ao longo do tempo, permitindo identificar relações de causa e efeito e avaliar os impactos de políticas públicas ou mudanças estruturais em horizontes de médio e longo prazo (LARRAIN; GROENE, 2021). Essa abordagem é indicada para estudos de planejamento estratégico, como projeções de demanda por serviços. Entre suas principais vantagens estão a clareza conceitual, a capacidade de explorar cenários em escala macro e a possibilidade de analisar efeitos acumulativos e tendências de longo prazo. A SD apresenta, porém, limitações quanto ao detalhamento operacional, uma vez que trabalha com dados agregados e não representa com precisão a variabilidade individual dos pacientes ou os processos de atendimento em nível micro. Desta forma, embora importante para análise de sistemas complexos, sua aplicação em estudos de fluxos operacionais requer integração com outras metodologias, como a DES e a ABS, para gerar uma visão mais completa (WANG; DEMEULEMEESTER, 2023).

MCS é uma das técnicas clássicas de simulação, definida por Banks (1998) como um método baseado na geração repetida de cenários a partir de distribuições de probabilidade, permitindo analisar a incerteza em sistemas complexos. Na área da saúde, essa abordagem tem sido empregada para lidar com a variabilidade dos tempos de atendimento, da chegada de pacientes e do uso de recursos, fornecendo suporte à tomada de decisão em ambientes caracterizados por alto nível de incerteza. (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012) cita que a MCS é útil para representar processos estocásticos, como filas hospitalares e tempos de espera em setores de diagnóstico. Já Roy, Shah e Gajjar (2021), destacam que essa técnica pode auxiliar na avaliação de cenários de desempenho em operações de saúde, especialmente quando é necessário mensurar riscos ou prever impactos de mudanças em condições operacionais.

Embora a literatura frequentemente apresente MCS como uma técnica independente, é importante destacar que ela não constitui, por si só, um *framework* de modelagem de processos, mas sim um método estatístico de amostragem para lidar com incertezas. A MCS gera múltiplos cenários a partir de distribuições de probabilidade, permitindo explorar a variabilidade associada a tempos de atendimento, chegadas de pacientes ou uso de recursos (BANKS, 1998; MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012). Nesse sentido, sua aplicação isolada é comum em análises de risco, avaliação de custos e estudos de confiabilidade em saúde (ROY; SHAH; GAJJAR, 2021). Assim, DES e MCS não se situam exatamente no mesmo nível conceitual: a primeira é uma metodologia abrangente para representação de processos, e a segunda é uma técnica estatística que sustenta a variabilidade dentro desses modelos. Essa complementaridade explica por que muitos estudos relatam a integração de ambas, especialmente em setores como radiologia, emergências hospitalares e diagnóstico por imagem, nos quais a incerteza e a variabilidade são elementos centrais para a análise (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; SHAKOOR *et al.*, 2021).

Além dessas técnicas consolidadas, a literatura também destaca métodos como:

- Simulação matemática, que utiliza modelos analíticos de equações diferenciais e representações formais para capturar fenômenos em saúde, especialmente em situações epidemiológicas ou de crescimento populacional. Sua principal

vantagem é a clareza conceitual e rapidez de cálculo, mas sua limitação é a baixa adequação a sistemas muito complexos com múltiplas variáveis interdependentes (LARRAIN; GROENE, 2021).

- Simulação estatística (probabilística): fundamenta-se em métodos de inferência e em distribuições de probabilidade ajustadas a dados históricos, permitindo estimar tempos médios de atendimento, variabilidade da demanda e capacidade do sistema. Essa abordagem é útil para o planejamento de recursos e a avaliação de cenários operacionais, já que é baseada em observações reais. No entanto, sua principal limitação é a dependência da quantidade e da qualidade dos dados disponíveis, se os registros forem escassos ou enviesados, o modelo pode não representar adequadamente o comportamento do sistema (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).
- Simulação estocástica: incorpora de forma explícita a aleatoriedade intrínseca ao comportamento do sistema, admitindo que determinados fenômenos possuem variabilidade imprevisível mesmo quando não há dados suficientes para modelagem estatística detalhada. Essa abordagem é relevante em contextos de alta incerteza, como emergências hospitalares ou surtos epidêmicos, nos quais a demanda pode variar abruptamente. Sua vantagem é permitir explorar cenários plausíveis sob diferentes condições de incerteza, mas a limitação reside na dificuldade de validação prática, uma vez que os resultados são mais sensíveis a hipóteses sobre os processos aleatórios considerados (WANG; DEMEULEMEESTER, 2023).
- Algoritmos de otimização e heurísticas, frequentemente integrados a técnicas de simulação, contribuem para problemas de agendamento de pacientes, alocação de leitos e dimensionamento de equipes. Esses métodos podem gerar soluções eficientes em tempo reduzido, mas apresentam limitações quando aplicados a problemas de grande escala, nos quais a convergência para o ótimo depende da parametrização adequada (ORDU *et al.*, 2021).

Essas diferentes abordagens podem ser utilizadas isoladamente ou de forma integrada conforme os objetivos do estudo e a complexidade do sistema a ser modelado. Nos últimos anos, estudos têm destacado a relevância de modelos híbridos, que integram diferentes técnicas de simulação, como DES, ABS, SD e

algoritmos de otimização, buscando aproveitar os pontos fortes de cada abordagem (Tabela 9). Esses modelos permitem, representar ao mesmo tempo o detalhamento operacional dos fluxos assistenciais, os comportamentos emergentes das interações entre pacientes e profissionais e os efeitos de longo prazo no sistema (WANG, L.; DEMEULEMEESTER, 2023). Ordu et al. (2021), utilizaram um modelo híbrido de previsão, simulação e otimização para alocação de recursos em unidades de saúde, possibilitando maior eficiência no planejamento. Já Mitropoulos, Adamides e Mitropoulos (2023) empregaram a integração entre DES e SD para redesenhar a rede de atenção primária, explorando tanto a dinâmica operacional de centros de saúde quanto o impacto estratégico das mudanças propostas. Além disso, a combinação de DES e ABS pode auxiliar na alocação de leitos hospitalares, ao trabalhar simultaneamente as restrições de capacidade e os comportamentos adaptativos dos pacientes no sistema (WU; LI; CHU, 2019). Esses exemplos evidenciam como a utilização de modelos híbridos amplia a capacidade analítica da simulação, oferecendo uma visão mais completa e realista da complexidade dos serviços de saúde modernos.

Nos últimos anos, estudos têm destacado a relevância de modelos híbridos, que integram diferentes técnicas de simulação, como DES, ABS, SD e algoritmos de otimização, buscando aproveitar os pontos fortes de cada abordagem (Tabela 9). Esses modelos permitem, representar ao mesmo tempo o detalhamento operacional dos fluxos assistenciais, os comportamentos emergentes das interações entre pacientes e profissionais e os efeitos de longo prazo no sistema (WANG, L.; DEMEULEMEESTER, 2023). Ordu *et al.* (2021), utilizaram um modelo híbrido de previsão, simulação e otimização para alocação de recursos em unidades de saúde, possibilitando maior eficiência no planejamento. Já Mitropoulos, Adamides e Mitropoulos (2023) empregaram a integração entre DES e SD para redesenhar a rede de atenção primária, explorando tanto a dinâmica operacional de centros de saúde quanto o impacto estratégico das mudanças propostas. Além disso, a combinação de DES e ABS pode auxiliar na alocação de leitos hospitalares, ao trabalhar simultaneamente as restrições de capacidade e os comportamentos adaptativos dos pacientes no sistema (WU; LI; CHU, 2019). Esses exemplos evidenciam como a utilização de modelos híbridos amplia a capacidade analítica da simulação,

oferecendo uma visão mais completa e realista da complexidade dos serviços de saúde modernos.

Tabela 1- Comparação das principais abordagens de simulação aplicadas à saúde e suas evidências na literatura.

Tipo de Simulação	Definição	Vantagens	Limitações	Estudos na literatura
DES	Modela processos em que mudanças ocorrem em instantes discretos, desencadeados por eventos.	Ideal para mapear fluxos, gargalos e testar alternativas operacionais.	Foca em processos lineares, com dificuldade em capturar interações sociais complexas.	AHMAD, A. N. A. et al., 2021; MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; ROY; SHAH; GAJJAR, 2021; SHAKOOR et al., 2021
ABS	Modela unidades autônomas (agentes) que interagem entre si e com o ambiente.	Representa heterogeneidade e comportamentos emergentes.	Alta complexidade de modelagem e necessidade de muitos dados.	MITROPOULOS, P.; ADAMIDES; MITROPOULOS, I., 2023; WU; LI; CHU, 2019)
SD	Representa sistemas agregados por meio de estoques, fluxos e laços de retroalimentação.	Útil para planejamento estratégico e análise de longo prazo.	Menor detalhamento operacional, trabalha com dados agregados.	LARRAIN; GROENE, 2021; MITROPOULOS, P.; ADAMIDES; MITROPOULOS, I., 2023
MCS	Baseia-se em experimentos repetitivos com distribuições de probabilidade para lidar com incertezas.	Flexibilidade para explorar inúmeros cenários possíveis.	Exige poder computacional elevado e definição precisa das distribuições.	JERRY BANKS, 1998; ROY; SHAH; GAJJAR, 2021
Simulação Matemática	Utiliza equações e modelos analíticos para	Clareza conceitual e rapidez em	Pode não capturar o	LARRAIN; GROENE, 2021

	representar sistemas de saúde e prever comportamentos.	cálculos analíticos.	dinamismo de sistemas reais.	
Simulação Estatística	Usa modelos probabilísticos para estimar variabilidade e capacidade de processos.	Útil para planejamento de recursos e análise de capacidade.	Dependência de dados representativos e de qualidade.	MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012)
Simulação Estocástica	Incorpora aleatoriedade diretamente no modelo para representar incertezas reais do sistema.	Adequada para sistemas altamente imprevisíveis e dinâmicos.	Pode gerar cenários de difícil validação prática.	WANG, L.; DEMEULEMESTER, 2023
Algoritmos de Otimização e Heurísticas	Métodos computacionais que buscam soluções eficientes em problemas de alocação, escalonamento e otimização.	Soluções rápidas e aplicáveis a problemas reais de grande escala.	Dependem da parametrização correta e podem não garantir ótimo global.	BELHOR <i>et al.</i> , 2023; ORDU <i>et al.</i> , 2021

Fonte: Autor (2025)

Além das metodologias conceituais de simulação, *softwares* viabilizam suas aplicações práticas em saúde. Esses programas traduzem modelos teóricos em ambientes computacionais, permitindo análises detalhadas de fluxos assistenciais e recursos que, por sua vez, apresentam características próprias em termos de vantagens, limitações e aplicabilidade:

- FlexSim Healthcare: possui bibliotecas pré-configuradas para ambientes hospitalares como, salas de espera, triagem, exames e leitos, destaca-se pela capacidade de visualização 3D, que facilita a comunicação de cenários simulados a gestores e equipes não técnicas. É muito usado em hospitais que buscam otimizar fluxos de pacientes e reduzir gargalos sem necessidade de grande expertise em programação. A limitação, entretanto, é que, por ser muito

especializado, apresenta restrições na customização de modelos fora do contexto hospitalar (SHAKOOR *et al.*, 2021).

- Arena: amplamente consolidado na literatura de DES, utilizado em estudos de filas, prontos-socorros e agendamentos. Sua robustez e integração com Excel/VBA são pontos fortes, enquanto sua curva de aprendizado elevada e o tempo de modelagem são limitações (AHMAD *et al.*, 2021).
- Simul8: reconhecido pela interface amigável e rapidez de modelagem, sendo indicado para processos ambulatoriais e administrativos. A limitação está na menor flexibilidade para integração com modelos híbridos (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).
- AnyLogic: considerado o mais versátil, pois integra DES, ABS e SD, possibilitando o desenvolvimento de modelos híbridos aplicados a redes de saúde e epidemias. Sua flexibilidade é um diferencial, mas exige conhecimento avançado em programação e investimento em licenças (WU; LI; CHU, 2019).
- Vensim e Stella: especializados em Dinâmica de Sistemas, são recomendados para políticas de saúde, análises de longo prazo e projeções epidemiológicas. A vantagem é a clareza conceitual, enquanto a limitação é a falta de detalhamento micro operacional (LARRAIN; GROENE, 2021).
- Matlab/Simulink: amplamente usado em modelagem matemática e simulação estocástica, aplicado a epidemiologia e confiabilidade de equipamentos. Oferece poder computacional elevado e bibliotecas robustas, mas apresenta custo de licença alto e demanda conhecimento técnico avançado (WANG; DEMEULEMEESTER, 2023).
- Python e R: ferramentas de código aberto, cada vez mais utilizadas devido às bibliotecas como SimPy (DES), Mesa (ABS), PySD (SD) e Simmer (R). São flexíveis, gratuitas e permitem integração com *machine learning*, mas requerem esforço significativo em programação e validação (ORDU *et al.*, 2021).

2.3 APLICAÇÕES PRÁTICAS DE SIMULAÇÃO EM SERVIÇOS DE SAÚDE

A literatura evidencia aplicações de simulação de forma ampla e progressivamente mais sofisticada para apoiar decisões clínicas e gerenciais em contextos diversos de saúde. Em processos assistenciais de linha de frente, estudos

combinando simulação e *Lean* mostram reduções consistentes de tempos de espera e eliminação de desperdícios por meio de ajustes de layout, balanceamento de tarefas e realocação de recursos (AHMAD et al., 2021; ALKHER et al., 2019; CREMA; VERBANO, 2019; IMPROTA et al., 2020; TLAPA et al., 2022). Grande parte desses estudos foi conduzida em softwares generalistas de simulação discreta, como Arena e Simul8, que oferecem flexibilidade para modelar fluxos de pacientes e avaliar cenários alternativos de configuração. Simultaneamente, a gestão do acesso recebe especial atenção via problemas de agendamento e combinação paciente–prestador, explorando DES, otimização e regras de decisão para minimizar atrasos, cancelamentos e ociosidade (ALA; CHEN, 2022; CHEN et al., 2019; KUIPER et al., 2023). Nesses casos, o AnyLogic aparece com maior frequência, pois permite integrar DES e simulação baseada em agentes, possibilitando a análise simultânea da eficiência operacional e dos comportamentos emergentes dos pacientes e profissionais.

No suporte à operação, a simulação vem combinada a decisões de inventário e manutenção, reduzindo custos logísticos por meio de simulação, otimização e meta-heurísticas (BUSCHIAZZO; MULA; CAMPUZANO-BOLARIN, 2020; MWANZA; TELUKDARIE; IGUSA, 2023). Nessas aplicações, MATLAB e Python têm sido utilizados como ferramentas de apoio, principalmente para integração com algoritmos de otimização e parametrização de distribuições de probabilidade. Em *home healthcare*, abordagens de otimização e meta-heurísticas reduzem deslocamentos e janelas de atendimento, com ganhos em cobertura e qualidade (BELHOR et al., 2023).

Modelos integrais ou em rede têm sido empregados para avaliar sistemas integrados de saúde, orientar redesenhos de redes de atenção primária e definir capacidade em alianças, frequentemente combinando DES, SD e otimização (GAO; WEN; SONG, 2020; LARRAIN; GROENE, 2021; MITROPOULOS; ADAMIDES; MITROPOULOS, 2023). Em cenários de riscos e choques, a simulação apoia estratégias de desvio de pacientes e de planejamento para desastres e pandemias, gerando cenários de demanda, acessibilidade e ocupação (GROVES-KIRKBY et al., 2023; LIN; LIN; LIN, 2023).

Na perspectiva metodológica, nota-se um direcionamento a simulação-otimização para problemas de alocação, roteamento e reconfiguração de setores,

apontado por revisões de literatura recentes como campo promissor (BELHOR et al., 2023; MWANZA; TELUKDARIE; IGUSA, 2023; ORDU et al., 2021; TEYMOURIFAR, 2024; WANG; DEMEULEMEESTER, 2023). No setor de radiologia, o FlexSim Healthcare tem se mostrado particularmente eficiente, pois dispõe de bibliotecas pré-configuradas para modelar processos de diagnóstico por imagem, permitindo avaliar escalas, gargalos e utilização de equipamentos de forma detalhada (SHAKOOR et al., 2021). Por outro lado, há aplicações focadas na sustentabilidade e gestão verde da cadeia de suprimentos, como redução de resíduos e logística reversa, conectando métricas operacionais e ambientais (CHANG *et al.*, 2019; SRIVASTAVA, 2007). neste mesmo setor, aplicações específicas de DES demonstram identificação de gargalos, cenários de escalas e equipamentos e redução de tempos porta-exame (SHAKOOR *et al.*, 2021).

A literatura também discute valoração e custos de projetos baseados em modelagem e boas práticas de ciência aberta, como compartilhamento de modelos e código, elementos-chave para difusão e impacto (MONKS; HARPER, 2023; SOORAPANTH; ELDABI; YOUNG, 2023; YOUNG *et al.*, 2020). Por fim, estudos sobre análise pós desastres indicam como mudanças de processo apoiadas por modelagem podem fortalecer a segurança do paciente em contextos remotos (FLORIDIS, 2023).

2.4 LIMITAÇÕES E OPORTUNIDADES DA LITERATURA

Apesar dos avanços na literatura sobre simulação aplicada à saúde, muitos estudos concentram-se em hospitais de grande porte ou em sistemas de saúde públicos, deixando em segundo plano clínicas privadas de médio porte, particularmente no contexto brasileiro (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012). Esse cenário é crítico no setor de diagnóstico por imagem, onde o tempo de espera prolongado e a subutilização de equipamentos comprometem a eficiência e a experiência do paciente (SHAKOOR *et al.*, 2021). Além disso, verifica-se escassez de pesquisas voltadas especificamente para exames de ressonância magnética, mesmo sendo um dos procedimentos de maior complexidade e demanda crescente (CAI; JIA, 2019).

Outro ponto crítico refere-se ao uso de dados. Muitos estudos ainda utilizam suposições simplificadas ou distribuições genéricas para parametrizar seus modelos,

sem validação a partir da realidade operacional de clínicas e hospitais (AHMAD et al., 2021; BAHARI; ASADI, 2020). É importante destacar que toda simulação gera cenários artificiais, porém a limitação está em não confrontar os resultados com dados observados em campo, reduzindo a confiabilidade das análises. Neste presente estudo, esse desafio é mitigado por meio da coleta de dados reais para parametrizar as distribuições utilizadas, embora hipóteses adicionais ainda sejam necessárias, como o comportamento do paciente e a disponibilidade da equipe, que não podem ser totalmente capturadas em campo.

Além disso, a literatura mostra que a integração entre simulação e otimização representa um caminho promissor quando associada a heurísticas como algoritmos genéticos, permitindo explorar soluções mais eficientes para alocação de recursos e agendamento (WANG; DEMEULEMEESTER, 2023). Entretanto, ainda há carência de trabalhos que apliquem essa integração em unidades de diagnóstico, restringindo sua aplicação prática.

Por fim, é possível observar a ausência de padronização nos métodos de modelagem de processos ambulatoriais. Isso significa que cada estudo adota técnicas, variáveis e níveis de detalhamento diferentes, alguns focam apenas no fluxo de pacientes, outros incluem recursos humanos, tempos de setup ou logística de resultados, o que dificulta a comparação entre pesquisas e a replicação de boas práticas em diferentes contextos (MITROPOULOS; ADAMIDES; MITROPOULOS, 2023; WU; LI; CHU, 2019). Desta forma, torna-se fundamental a adoção de modelos que explicitem as variáveis utilizadas, as distribuições estatísticas aplicadas e as hipóteses assumidas, de modo a facilitar futuras análises comparativas e promover maior robustez na construção de evidências para a gestão em saúde (AHMAD et al., 2021; BAHARI; ASADI, 2020; MITROPOULOS; ADAMIDES; MITROPOULOS, 2023; WANG; DEMEULEMEESTER, 2023; WU; LI; CHU, 2019).

3 METODOLOGIA

Este capítulo apresenta o caminho metodológico adotado para o desenvolvimento da pesquisa, descrevendo as etapas de caracterização do estudo, coleta e parametrização dos dados, construção do modelo de simulação e análise dos cenários propostos.

3.1 CARACTERIZAÇÃO DA PESQUISA

Esta pesquisa é classificada como aplicada, uma vez que busca oferecer soluções práticas a um problema real enfrentado em uma clínica de diagnóstico por imagem localizada no interior de Pernambuco. Quanto à abordagem, caracteriza-se como quantitativa, pois trabalha com dados numéricos coletados diretamente do processo assistencial, analisados estatisticamente e transformados em distribuições de probabilidade para posterior simulação (GIL, 2017; SEVERINO, 2017)

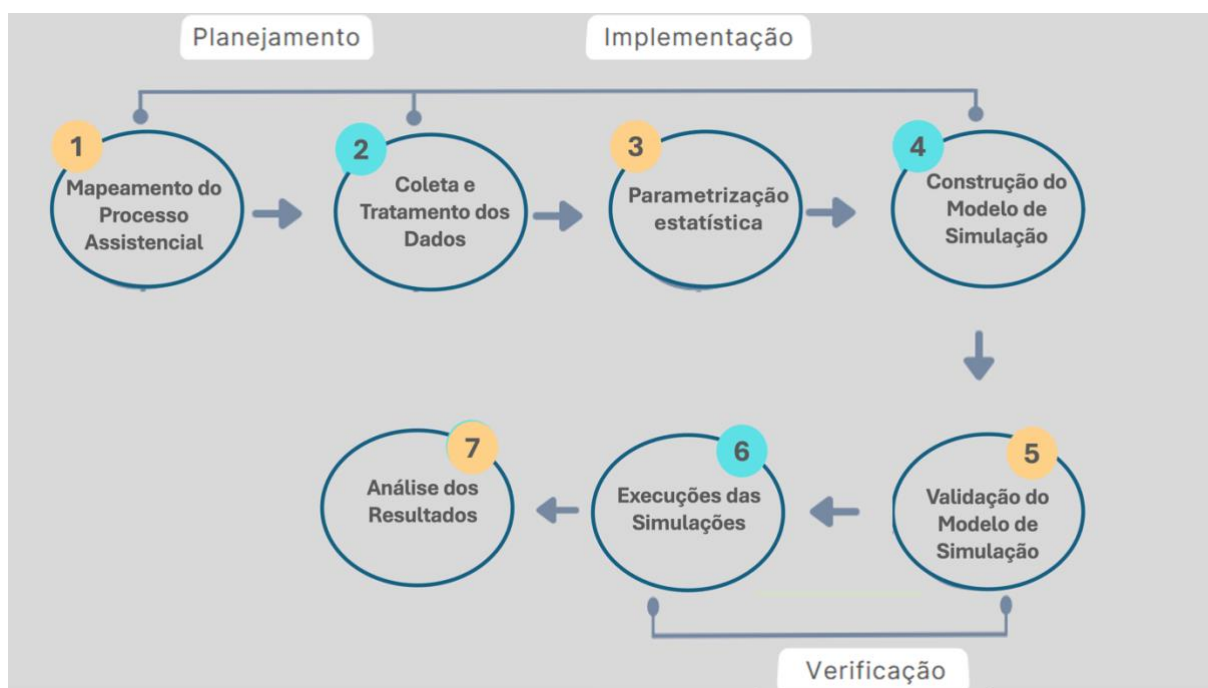
No que se refere aos objetivos, apresenta natureza exploratória e descritiva. É exploratória pois procura identificar variáveis críticas que influenciam o tempo de espera dos pacientes e a utilização dos recursos, em um contexto ainda pouco investigado em clínicas privadas de médio porte. Ao mesmo tempo, é descritiva, pois busca detalhar o funcionamento do processo atual e comparar cenários alternativos simulados, sem alterar diretamente a rotina operacional da clínica (GIL, 2017; SEVERINO, 2017; VERGARA, 2016).

O método de pesquisa adotado foi o estudo de caso, apropriado para analisar em profundidade uma realidade específica e contextualizada, integrando observação direta, análise de dados e modelagem computacional (YIN, 2014). Essa escolha é reforçada por estudos que aplicam metodologias semelhantes em serviços de saúde para compreender fluxos assistenciais e propor melhorias (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; SHAKOOR *et al.*, 2021).

Definida a natureza metodológica desta pesquisa como aplicada, quantitativa e estruturada em estudo de caso, torna-se necessário apresentar o contexto em que o problema investigado se insere. A caracterização da pesquisa estabelece o enquadramento científico que justifica a escolha da simulação computacional como estratégia analítica. No entanto, é a descrição do funcionamento real da clínica de

diagnóstico por imagem que fundamenta a construção do modelo (Figura 21). Assim, a seção seguinte apresenta a caracterização do problema, detalhando os recursos disponíveis, o fluxo de pacientes e os gargalos que motivaram este estudo.

Figura 3 - Metodologia do estudo.



Fonte: Autor (2025).

3.2 CARACTERIZAÇÃO DO PROBLEMA

A clínica de diagnóstico por imagem analisada neste estudo está localizada em uma cidade de médio a grande porte no interior de Pernambuco e encontra-se em funcionamento há mais de 35 anos, contando atualmente com duas unidades em operação. Atua sob demanda crescente, oferecendo exames de Ressonância Magnética (RM) em regime contínuo, com funcionamento em turnos que garantem atendimento diário. No fluxo de RM, conta com duas máquinas de RM, duas recepcionistas, uma enfermeira para triagem e técnicas de radiologia responsáveis pelo setup e operação dos equipamentos.

Apesar de estruturado, o processo apresenta desafios relacionados ao tempo de espera dos pacientes e à utilização de recursos. Entre os principais fatores que comprometem a eficiência estão: (i) a variabilidade da demanda de pacientes, que

gera períodos de superlotação intercalados com momentos de ociosidade; (ii) o tempo de preparação (setup) das máquinas, que varia de acordo com o tipo de exame e reduz a cadência do atendimento; e (iii) a disponibilidade da equipe, frequentemente sobrecarregada em horários de pico. Esses fatores afetam diretamente indicadores como tempo médio de espera, taxa de ocupação de recursos e tempo total de permanência dos pacientes no sistema (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; SHAKOOR *et al.*, 2021), comprometendo não apenas a produtividade da clínica, mas também a experiência do paciente, uma vez que longos tempos de espera prejudicam a percepção de qualidade do atendimento (PORTER, 2010). Diante desse cenário, é essencial avaliar alternativas de melhoria que apoiem a tomada de decisão gerencial.

Considerando os desafios identificados no processo de atendimento da clínica, é essencial compreender quantitativamente como cada etapa contribui para os gargalos observados. Para isso, foi necessário realizar a coleta sistemática de dados operacionais e a sua parametrização em distribuições estatísticas representativas. Essa etapa possibilitou transformar observações empíricas em insumos confiáveis para a construção do modelo de simulação, garantindo que os cenários testados reflitam com maior precisão a realidade do sistema estudado.

3.3 ORIGEM E PARAMETRIZAÇÃO DOS DADOS

Os dados utilizados nesta pesquisa têm origem primária e foram parametrizados conforme descrito:

- Dados primários: coletados foram diretamente na clínica no mês de maio, com base no histórico de atendimento dos três meses anteriores para definir a quantidade necessária de observações. Os dados incluíram: tempos de recepção, triagem, preparação da máquina de ressonância magnética e duração dos exames.
- A parametrização foi realizada com auxílio do Python, por meio de bibliotecas estatísticas como SciPy. Esse recurso permitiu ajustar distribuições de probabilidade aos dados coletados, aplicando testes de aderência de Kolmogorov-Smirnov para representatividade estatística das variáveis (AHMAD *et al.*, 2021; BAHARI; ASADI, 2020). Dessa forma, o modelo foi

alimentado com dados validados, mitigando a limitação de estudos que utilizam apenas suposições ou distribuições genéricas (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).

3.4 SOFTWARE ESCOLHIDO

A modelagem foi implementada no FlexSim Healthcare, uma extensão do FlexSim direcionada ao setor da saúde, na versão acadêmica. A escolha desse software se justifica por três aspectos principais:


- Bibliotecas específicas para saúde: inclui objetos pré-configurados, como triagem, recepção e leitos, o que agiliza a modelagem e aumenta a precisão (SHAKOOR *et al.*, 2021).
- Visualização em 3D: facilita a comunicação dos resultados a gestores e profissionais sem conhecimento técnico aprofundado (CAI; JIA, 2019).
- Reconhecimento acadêmico: o *FlexSim Healthcare* tem sido utilizado em pesquisas recentes, confirmando sua adequação para cenários hospitalares e de diagnóstico (WANG; DEMEULEMEESTER, 2023).

4 APLICAÇÃO NA ÁREA DE SAÚDE

4.1 CENÁRIO ATUAL

O desenvolvimento desta pesquisa seguiu uma sequência estruturada de etapas que permitiu construir, validar e analisar o modelo de simulação. Inicialmente, realizou-se o mapeamento do processo assistencial, no qual foram identificadas todas as etapas do fluxo do paciente como mostra a Figura 22. Esse mapeamento foi desenvolvido em conjunto com a equipe da clínica e representado em fluxogramas, de modo a capturar a lógica operacional real (AHMAD et al., 2021).

Figura 4 - Mapa do fluxo assistencial.



Fonte: Autor (2025)

A etapa seguinte consistiu na coleta e tratamento dos dados, conduzida por meio de observação direta do funcionamento da clínica e análise de registros internos. Foram coletadas 135 observações válidas, distribuídas entre os tempos *setup* das máquinas e duração dos exames, considerando o período de um mês. A definição do número de observações baseou-se no histórico de atendimentos dos três meses anteriores, de modo a garantir representatividade estatística das variáveis analisadas.

Os tempos coletados foram organizados em planilhas para análise estatística, de forma a garantir consistência e comparabilidade entre variáveis relevantes, conforme recomendam estudos de simulação aplicados a serviços de saúde (BAHARI; ASADI, 2020).

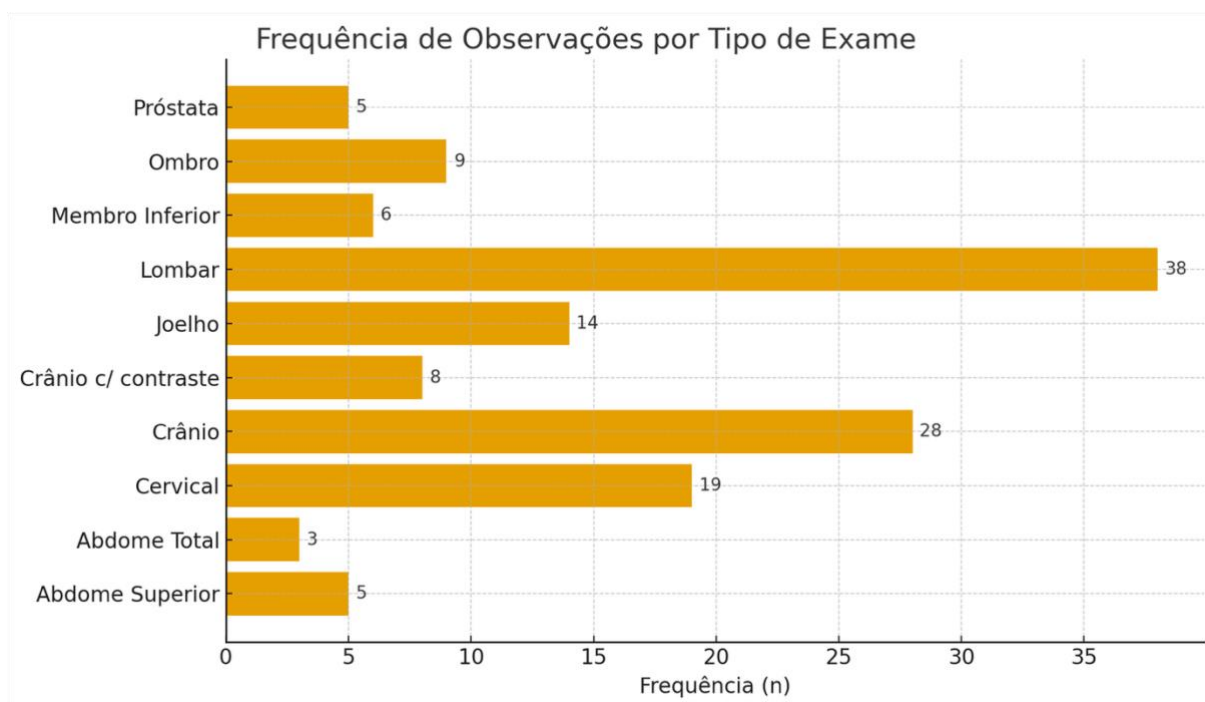
Atualmente, os exames são agendados de forma aleatória, sem critérios específicos relacionados ao tipo de exame, ao tempo de duração ou ao preparo necessário para sua realização. Os horários disponíveis na agenda são simplesmente preenchidos conforme a demanda, de maneira sequencial, à medida que surgem vagas, independentemente das características técnicas do exame solicitado.

Para representar adequadamente a heterogeneidade operacional do processo, adotou-se uma estratificação por tipo de exame (Figura 23): abdome superior, abdome total, cervical, crânio, crânio (com contraste), joelho, lombar, membro inferior, ombro e próstata. Essa classificação foi utilizada como fator de agrupamento na etapa de ajuste estatístico, de modo que as amostras de tempo de *setup* e tempo de realização correspondentes a cada estrato fossem tratadas separadamente, como mostram as tabelas 2 e 3. A parametrização foi realizada com auxílio do Python, utilizando bibliotecas estatísticas como SciPy, que permitiram ajustar distribuições de probabilidade aos dados coletados e aplicar testes de aderência de Kolmogorov–Smirnov para avaliar sua representatividade. A seleção das distribuições candidatas foi fundamentada tanto na literatura de simulação aplicada à saúde quanto em critérios estatísticos de aderência aos dados observados.

Estudos que modelam fluxos assistenciais e tempos de atendimento em serviços hospitalares e de diagnóstico por imagem indicam a utilização recorrente das distribuições Normal, Exponencial, Lognormal e Weibull para representar tempos operacionais e processos estocásticos (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; ROY; SHAH; GAJJAR, 2021; SHAKOOR *et al.*, 2021). Essas distribuições foram selecionadas por sua capacidade de modelar diferentes comportamentos dos dados, incluindo simetria, assimetria positiva e taxas de ocorrência constantes ou variáveis ao longo do tempo. As distribuições que não apresentaram aderência estatisticamente satisfatória foram descartadas. Assim, a escolha final para cada variável foi baseada no melhor ajuste estatístico aliado à coerência teórica com o fenômeno modelado. Para a distribuição Normal, os parâmetros estimados correspondem à média (μ) e ao

desvio-padrão (σ), refletindo a tendência central e a dispersão dos tempos observados. Já na distribuição Exponencial, o parâmetro λ (lambda) representa a taxa de ocorrência dos eventos, sendo o inverso do tempo médio entre eles, além de um parâmetro de localização. Na distribuição Lognormal, os parâmetros indicam a média e o desvio-padrão do logaritmo dos tempos, adequada para fenômenos assimétricos e positivos, além de um parâmetro de localização. A distribuição Weibull é descrita pelos parâmetros de forma (β) e escala (α), além de um parâmetro de localização. A Tabela 10 apresenta as distribuições ajustadas e seus respectivos parâmetros para os tempos de setup por tipo de exame, enquanto a Tabela 11 mostra os resultados equivalentes para os tempos de realização dos exames.

Figura 5 - Frequência de observações por tipo de exame.



Fonte: Autor (2025)

Os parâmetros estimados por estrato foram então incorporados ao modelo no *FlexSim Healthcare*, assegurando que a simulação refletisse não apenas o fluxo agregado, mas também as diferenças estruturais entre protocolos e complexidades de exame, condição necessária para avaliar impactos sobre filas, utilização de recursos e tempos de permanência no sistema.

Tabela 2 - Frequência e distribuição de tempo de setup.

Tipo de Exame	Frequência	Distribuição Set up	Parâmetros		
Abdome Superior	5	Normal	31,1667	3,8042	
Abdome Total	3	Normal	52,8	10,6094	
Cervical	19	Normal	20,58	6,8734	
Crânio	28	Exponencial	1	2,89	
Crânio (c/contraste)	8	Exponencial	16	6,625	
Joelho	14	Exponencial	7	5,8571	
Lombar	38	Lognormal	0,7684	5,8548	5,7672
Membro inferior	6	Exponencial	9	14	
Ombro	9	Weibull	0,6782	9	8,393
Próstata	5	Weibull	0,5561	24	15,6797

Fonte: Autor (2025)

Tabela 3 - Distribuição de tempo de realização de exame.

Tipo de Exame	Distribuição tempo de exame	Parâmetros		
Abdome Superior	Exponencial	4	0,667	0,667
Abdome Total	Exponencial	2	2,6	
Cervical	Normal	3,5	1,1354	
Crânio	Lognormal	9,534	1	0,1757
Crânio (com contraste)	Lognormal	12,3344	1	0,0307
Joelho	Weibull	0,855	2	2,0761
Lombar	Lognormal	0,3917	-0,3474	3,3391
Membro inferior	Exponencial	3	1,3333	

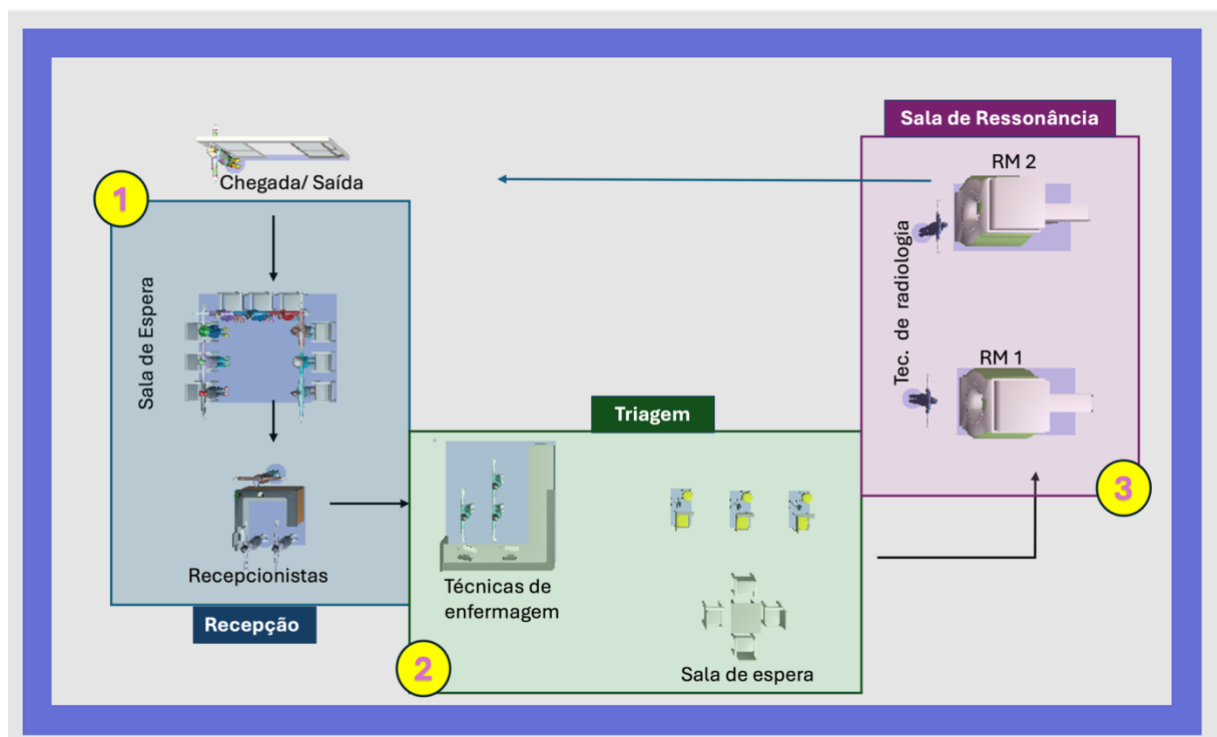
Ombro	Normal	4,5556	0,8315
Próstata	Normal	5,2	0,7483

Fonte: autor (2025)

4.1.1 Modelagem no Flexsim Healthcare

Para dar suporte à simulação e garantir que o modelo represente o funcionamento da clínica, foi elaborado no *FlexSim Healthcare* um diagrama operacional que incorpora todas as etapas do trajeto do paciente dentro do ambiente assistencial. Antes de inserir os dados e rodar cenários, foi necessário estruturar o fluxo de atendimento com as entidades lógicas interligadas, refletindo as restrições de recursos e as regras de espera entre etapas. Na Figura 24 é apresentada a sequência dos processos, da chegada do paciente à saída, que serve de base para parametrização, execução de cenários e análise dos resultados no ambiente de simulação.

Figura 6 - Fluxo de execução de exame no Flexsim.



Fonte: Autor (2025)

O modelo de simulação foi construído a partir do fluxo real percorrido pelo paciente dentro da clínica de diagnóstico por imagem:


- 1) O processo inicia-se na recepção, onde duas recepcionistas registram a chegada dos pacientes. Quando ambas estão ocupadas, o paciente aguarda em uma fila de cadeiras destinadas à recepção, configurada no FlexSim como recurso de espera. Essa etapa reflete a primeira interação do paciente com o sistema e já evidencia possíveis gargalos em horários de maior demanda.
- 2) Após o registro, o paciente é encaminhado à triagem, conduzida por duas técnicas de enfermagem responsáveis pela aplicação de um questionário sobre as condições clínicas e pelo preparo inicial. No modelo, foi considerada a possibilidade de espera: quando todas as enfermeiras estão ocupadas, o paciente permanece aguardando na área de recepção. Assim, é possível captar a dependência entre setores e a propagação de atrasos.
- 3) Concluída a triagem, o paciente segue para a sala de exames de ressonância magnética, onde estão disponíveis duas máquinas. Caso ambas estejam em uso, os pacientes permanecem em espera na sala de triagem. Antes de cada exame, ocorre um setup técnico, representado no modelo computacional como um processo adicional necessário para o posicionamento da bobina de acordo com o tipo de exame solicitado. Desta forma, pode-se representar a variabilidade operacional, uma vez que diferentes exames demandam tempos distintos de preparação. Por fim, após a realização do exame, o paciente retorna à triagem para finalizar o processo e deixar o sistema.

O modelo, portanto, avalia não apenas os tempos médios de espera em cada estação, mas também a utilização dos recursos, a ocorrência de gargalos e o impacto dos *setups* no desempenho do sistema.

Conforme a parametrização e o fluxo operacional previamente descritos, executou-se o modelo no *software* para um horizonte de cinco dias, obtendo-se um tempo médio de permanência no sistema de 139 minutos por paciente (Figura 25) e *throughput* total de 161 pacientes no período (aproximadamente 32,2 pacientes/dia;


com duas máquinas de RM, aproximadamente 16,1 exames/máquina/dia), como mostra a Figura 26.

Figura 7 - Tempo de permanência no sistema em minutos.



Fonte: Autor (2025)

Figura 8 - Quantidade de pessoas atendidas em 5 dias.



Fonte: Autor (2025)

A análise dos estados médios de utilização dos recursos humanos (*Avg State*), apresentada na Figura 27, apresenta diferenças na distribuição das atividades entre os profissionais envolvidos no processo de RM. No modelo parametrizado, o FlexSim Healthcare classifica o tempo dos recursos em categorias operacionais, *in transit*, *providing care*, *performing task* e *idle*, de acordo com a natureza das atividades executadas. A interpretação desses estados depende diretamente da modelagem do fluxo de trabalho. No caso das técnicas de radiologia, observou-se que 76,07% do de utilização total, maior parte do tempo foi categorizado como *Providing Care*. Embora, conceitualmente, se possa associar esse estado apenas a ações assistenciais, no ambiente do FlexSim foram incluídas todas as atividades que envolvem interação direta com o paciente, tais como acomodação na mesa, preparação das bobinas, orientações durante o exame, retirada de objetos metálicos e assistência na entrada e saída da sala. Como o processo de setup foi modelado como uma etapa que ocorre

com a presença do paciente e exige sua preparação física, o *software* alocou a maior parte desse período em *providing care*.


De maneira complementar, 21,11% do tempo das técnicas foi registrado como *performing task*, correspondendo às atividades técnicas e sem contato humano direto, como configuração de parâmetros do equipamento, ajustes internos e tarefas executadas pelo *task executer* fora da sala de exame. Esse padrão de distribuição é característico de modelos em que o *setup* envolve a participação no cuidado ao paciente, reforçando que a categorização depende da lógica interna do simulador e não exclusivamente da descrição clínica das tarefas.

Para as enfermeiras, registrou-se 12,65% do tempo em *providing care*, refletindo sua atuação concentrada nas fases iniciais do fluxo, acolhimento, triagem e orientações prévias, com longos intervalos de ociosidade entre atendimentos, dada a baixa variabilidade e curta duração das suas tarefas.

Para as recepcionistas, observou-se 9,05% do tempo em *providing care*, valor condizente com um processo de recepção padronizado, rápido e não contínuo dentro do fluxo específico da ressonância magnética. A predominância do estado *idle* não deve ser interpretada como ociosidade real, mas sim como um artefato da modelagem focada exclusivamente no processo de RM. Na operação real da clínica, as recepcionistas desempenham um conjunto de atividades não modeladas no simulador, incluindo recepção e cadastro de pacientes de outros processos, como tomografia computadorizada e ultrassonografia, agendamento de exames, prestam o serviço de informações gerais e suporte administrativo. Assim, a baixa utilização dentro do modelo reflete apenas o escopo restrito da simulação.

Assim, os resultados do *avg state* demonstram que a maior restrição operacional do sistema aponta as técnicas de radiologia, cuja elevada proporção de tempo em *providing care* e *performing task* indica dependência da capacidade instalada das salas de RM e alto envolvimento em atividades simultaneamente técnicas e assistenciais. As demais categorias profissionais apresentam folgas operacionais significativas, o que confirma que os gargalos do sistema estão concentrados na etapa de exame e *setup*, e não nas fases de triagem ou recepção.

Figura 9 - Média de tempo de cada setor realizando atividades.



Fonte: Autor (2025)

4.2 CENÁRIO 2: REORGANIZAÇÃO DA SEQUÊNCIA E LÓGICA DE AGENDAMENTO

Com base na análise do cenário atual, no qual foi observado um tempo médio de permanência no sistema de 139 minutos, 161 pacientes atendidos em cinco dias de simulação e alta utilização das técnicas em radiologia, foi trabalhado um novo cenário com o objetivo avaliar o impacto de intervenções exclusivamente operacionais, sem aumento de recursos físicos ou humanos, sobre o desempenho do processo de ressonância magnética. As mudanças propostas foram fundamentadas nos dados levantados na clínica, nos princípios de gerenciamento de filas, teoria das operações e boas práticas de gestão de serviços de saúde. O foco desse cenário foi reorganizar o fluxo por meio da padronização, sequenciamento inteligente e inserção de buffers operacionais, visando reduzir gargalos, tempos de espera e variabilidade.

4.2.1 Construção do novo fluxo

4.2.1.1 Agrupamento de exames por similaridade técnica

A primeira lógica adotada foi o agrupamento dos exames em blocos homogêneos, organizados segundo suas características técnicas, protocolos de aquisição e requisitos de configuração. Foram definidos quatro agrupamentos principais: (i) os exames de coluna (cervical, torácica e lombar), que utilizam as bobinas integradas da mesa e apresentam potencial de setup mínimo; (ii) o exame de

crânio; (iii) os exames musculoesqueléticos, como ombro e joelho, que requerem bobinas de superfície e maior intervenção manual; e (iv) os exames de abdome e pelve. Essa organização reduz trocas de bobina e reconfigurações sucessivas, favorecendo um fluxo mais estável e diminuindo a variabilidade operacional observada no cenário atual. As modificações fundamentaram-se em dois princípios operacionais:

- Redução da variabilidade interna do processo, evitando alternâncias entre sequências de procedimentos incompatíveis entre si.
- Diminuição do número de *setups*, uma vez que transições frequentes entre tipos de exame representam uma das maiores causas de tempo improdutivo no processo de imagem.

Esse agrupamento permitiu a criação de um fluxo mais previsível e contínuo, alinhando-se ao conceito de *single-piece flow* aplicado de maneira adaptada ao contexto de saúde.

4.2.2 Alternância estratégica entre exames curtos e longos

Após a definição dos blocos, os exames foram distribuídos ao longo do turno de maneira a equilibrar a carga sobre as máquinas e equipes. Assim, exames de menor duração, cuja média variou entre 25 e 30 minutos segundo os dados coletados, foram intercalados com exames mais longos, cuja duração média ultrapassou 35 minutos. Essa decisão foi baseada no entendimento de que:

- Em turnos com muitos exames prolongados consecutivos, há maior probabilidade de formação de filas e atrasos acumulados.
- Em turnos com muitos exames curtos consecutivos, a equipe pode sofrer sobrecarga por setups repetidos e ritmo acelerado.

A alternância introduzida no cenário buscava reduzir o efeito de pico de demanda, mantendo o sistema em equilíbrio e evitando o acúmulo de pacientes na fila de exame, particularmente nos períodos críticos de atendimento.

4.2.3 Estruturação de intervalos operacionais entre blocos

Entre cada bloco de exames, foram introduzidas pausas calculadas de 10 minutos, que funcionam como *buffers*, elementos que são recomendados em sistemas de serviços complexos. Essas pausas tiveram como finalidades:


- Absorver desvios naturais dos tempos de exame e *setup*, evitando atrasos sucessivos.
- Permitir ajustes na máquina, reposicionamento da equipe ou reconfiguração pontual sem impactar o bloco seguinte.
- Reduzir a pressão operacional contínua, permitindo maior constância produtiva ao longo do dia.

A utilização de *buffers* é apresentada na literatura de simulação em saúde como uma ferramenta eficaz para controlar a variabilidade e reduzir tempos de espera em ambientes com alta dependência tecnológica (DATTA; UPADHYAY; JAIDEEP, 2012; MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).

A aplicação desse conjunto de princípios demonstrou, de acordo com a simulação computacional, impactos positivos no desempenho do sistema. Os resultados sintetizam como a reorganização do fluxo contribuiu para um processo mais estável, menos sujeito a variações e mais produtivo. Os principais efeitos observados foram a redução do tempo de permanência no sistema de 139 para aproximadamente 119 minutos (Figura 28), uma experiência mais eficiente para o paciente, e o aumento da capacidade produtiva, de 161 para 178 pacientes em cinco dias, sem alteração de recursos (Figura 29). De forma complementar, observaram-se:


- Redução de aproximadamente 23% no tempo médio de fila, devido à alternância entre exames curtos e longos e ao amortecimento proporcionado pelos buffers;
- Redução da carga operacional sobre as técnicas de radiologia (Figura 30), caiu para 68.90% devido à menor necessidade de ajustes técnicos e reconfigurações frequentes do equipamento, contribuindo para um ritmo de trabalho mais equilibrado.

Figura 10 - Tempo de permanência no sistema no cenário 2.




Fonte: Autor (2025)

Figura 11 - Quantidade de pessoas atendidas no cenário 2.



Fonte: Autor (2025)

Figura 12 - Média de tempo de cada setor realizando atividades no cenário 2.



Fonte: Autor (2025)

Comparando a Figura 27 e a Figura 30 é possível compreender de forma mais clara como a reorganização da sequência de exames e a redução das transições desnecessárias entre protocolos tornaram o trabalho no setor de RM mais estável e previsível. Entre as técnicas de radiologia, nota-se uma redução proporcional do tempo em *providing care*, ainda que a duração dos exames tenha permanecido a mesma. Essa mudança não significa diminuição do cuidado ou da presença junto ao


paciente, mas sim um processo mais fluido, com menos interrupções e retrabalhos ao longo do exame. É importante destacar que o tempo de *setup* está registrado no estado *performing task*, contudo, quando o número de *setups* diminui, o impacto é sentido também no *providing care*. Com menos trocas de bobinas, menos ajustes inesperados e menos reinícios de posicionamento, a técnica consegue acompanhar o paciente de maneira mais contínua e sem tantas intervenções corretivas.

4.3 CENÁRIO 3: AMPLIAÇÃO DA CAPACIDADE TECNOLÓGICA

O terceiro cenário proposto teve como objetivo avaliar o impacto da expansão da capacidade instalada na etapa de exame, por meio da adição de uma terceira máquina de RM e da incorporação de um terceiro técnico de radiologia responsável pela sua operação. Todos os demais parâmetros operacionais, como tempos de *setup*, duração dos exames, regras de agendamento, lógica de fluxo e número de pacientes agendados por dia, foram mantidos idênticos aos do cenário atual, permitindo isolar o efeito da nova capacidade produtiva sobre o desempenho do sistema. Do ponto de vista da lógica de modelagem, a etapa de exame passou a operar como um conjunto de três recursos paralelos (RM1, RM2 e RM3) alimentados pela mesma fila de pacientes, sem escalonamento adicional ou alteração da política de prioridade.

A simulação realizada no *software* evidenciou mudanças nos principais indicadores operacionais. Primeiramente, como esperado, observou-se redução expressiva no tempo médio de permanência do paciente no sistema, que caiu de 139 minutos (cenário atual) e 119 minutos (cenário 2) para 74,67 minutos no cenário 3 (Figura 31). Essa redução decorre da eliminação quase completa das filas nas salas de ressonância, uma vez que a capacidade instalada passou a exceder amplamente a demanda simulada. A presença de três máquinas capazes de absorver o mesmo perfil de exames distribuiu a carga de forma mais homogênea, minimizando tempos de espera e ampliando a fluidez geral do processo.


Figura 13 - Tempo de permanência no sistema no cenário 3.



Fonte: Autor (2025)

Outro efeito significativo foi o aumento do throughput semanal. Mantendo a lógica de agendamento aleatório e os mesmos parâmetros da agenda base, o sistema foi capaz de concluir 227 atendimentos em cinco dias (Figura 32), valor substancialmente superior ao observado nos cenários anteriores. Esse incremento reflete a capacidade adicional instalada, que permitiu que os pacientes entrassem e saíssem do sistema de forma mais rápida, liberando vagas para novos atendimentos sem que o fluxo sofresse congestionamentos.

Figura 14 - Quantidade de pessoas atendidas no cenário 3.




Fonte: Autor (2025)

A análise da utilização dos recursos, *avg state* (Figura 33), confirma essa tendência de melhor distribuição operacional. A utilização média dos técnicos de radiologia caiu para 54,74%, valor inferior ao observado nos cenários anteriores. Essa redução pelo fato que ao adicionar uma terceira máquina e um novo técnico, o sistema passa a operar com capacidade ociosa estrutural, permitindo que a demanda seja absorvida de forma distribuída entre os três equipamentos. Assim, o tempo dedicado

às atividades de *performing task* diminui proporcionalmente, enquanto o estado *idle* passa a representar parcela significativa da jornada, um indicativo de que nesse cenário, o equipamento deixa de ser o gargalo do processo.

Figura 15 - Média de tempo de cada setor realizando atividades no cenário 3.



Fonte: Autor (2025)


Comportamento semelhante foi observado entre enfermeiras e recepcionistas. Embora seus tempos no estado *providing Care* tenham aumentado, esses valores permanecem dentro de faixas inferiores ao limite de saturação, mostrando que a adição da nova máquina não provocou sobrecarga em setores adjacentes. Isso ocorre porque a redução do tempo de permanência dos pacientes evita acúmulo simultâneo de atendimentos, preservando a estabilidade do fluxo.

4.4 CENÁRIO 4: ANÁLISE INTEGRADA DE EXPANSÃO ESTRUTURAL E OTIMIZAÇÃO OPERACIONAL

O cenário 4 foi desenvolvido com o objetivo de avaliar o desempenho máximo potencial do sistema combinando as duas estratégias investigadas nos cenários anteriores: (i) a reorganização do fluxo assistencial por meio do agrupamento de exames e estruturação de intervalos operacionais entre bloco e (ii) a ampliação da capacidade instalada com a inclusão de uma terceira máquina de ressonância magnética e a contratação de um terceiro técnico de radiologia. A simulação foi conduzida no FlexSim utilizando os mesmos parâmetros e distribuições do cenário base, permitindo isolar o efeito exclusivo dessas intervenções estruturais e operacionais.

Os resultados indicaram que esta combinação produziu o melhor desempenho global entre todos os cenários analisados. O *throughput* semanal atingiu 280 pacientes (Figura 34), valor 42,5% superior ao observado no cenário atual e ainda 18,92% maior do que o obtido no cenário 3. Este aumento resultou da eliminação quase completa do gargalo previamente localizado na sala de exame, agora suportada por três máquinas operando em fluxo equilibrado.


Figura 16 - Quantidade de pessoas atendidas no cenário 4.



Fonte: Autor (2025)

Simultaneamente, nota-se uma redução no tempo médio de permanência do paciente no sistema, que caiu para 50 minutos (Figura 35). Essa diminuição refletiu a estabilização do processo, a menor formação de filas na etapa de exame e a maior fluidez entre triagem, preparação e realização do procedimento.

Figura 17 - Tempo de permanência no sistema no cenário 4.




Fonte: Autor (2025)

Enquanto no cenário atual os técnicos permaneciam 76,07% ocupados, no cenário 4 a utilização caiu para aproximadamente 40% no estado de *performing task*, 23% em *providing care*. Essa distribuição equilibrada indica que, embora a capacidade produtiva tenha aumentado e a proporção relativa de *providing care* tenha diminuído em relação ao cenário atual, a utilização efetiva aumentou, pois, a capacidade adicional favoreceu um fluxo contínuo e evitou gargalos gerados por esperas internas

no processo. Isso explica o aumento da utilização total das técnicas de 54,74% no cenário 3 para 63,45% no cenário 4 (Figura 36). Esse resultado não indica maior sobrecarga, mas sim uma operação mais estável, com menor variabilidade, menos transições entre estados que não geram valor ao processo e melhor sincronização entre o fluxo de pacientes e os recursos disponíveis.

Figura 18 - Média de tempo de cada setor realizando atividades no cenário 4.



Fonte: Autor (2025)

Para as enfermeiras, foram observados 11,92% em *providing care*, porcentagem semelhante aos cenários anteriores, coerente com o papel concentrado em etapas iniciais do fluxo, cuja duração é curta e pouco variável. A predominância do estado *idle* é esperada, pois suas atividades são restritas à triagem e orientações preliminares, não sendo influenciadas diretamente pela inclusão de uma nova máquina. As recepcionistas registraram 9,11% em *providing care*, proporção semelhante aos cenários anteriores. Importante destacar que a baixa utilização no modelo não representa subutilização real, mas sim um reflexo da modelagem focada exclusivamente no processo de RM. Com base nesses indicadores, o cenário 4 representou o estado de melhor desempenho observado em toda a investigação. A combinação de um fluxo mais previsível com o aumento de capacidade estrutural permitiu elevar significativamente o *throughput*, reduzir o tempo de permanência no sistema e distribuir a carga de trabalho de forma mais sustentável entre os profissionais, sem transferir o gargalo para outras etapas do processo. Em síntese, o cenário demonstrou que intervenções simultaneamente técnicas e operacionais podem produzir efeitos sinérgicos na performance global do serviço de ressonância magnética.

4.5 ANÁLISE FINANCEIRA INTEGRADA À SIMULAÇÃO

A análise financeira foi conduzida de forma integrada aos resultados da simulação computacional, com o objetivo de avaliar economicamente e comparar os cenários operacionais modificados, baseados na reorganização dos recursos existentes e aqueles que envolvem a ampliação da capacidade tecnológica por meio da aquisição de uma nova máquina de ressonância magnética.

Assim, buscou-se diferenciar os ganhos econômicos decorrentes de melhorias operacionais daqueles associados a investimentos estruturais, assegurando coerência entre o comportamento do sistema observado na simulação, a utilização dos recursos e os resultados financeiros. As estimativas de custos e receitas foram realizadas com base no *throughput* obtido em cada cenário, considerando explicitamente os recursos humanos, os custos operacionais e a base de ativos envolvidos.

4.5.1 Estrutura de custos considerados

A estrutura de custos adotada engloba (a) recursos humanos, (b) custos de manutenção e (c) reposição de peças e depreciação dos equipamentos de ressonância magnética. Esses custos foram tratados de forma semelhante entre os cenários analisados, variando em função da configuração operacional simulada, de forma a garantir comparabilidade econômica entre as alternativas analisadas.

4.5.1.1 Custos com recursos humanos

Foram considerados os custos mensais dos profissionais diretamente envolvidos no fluxo de atendimento de RM, obtidos a partir de informações disponibilizadas pela própria empresa estudada, com base em suas políticas internas de remuneração vigentes no período da coleta de dados. Esses valores correspondem aos salários brutos praticados pela clínica para as funções de recepção, enfermagem e técnicos em radiologia, incluindo os adicionais legais aplicáveis, como o adicional de insalubridade no caso dos técnicos de radiologia. como apresentados Tabela 12. No cenário com ampliação tecnológica, foi incorporado um técnico adicional de radiologia para operação da terceira máquina de RM.

Tabela 4 - Custos mensais com recursos humanos no cenário com três RM

Cargo	Quantidade	Salário Mensal Individual (R\$)	Custo mensal total (R\$)
Recepcionista	2	2.041,41	4.082,82
Técnica de enfermagem	2	2.932,90	5.865,80
Técnico em radiologia	3	3.990,00	11.970,00
Total mensal	—	—	21.918,62

Fonte: Autor (2025)

Nos cenários com duas máquinas, o custo mensal com recursos humanos é inferior, uma vez que não há a necessidade do terceiro técnico em radiologia, permanecendo inalterados os demais cargos.

4.5.1.2 Custos de manutenção e reposição de peças

Os valores referentes aos custos de manutenção preventiva, corretiva e reposição de peças das máquinas de RM foram obtidos a partir de informações disponibilizadas pela empresa estudada, com base nos contratos firmados junto ao fabricante dos equipamentos. Esses contratos estabelecem os valores de R\$360.834,79 anualmente, o que equivale a R\$ 30.069,57 mensais de manutenção e cobertura técnica aplicáveis a cada máquina em operação. Dessa forma, o custo total de manutenção varia de acordo com o número de máquinas em operação em cada cenário.

No cenário de ampliação tecnológica, adotou-se a hipótese contratual de garantia integral de um ano para a nova máquina. Assim, durante os primeiros 12 meses de operação, os custos de manutenção incidem apenas sobre as máquinas já existentes. A partir do segundo ano, com o término da garantia, os custos passam a refletir a operação de todas as máquinas disponíveis.

4.5.1.3 Depreciação dos equipamentos

A depreciação dos equipamentos de RM foi considerada em todos os cenários, proporcionalmente ao número de máquinas em operação, uma vez que o objetivo da análise financeira é comparar economicamente configurações distintas do sistema simulado.

Foi adotado o método de depreciação linear, considerando uma vida útil econômica de 10 anos e valor de aquisição de R\$ 2.000.000,00 por equipamento. A Tabela 13 apresenta os parâmetros e o cálculo da depreciação unitária adotada neste estudo.

Tabela 5 - Parâmetros e cálculo da depreciação unitária das máquinas de RM

Parâmetro	Descrição	Valor
Valor de aquisição do equipamento	Custo por máquina de RM	R\$ 2.000.000,00
Vida útil econômica	Horizonte considerado	10 anos
Método de depreciação	Linear	—
Depreciação anual por máquina	$2.000.000 / 10$	R\$ 200.000,00
Depreciação mensal por máquina	$200.000 / 12$	R\$ 16.666,67

Fonte: Autor (2025)

A depreciação mensal unitária resultante é de R\$ 16.666,67 por máquina. A depreciação total considerada em cada cenário corresponde à soma da depreciação unitária de todas as máquinas em operação. Assim, nos cenários atual e reorganizado, que operam com duas máquinas, a depreciação mensal total é de R\$ 33.333,34, enquanto no cenário com ampliação tecnológica, que conta com três máquinas, a depreciação mensal total é de R\$ 50.000,01. A diferença entre esses valores decorre do maior número de ativos depreciáveis no cenário de ampliação de recursos, permanecendo constantes o valor unitário, a vida útil econômica e o método de depreciação adotados.

4.5.2 Estimativa de receita por throughput

A estimativa de receita foi realizada a partir da integração entre os resultados operacionais da simulação e os dados econômicos da clínica, tendo como base o

throughput de pacientes obtido em cada cenário analisado. O objetivo desta seção é apresentar de forma transparente o procedimento adotado para o cálculo da receita mensal, bem como os valores estimados para cada cenário operacional.

A receita unitária considerada na análise corresponde ao valor médio ponderado dos exames de RM (Equação 4), calculado a partir dos valores unitários praticados pela clínica e da frequência relativa de cada tipo de exame observada no fluxo real de pacientes (Figura 23). Por razões de confidencialidade institucional, os valores unitários individuais dos exames não são apresentados. O cálculo do valor médio ponderado foi realizado por meio da ponderação dos preços pelos respectivos percentuais de ocorrência no mix de exames, resultando em um valor médio de R\$ 747,50 por paciente atendido.

Equação 1 - Valor médio ponderado dos exames de RM

$$R_m = \sum_{i=1}^n (p_i \times f_i)$$

Onde:

- p_i é o valor unitário do exame i ;
- f_i é a frequência relativa do exame i no fluxo observado.

A receita mensal estimada de cada cenário foi obtida pela multiplicação desse valor médio ponderado pelo *throughput* mensal observado na simulação, conforme a Equação 5:

Equação 2 - Cálculo da receita mensal do cenário

$$Receita_{mensal} = Throughput_{mensal} \times R_m$$

Nos cenários em que o *throughput* foi obtido diretamente em base mensal, o valor foi utilizado conforme reportado pela simulação. Para o segundo cenário com ampliação tecnológica (cenário 4), o *throughput* foi inicialmente obtido a partir de uma simulação de cinco dias úteis, totalizando 280 pacientes. Para fins de comparabilidade com os demais cenários, esse valor foi convertido para base mensal, considerando-se quatro semanas operacionais, resultando em um *throughput* mensal estimado de 1.120 pacientes.

A Tabela 14 evidencia que as diferenças de receita mensal entre os cenários decorrem exclusivamente da variação do *throughput* obtido na simulação, uma vez que o valor médio ponderado por paciente foi mantido constante. O cenário reorganizado apresenta aumento de receita em relação ao cenário atual sem acréscimo da capacidade instalada, refletindo ganhos oriundos da otimização do fluxo de atendimento. Por sua vez, os dois cenários com ampliação tecnológica apresentam os maiores valores de receita mensal, em função do aumento da capacidade produtiva proporcionado pela adição de uma nova máquina de RM, sendo possível observar diferenças de desempenho econômico entre configurações operacionais distintas mesmo com a mesma base tecnológica.

Tabela 6 - Receita mensal estimada por cenário

Cenário	Throughput mensal (pacientes)	Receita mensal estimada (R\$)
Cenário 1	692	517.270,00
Cenário 2	765	571.087,50
Cenário 3	976	729.560,00
Cenário 4	1120	837.200,00

Fonte: Autor (2025)

4.5.3 Análise comparativa dos cenários

A análise comparativa dos cenários foi conduzida com base na integração entre os resultados operacionais obtidos por meio da simulação computacional e os indicadores econômicos estimados para cada configuração do sistema. Foram considerados quatro cenários distintos: o cenário 1, o cenário reorganizado sem ampliação da capacidade instalada (cenário 2) e dois cenários com expansão tecnológica por meio da aquisição de uma nova máquina de ressonância magnética (cenários 3 e 4), os quais diferem entre si pela configuração operacional adotada.

A comparação inicial entre os cenários com duas máquinas de RM evidencia que a reorganização operacional resulta em aumento do *throughput* e, conseqüentemente, da receita mensal estimada, sem acréscimo dos custos estruturais associados à base tecnológica. Esse resultado demonstra que ganhos

econômicos relevantes podem ser obtidos por meio da melhoria do fluxo de atendimento e da melhor alocação dos recursos existentes, configurando uma alternativa de baixo risco financeiro e de maior viabilidade no curto prazo.

Ao comparar o cenário 2 com os cenários que incorporam a aquisição de uma nova máquina, observa-se que a ampliação da capacidade tecnológica proporciona incrementos expressivos no *throughput* e na receita mensal. Entretanto, esses ganhos operacionais e econômicos estão condicionados a um conjunto de restrições estruturais e financeiras, que devem ser consideradas no processo decisório.

Do ponto de vista financeiro, a aquisição de uma nova máquina implica um investimento inicial elevado, associado não apenas ao custo de compra do equipamento, mas também à imobilização de capital e ao impacto sobre a capacidade de investimento da clínica. Além disso, mesmo considerando períodos de garantia para manutenção, a ampliação da base de ativos resulta em aumento dos custos estruturais ao longo do tempo, especialmente aqueles relacionados à depreciação dos equipamentos e à necessidade de ampliação do quadro técnico para operação contínua da nova máquina.

Sob a perspectiva de infraestrutura física, a incorporação de uma nova máquina de RM impõe restrições relacionadas à adequação do espaço físico da clínica. Esses requisitos incluem, entre outros aspectos, a disponibilidade de área compatível com o porte do equipamento, adaptações estruturais específicas, blindagem adequada, adequações elétricas e de climatização, além do atendimento às normas técnicas e regulatórias vigentes. Tais intervenções podem demandar investimentos adicionais e tempo de implementação, que não são capturados diretamente pelos indicadores financeiros do estudo, mas impactam a viabilidade prática da expansão.

A existência de dois cenários com ampliação tecnológica permite avaliar de forma mais aprofundada o papel da configuração operacional mesmo sob a mesma base tecnológica. Os resultados mostram que, embora os cenários 3 e 4 contem com três máquinas de RM, diferenças na organização do fluxo e na utilização dos recursos resultam em desempenhos econômicos distintos. O cenário 4, que apresenta maior *throughput* mensal, alcança a maior receita mensal estimada entre os cenários analisados, evidenciando que a efetividade dos benefícios do investimento depende

de uma configuração operacional adequada e de uma gestão alinhada à nova capacidade instalada.

De forma geral, a análise comparativa demonstra que os cenários podem ser organizados em uma hierarquia de desempenho econômico e de complexidade de implementação. O cenário atual apresenta o menor nível de eficiência operacional e econômica. O cenário reorganizado representa um avanço significativo, com ganhos obtidos sem investimento em novos ativos e com menores restrições financeiras e estruturais. Os cenários com ampliação tecnológica apresentam os maiores níveis de desempenho econômico potencial, porém estão associados a maiores restrições financeiras, estruturais e organizacionais, que devem ser cuidadosamente avaliadas.

Assim, os resultados evidenciam que estratégias baseadas exclusivamente em reorganização operacional e aquelas que envolvem expansão tecnológica não devem ser tratadas como excludentes, mas como alternativas com diferentes níveis de risco, investimento e complexidade. A decisão gerencial deve considerar não apenas o desempenho econômico estimado, mas também a capacidade financeira da organização, a viabilidade de adequação da infraestrutura física e a maturidade da gestão para operar um sistema mais complexo.

Com o objetivo de sintetizar os principais resultados da análise comparativa, a Tabela 15 apresenta as vantagens e restrições associadas a cada cenário avaliado, evidenciando as diferenças em termos de desempenho econômico, complexidade de implementação e viabilidade prática.

Tabela 7- Síntese comparativa de vantagens e restrições dos cenários analisados

Cenário	Configuração operacional	Principais vantagens	Principais restrições
Cenário 1	2 RMs – fluxo original	<ul style="list-style-type: none">• Não requer investimentos adicionais• Estrutura física e organizacional já consolidada• Baixa complexidade de gestão	<ul style="list-style-type: none">• Menor <i>throughput</i> e receita• Maior tempo de espera dos pacientes• Gargalos operacionais persistentes• Uso ineficiente da capacidade instalada

Cenário	Configuração operacional	Principais vantagens	Principais restrições
Cenário 2	2 RMs – fluxo otimizado	<ul style="list-style-type: none"> • Aumento do <i>throughput</i> sem investimento em ativos • Ganhos econômicos com baixo risco financeiro • Melhor aproveitamento dos recursos existentes • Implementação rápida 	<ul style="list-style-type: none"> • Capacidade produtiva limitada à infraestrutura existente • Ganhos dependentes da disciplina operacional • Menor potencial de crescimento no médio e longo prazo
Cenário 3	3 RMs – configuração operacional atual	<ul style="list-style-type: none"> • Ampliação da capacidade produtiva • Redução adicional dos tempos de espera • Aumento significativo da receita mensal 	<ul style="list-style-type: none"> • Elevado investimento inicial • Necessidade de adequação da estrutura física • Ampliação do quadro técnico • Maior custo estrutural (depreciação e manutenção) • Risco de subutilização se a gestão não for adequada
Cenário 4	3 RMs – configuração operacional otimizada	<ul style="list-style-type: none"> • Maior <i>throughput</i> entre os cenários • Melhor captura dos benefícios do investimento • Maior potencial de receita mensal • Redução mais expressiva de gargalos 	<ul style="list-style-type: none"> • Mesmas restrições financeiras e estruturais do cenário 3 • Maior complexidade operacional • Dependência de demanda suficiente para sustentar a capacidade instalada

Fonte: Autor (2025)

4.5.4 Viabilidade econômica e retorno do investimento

A viabilidade econômica dos cenários analisados foi avaliada a partir da integração entre os resultados operacionais obtidos na simulação e os indicadores financeiros estimados para cada configuração do sistema. A análise tem como foco principal os cenários que incorporam a aquisição de uma nova máquina de RM, comparados ao cenário 2 que representa a melhor alternativa sem investimento adicional em ativos físicos.

Nos cenários sem ampliação da capacidade instalada, não há necessidade de investimento inicial em equipamentos. Assim, a avaliação econômica restringe-se à comparação entre receitas e custos operacionais correntes, evidenciando que o cenário reorganizado apresenta ganhos econômicos decorrentes da otimização do fluxo de atendimento, com baixo risco financeiro e rápida implementação.

Nos cenários com ampliação tecnológica, a viabilidade econômica passa a depender da capacidade do sistema em transformar o aumento do *throughput* em receita suficiente para compensar o investimento inicial e os custos estruturais adicionais. O investimento considerado corresponde à aquisição de uma nova máquina de RM, no valor de R\$ 2.000.000,00, além da ampliação do quadro técnico necessária para sua operação. Os custos recorrentes de manutenção, reposição de peças e depreciação dos equipamentos foram incorporados à análise conforme descrito nas seções anteriores.

Para avaliar o retorno do investimento, adotou-se o método do payback simples, definido como a razão entre o investimento inicial e o ganho incremental de receita mensal obtido em relação ao cenário reorganizado. Esse método foi escolhido por sua simplicidade e adequação a análises comparativas exploratórias, permitindo estimar a ordem de grandeza do tempo necessário para recuperação do capital investido. A Equação 6 apresenta a formulação utilizada:

Equação 3 - Equação de payback

$$Payback_{meses} = \frac{Invenstimento\ inicial}{Ganho\ incremental\ da\ receita\ mensal}$$

O ganho incremental de receita mensal foi calculado como a diferença entre a receita mensal estimada de cada cenário com nova máquina e a receita mensal do cenário reorganizado, isolando, assim, o efeito econômico da expansão tecnológica em relação à alternativa de otimização sem investimento.

A Tabela 16 apresenta os cálculos de retorno do investimento para os dois cenários com ampliação tecnológica.

Tabela 8 - Viabilidade econômica e retorno do investimento

Indicador	Cenário 3	Cenário 4
Receita mensal estimada (R\$)	729.560,00	837.200,00
Receita mensal – Cenário 2 (R\$)	571.087,50	571.087,50
Ganho incremental de receita mensal (R\$)	158.472,50	266.112,50
Investimento inicial	2.000.000,00	2.000.000,00
Payback simples (meses)	≈ 12,6	≈ 7,5
Payback simples (anos)	≈ 1,05	≈ 0,62

Fonte: Autor (2025)

Os resultados indicam que ambos os cenários com aquisição de nova máquina apresentam potencial de retorno do investimento em horizonte inferior a dois anos, sendo que o cenário 4 se destaca por apresentar maior ganho incremental de receita mensal e, conseqüentemente, menor tempo estimado de retorno. Esse resultado evidencia que a viabilidade econômica da expansão tecnológica depende fortemente da configuração operacional adotada, mesmo quando o investimento inicial é o mesmo.

Ressalta-se que o ganho incremental utilizado no cálculo do *payback* representa uma medida exploratória baseada na receita adicional gerada pelo aumento do *throughput*. Embora os custos estruturais adicionais tenham sido incorporados à análise econômica ao longo do capítulo, o uso da receita incremental como base para o *payback* visa fornecer uma estimativa da ordem de grandeza do retorno do investimento, adequada ao caráter comparativo do estudo.

Adicionalmente, o método do *payback* simples não considera o valor do dinheiro no tempo, tampouco incorpora explicitamente possíveis atrasos associados à implantação da nova máquina, tais como adequações da infraestrutura física, obtenção de licenças regulatórias e treinamento da equipe.

Por outro lado, o ganho incremental utilizado no cálculo do *payback* representa uma medida exploratória baseada na receita adicional gerada pelo aumento do *throughput*. Embora os custos estruturais adicionais tenham sido incorporados à análise econômica ao longo do capítulo, o uso da receita incremental como base para

o *payback* visa fornecer uma estimativa da ordem de grandeza do retorno do investimento, adequada ao caráter comparativo do estudo.

Outra variável relevante refere-se à dependência da demanda. A viabilidade econômica dos cenários com ampliação tecnológica está condicionada à manutenção de níveis de demanda compatíveis com a capacidade instalada. Caso a demanda não seja suficiente para absorver o aumento do throughput simulado, os ganhos incrementais de receita tendem a ser reduzidos, impactando negativamente o tempo de retorno do investimento.

Assim, a análise de viabilidade econômica demonstra que, embora os cenários com nova máquina de ressonância magnética apresentem elevado potencial de retorno financeiro no médio e longo prazo, sua implementação está associada a maiores restrições financeiras, estruturais e organizacionais quando comparados ao cenário reorganizado. A decisão pela expansão tecnológica deve, portanto, considerar não apenas o retorno financeiro estimado, mas também a capacidade financeira da clínica, o tempo necessário para implantação da nova estrutura e a maturidade gerencial requerida para operar um sistema mais complexo.

5 CONCLUSÃO

Este estudo utilizou a simulação computacional fundamentada em dados reais como ferramenta de apoio à decisão para a gestão de serviços de diagnóstico por imagem. A partir da modelagem do fluxo de pacientes em uma clínica de ressonância magnética no interior de Pernambuco, foi possível compreender, quantificar e intervir sobre os principais fatores que impactam o desempenho operacional do sistema, especialmente os tempos de espera, a utilização dos recursos críticos e a capacidade produtiva.

Os resultados mostraram que os gargalos do processo se concentravam principalmente na etapa de exame, fortemente influenciada pela variabilidade dos tempos de setup e pela lógica de agendamento adotada. No cenário atual, a elevada utilização das técnicas de radiologia e das máquinas de RM confirmou a existência de restrições estruturais que limitam o número atendimentos e prolongam o tempo de permanência dos pacientes no sistema. A simulação permitiu tornar visíveis essas restrições, oferecendo uma visão sistêmica que dificilmente seria alcançada apenas por observação empírica.

A avaliação dos cenários alternativos demonstrou que intervenções exclusivamente operacionais, sem incremento de recursos físicos ou humanos, já são capazes de gerar ganhos relevantes. A reorganização da sequência de exames, o agrupamento por similaridade técnica, a alternância entre procedimentos de curta e longa duração e a introdução de buffers operacionais resultaram em redução significativa do tempo médio de permanência no sistema e aumento da capacidade de atendimento semanal. Esses achados reforçam que a eficiência do serviço não depende apenas de investimentos em tecnologia, mas também de decisões gerenciais baseadas em análise quantitativa e compreensão do fluxo assistencial.

De maneira integrada, os resultados obtidos nos quatro cenários permitiram identificar impactos operacionais decorrentes das intervenções simuladas. No entanto, apesar da redução do tempo médio de permanência observada, de aproximadamente 139 para 119 minutos no cenário reorganizado e para cerca de 75 minutos no cenário com três máquinas, tais melhorias devem ser interpretadas com criticidade, uma vez que dependem de condições específicas de demanda, disponibilidade da equipe e estabilidade do processo. De modo semelhante, o

incremento do *throughput* semanal, de 161 para 178 e posteriormente para 227 exames, indica potencial de expansão produtiva, mas não garante que tais níveis seriam sustentáveis em longo prazo diante da variabilidade real do serviço.

No que se refere ao desempenho financeiro, os resultados evidenciam que o aumento do *throughput* obtido nos cenários simulados está diretamente associado a incrementos relevantes na receita mensal estimada. A receita passou de aproximadamente R\$ 517.270,00 no cenário atual para R\$ 571.087,50 no cenário reorganizado, sem necessidade de investimento adicional em ativos. Nos cenários com expansão estrutural, a incorporação de uma nova máquina de RM elevou a receita mensal para valores entre R\$ 729.560,00 e R\$ 837.200,00, a depender da configuração operacional adotada. A análise financeira integrada incorporou explicitamente custos de recursos humanos, manutenção, reposição de peças e depreciação dos equipamentos, bem como a avaliação do retorno do investimento por meio do método do *payback* simples, indicando tempos estimados de retorno entre 7,5 e 12,6 meses para os cenários com ampliação tecnológica. Esses resultados indicam que, embora a expansão estrutural apresente maior potencial de geração de receita, sua viabilidade econômica está condicionada à adequada configuração operacional, à manutenção da demanda e à capacidade financeira da organização para absorver o investimento inicial e os custos estruturais associados.

Assim, embora os resultados indiquem benefícios potenciais do uso de simulação na gestão de serviços de imagem, tais achados representam apenas parte de um contexto mais amplo e não encerram a discussão sobre o tema. Os cenários simulados mostram tendências e possibilidades de melhoria, mas não substituem a complexidade da operação real, reforçando a necessidade de interpretações cautelosas e de aprofundamento contínuo.

Além das contribuições práticas, este trabalho também explorou um contexto ainda pouco investigado na literatura: clínicas privadas de médio porte, com foco específico em exames de ressonância magnética. A padronização metodológica adotada, desde a coleta de dados até a análise dos relatórios de simulação, amplia a replicabilidade do estudo e fortalece sua relevância científica.

Como oportunidades para trabalhos futuros, pode-se ampliar o escopo do modelo para incluir outros serviços da clínica, como tomografia e ultrassonografia,

possibilitando uma visão integrada da operação e da alocação compartilhada de recursos. A incorporação de comportamentos dos pacientes, como atrasos, faltas ou necessidade de repetição de exames, por meio de abordagens híbridas que integrem DES e ABS, também representa um avanço metodológico relevante. A integração entre simulação e técnicas de otimização, como algoritmos genéticos ou heurísticas de agendamento, visando identificar automaticamente sequências ótimas de exames e escalas de equipe. Outra possibilidade se refere à incorporação de indicadores econômicos mais detalhados, permitindo análises custo-benefício e avaliação do retorno sobre investimento em diferentes cenários de expansão. Por fim, a aplicação do modelo em outras unidades ou regiões permitiria análises comparativas e maior generalização dos resultados.

Desta forma, a simulação computacional se mostra como um instrumento estratégico para a melhoria contínua dos serviços de saúde, capaz de apoiar decisões mais eficientes, sustentáveis e alinhadas à geração de valor para o paciente. O presente estudo reafirma seu potencial tanto como ferramenta gerencial quanto como objeto de investigação científica, contribuindo para o avanço da engenharia de produção aplicada à saúde.

REFERÊNCIAS

AHMAD, A. N. A. *et al.* Implementation of Lean Technique towards Reducing Waiting Time in a Public Healthcare using Arena Simulation. **International Journal of Integrated Engineering**, 2021. v. 13, n. 5, p. 201–214.

ALA, A.; CHEN, F. **Appointment Scheduling Problem in Complexity Systems of the Healthcare Services: A Comprehensive Review**. *Journal of Healthcare Engineering*. Hindawi Limited.

ALKHER, M. *et al.* Case study of healthcare organization improvement with lean concept. **Tehnicki Vjesnik**, 2019. v. 26, n. 3, p. 845–851.

BAHARI, A.; ASADI, F. A simulation optimization approach for resource allocation in an emergency department healthcare unit. **Global Heart**, 11 fev. 2020. v. 15, n. 1.

BANIK, D. *et al.* A decision support model for selecting unmanned aerial vehicle for medical supplies: context of COVID-19 pandemic. **The International Journal of Logistics Management**, 14 mar. 2023. v. 34, n. 2, p. 473–496.

BELHOR, M. *et al.* Learning-Based Metaheuristic Approach for Home Healthcare Optimization Problem. **Computer Systems Science and Engineering**, 2023. v. 45, n. 1, p. 1–19.

BUSCHIAZZO, M.; MULA, J.; CAMPUZANO-BOLARIN, F. Simulation optimization for the inventory management of healthcare supplies. **International Journal of Simulation Modelling**, 1 jun. 2020. v. 19, n. 2, p. 255–266.

CAI, H.; JIA, J. Using Discrete Event Simulation (DES) To Support Performance-Driven Healthcare Design. **Health Environments Research and Design Journal**, 1 jul. 2019. v. 12, n. 3, p. 89–106.

CHANG, H. C. *et al.* The application of GSCM in eliminating healthcare waste: Hospital EDC as an example. **International Journal of Environmental Research and Public Health**, 1 nov. 2019. v. 16, n. 21.

CHEN, X. *et al.* Matching patients and healthcare service providers: a novel two-stage method based on knowledge rules and OWA-NSGA-II algorithm. **Journal of Combinatorial Optimization**, 15 jan. 2019. v. 37, n. 1, p. 221–247.

CREMA, M.; VERBANO, C. **Simulation modelling and lean management in healthcare: first evidences and research agenda. Total Quality Management and Business Excellence.** Routledge.

DATTA, R.; UPADHYAY, K. K.; JAIDEEP, C. N. Simulation and its role in medical education. **Medical Journal Armed Forces India**, 1 abr. 2012. v. 68, n. 2, p. 167–172. . Acesso em: 25 ago. 2025.

FELIX, L. T. X. E S.; MAIOR, C. B. S. Revisão Sistemática de Aplicações de Simulação em Serviços de Saúde. [S.l.]: [s.n.], 2025.

FLORIDIS, J. Debriefing after critical incidents in rural and remote healthcare settings - a remote clinician perspective. **Rural and Remote Health**, 2023. v. 23, n. 1.

GAO, X.; WEN, J.; SONG, J. Capacity allocation and revenue sharing in healthcare alliances. **Flexible Services and Manufacturing Journal**, 1 dez. 2020. v. 32, n. 4, p. 829–851.

GIL, A. C. **Como elaborar projetos de pesquisa**. 6. ed. São Paulo: Atlas, 2017.

GROVES-KIRKBY, N. *et al.* Large-scale calibration and simulation of COVID-19 epidemiologic scenarios to support healthcare planning. **Epidemics**, 1 mar. 2023. v. 42.

IMPROTA, G. *et al.* Agile six sigma in healthcare: Case study at santobono pediatric hospital. **International Journal of Environmental Research and Public Health**, 1 fev. 2020. v. 17, n. 3.

JERRY BANKS. **Handbook of Simulation: Principles, Methodology, Advances, Applications, and Practice**. 1. ed. Atlanta: John Wiley & Sons, Inc., 1998.

KUIPER, A. *et al.* A flexible and optimal approach for appointment scheduling in healthcare. **Decision Sciences**, 1 fev. 2023. v. 54, n. 1, p. 85–100.

LARRAIN, N.; GROENE, O. Simulation modeling to assess performance of integrated healthcare systems: Literature review to characterize the field and visual aid to guide model selection. **PLoS ONE**, 1 jul. 2021. v. 16, n. 7 July.

LIN, Y. X.; LIN, Chi Hao; LIN, Chih Hao. Post-earthquake Patient diversion strategies for improving regional emergency healthcare accessibility. **International Journal of Disaster Risk Reduction**, 1 out. 2023. v. 96.

MIELCZAREK, B.; UZIAŁKO-MYDLIKOWSKA, J. Application of computer simulation modeling in the health care sector: a survey. **SIMULATION**, 15 fev. 2012. v. 88, n. 2, p. 197–216.

MINISTÉRIO DA SAÚDE. **Normas e Manuais Técnicos Cadernos de Atenção Primária**. Brasília: [s.n.], 2010. V. 29.

MITROPOULOS, P.; ADAMIDES, E.; MITROPOULOS, I. Redesigning a network of primary healthcare centres using system dynamics simulation and optimisation. **Journal of the Operational Research Society**, 2023. v. 74, n. 2, p. 574–589.

MONKS, T.; HARPER, A. Computer model and code sharing practices in healthcare discrete-event simulation: a systematic scoping review. **Journal of Simulation**, 2023.

MWANZA, J.; TELUKDARIE, A.; IGUSA, T. Optimising Maintenance Workflows in Healthcare Facilities: A Multi-Scenario Discrete Event Simulation and Simulation Annealing Approach. **Modelling**, 1 jun. 2023. v. 4, n. 2, p. 224–250.

ORDU, M. *et al.* A novel healthcare resource allocation decision support tool: A forecasting-simulation-optimization approach. **Journal of the Operational Research Society**, 2021. v. 72, n. 3, p. 485–500.

PORTER, M. E. What Is Value in Health Care? **New England Journal of Medicine**, 23 dez. 2010. v. 363, n. 26, p. 2477–2481. Disponível em: <<http://www.nejm.org/doi/abs/10.1056/NEJMp1011024>>.

ROY, S. N.; SHAH, B. J.; GAJJAR, H. **Application of Simulation in Healthcare Service Operations**. **ACM Transactions on Modeling and Computer Simulation**. Association for Computing Machinery.

SEVERINO, A. J. **Metodologia do trabalho científico**. 24. ed. São Paulo: Cortez, 2017.

SHAKOOR, M. *et al.* Application of discrete event simulation for performance evaluation in private healthcare: The case of a radiology department. **International Journal of Healthcare Management**, 2021. v. 14, n. 4, p. 1303–1310.

SOORAPANTH, S.; ELDABI, T.; YOUNG, T. Towards a framework for evaluating the costs and benefits of simulation modelling in healthcare. **Journal of the Operational Research Society**, 2023. v. 74, n. 3, p. 637–646.

SRIVASTAVA, S. K. Green supply-chain management: A state-of-the-art literature review. **International Journal of Management Reviews**, 28 mar. 2007. v. 9, n. 1, p. 53–80.

TEYMOURIFAR, A. Simulation-based optimization for resectorization in healthcare systems. **Journal of Simulation**, 2024. v. 18, n. 3, p. 311–330.

TLAPA, D. *et al.* **Effects of Lean Interventions Supported by Digital Technologies on Healthcare Services: A Systematic Review**. **International Journal of Environmental Research and Public Health**. MDPI.

VERGARA, S. C. **Projetos e relatórios de pesquisa em administração**. 16. ed. São Paulo: Atlas, 2016.

WANG, L.; DEMEULEMEESTER, E. Simulation optimization in healthcare resource planning: A literature review. **IISE Transactions**, 3 out. 2023. v. 55, n. 10, p. 985–1007. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/24725854.2022.2147606>>.

WU, X.; LI, J.; CHU, C. H. Modeling multi-stage healthcare systems with service interactions under blocking for bed allocation. **European Journal of Operational Research**, 1 nov. 2019. v. 278, n. 3, p. 927–941.

YIN, R. K. **Case Study Research: Design and Methods**. 5. ed. Thousand Oaks, CA: SAGE, 2014.

YOUNG, T. *et al.* The costs and value of modelling-based design in healthcare delivery: five case studies from the US. **Health Systems**, 2 jul. 2020. v. 9, n. 3, p. 253–262.

AGRADECIMENTOS

Antes de tudo, agradeço a Deus pela força, sabedoria e direção em cada etapa desta caminhada, iluminando meus passos e sustentando minhas escolhas.

À minha família, expressei minha mais profunda gratidão, especialmente ao meu esposo e a minha mãe, pelos incentivos e conselhos que foram fundamentais para que eu pudesse prosseguir com coragem e determinação.

Sou igualmente grata aos amigos que, de diferentes formas, me ofereceram apoio e motivação, tornando esta trajetória mais leve.

De forma especial, agradeço ao meu orientador, Caio Souto Maior, pela dedicação, pelas orientações sempre construtivas, pelas ideias compartilhadas e pelo cuidado atento em cada etapa deste trabalho. Sua empatia, nos meus momentos de fragilidade, e comprometimento foram fundamentais para que esta dissertação se concretizasse.

Estendo meus agradecimentos a todos os que compõem o PPGEP-CAA, pelo compromisso com uma formação acadêmica de excelência, pelo acolhimento e pelas oportunidades de crescimento.

RESUMO

Este estudo teve como objetivo modelar e simular o fluxo de pacientes em uma clínica de diagnóstico por imagem, com foco nos exames de ressonância magnética (RM), visando reduzir o tempo de espera e melhorar a eficiência operacional. A pesquisa foi conduzida por meio de estudo de caso com abordagem quantitativa, utilizando Simulação de Eventos Discretos (DES), implementada no software FlexSim Healthcare e parametrizada com dados reais do processo assistencial. Foram avaliados quatro cenários: o modelo atual, um cenário reorganizado com otimização da lógica de agendamento, um cenário de ampliação estrutural com inclusão de uma nova máquina de RM e um cenário financeiro integrando custos e receitas. O modelo permitiu identificar gargalos operacionais e avaliar impactos em indicadores como tempo de permanência no sistema, *throughput* e retorno do investimento. Os resultados indicaram que a reorganização operacional reduziu o tempo médio de permanência dos pacientes de 139 para 119 minutos e elevou o *throughput* mensal de 692 para 765 exames, sem necessidade de investimentos adicionais. Nos cenários com expansão tecnológica, a inclusão de uma nova máquina ampliou a capacidade produtiva, com *throughput* mensal variando entre 976 e 1.120 exames. A análise financeira, considerando custos de recursos humanos, manutenção e depreciação, indicou *payback* simples entre 7,5 e 12,6 meses. Como principal contribuição, o estudo demonstra a aplicabilidade da integração entre simulação computacional e análise financeira como ferramenta de apoio à decisão em clínicas privadas de médio porte, oferecendo um modelo replicável para avaliação conjunta de desempenho operacional e viabilidade econômica.

Palavras-chave: Serviços de saúde; simulação computacional; diagnóstico por imagem; ressonância magnética; otimização de processos.

ABSTRACT

This study aimed to model and simulate patient flow in a diagnostic imaging clinic, focusing on magnetic resonance imaging (MRI) examinations, with the objective of reducing waiting times and improving operational efficiency. A quantitative case study approach was adopted, employing Discrete Event Simulation (DES) implemented in FlexSim Healthcare and parameterized using real operational data from the clinic. Four scenarios were analyzed: the current operational model; a reorganized scenario based on scheduling optimization; a structural expansion scenario involving the addition of a new MRI machine; and a financial scenario integrating cost and revenue analysis. The simulation model enabled the identification of operational bottlenecks and the evaluation of key performance indicators, including time in system, throughput, and return on investment. Results showed that workflow reorganization reduced the average patient time in the system from 139 to 119 minutes and increased monthly throughput from 692 to 765 examinations without additional capital investment. In the expansion scenarios, the introduction of a new MRI unit substantially increased productive capacity, with monthly throughput ranging from 976 to 1,120 examinations. The financial assessment, incorporating staffing costs, maintenance, and equipment depreciation, indicated a simple payback period between 7.5 and 12.6 months. The study demonstrates the value of integrating computational simulation with financial analysis as a decision-support tool for medium-sized private imaging clinics, offering a replicable framework for jointly assessing operational performance and economic feasibility.

Keywords: Healthcare services; computer simulation; diagnostic imaging; magnetic resonance imaging; process optimization.

LISTA DE ILUSTRAÇÕES

Figura 1 - Organização dos níveis de atenção à saúde.....	20
Figura 2 - Abordagens de simulação em saúde.....	23
Figura 3 - Metodologia do estudo.	35
Figura 4 - Mapa do fluxo assistencial.	38
Figura 5 - Frequência de observações por tipo de exame.	40
Figura 6 - Fluxo de execução de exame no Flexsim.	42
Figura 7 - Tempo de permanência no sistema em minutos.....	44
Figura 8 - Quantidade de pessoas atendidas em 5 dias.	44
Figura 9 - Média de tempo de cada setor realizando atividades.....	46
Figura 10 -Tempo de permanência no sistema no cenário 2.	49
Figura 11 - Quantidade de pessoas atendidas no cenário 2.	49
Figura 12 - Média de tempo de cada setor realizando atividades no cenário 2.....	49
Figura 13 - Tempo de permanência no sistema no cenário 3.	51
Figura 14 - Quantidade de pessoas atendidas no cenário 3.	51
Figura 15 - Média de tempo de cada setor realizando atividades no cenário 3.....	52
Figura 16 - Quantidade de pessoas atendidas no cenário 4.	53
Figura 17 - Tempo de permanência no sistema no cenário 4.	53
Figura 18 - Média de tempo de cada setor realizando atividades no cenário 4.....	54

LISTA DE TABELAS

Tabela 1- Comparação das principais abordagens de simulação aplicadas à saúde e suas evidências na literatura.....	28
Tabela 2 - Frequência e distribuição de tempo de setup.....	41
Tabela 3 - Distribuição de tempo de realização de exame.....	41
Tabela 4 - Custos mensais com recursos humanos no cenário com três RM.....	56
Tabela 5 - Parâmetros e cálculo da depreciação unitária das máquinas de RM.....	57
Tabela 6 - Receita mensal estimada por cenário.....	59
Tabela 7- Síntese comparativa de vantagens e restrições dos cenários analisados	61
Tabela 8 - Viabilidade econômica e retorno do investimento	64

SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	CONTRIBUIÇÕES.....	16
1.2	OBJETIVOS.....	17
1.2.1	OBJETIVO GERAL.....	17
1.2.2	OBJETIVOS ESPECÍFICOS.....	17
1.3	ESTRUTURA DO DA DISSERTAÇÃO.....	18
2	FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA.....	19
2.1	PRESTAÇÃO DE SERVIÇOS EM SAÚDE E GESTÃO DE PROCESSOS.....	19
2.2	SIMULAÇÃO COMPUTACIONAL APLICADA À SAÚDE.....	21
2.3	APLICAÇÕES PRÁTICAS DE SIMULAÇÃO EM SERVIÇOS DE SAÚDE.....	30
2.4	LIMITAÇÕES E OPORTUNIDADES DA LITERATURA.....	32
3	METODOLOGIA.....	34
3.1	CARACTERIZAÇÃO DA PESQUISA.....	34
3.2	CARACTERIZAÇÃO DO PROBLEMA.....	35
3.3	ORIGEM E PARAMETRIZAÇÃO DOS DADOS.....	36
3.4	SOFTWARE ESCOLHIDO.....	37
4	APLICAÇÃO NA ÁREA DE SAÚDE.....	38
4.1	CENÁRIO ATUAL.....	38
4.1.1	Modelagem no Flexsim Healthcare.....	42
4.2	CENÁRIO 2: REORGANIZAÇÃO DA SEQUÊNCIA E LÓGICA DE AGENDAMENTO.....	46
4.2.1	Construção do novo fluxo.....	46
4.2.2	Alternância estratégica entre exames curtos e longos.....	47
4.2.3	Estruturação de intervalos operacionais entre blocos.....	48
4.3	CENÁRIO 3: AMPLIAÇÃO DA CAPACIDADE TECNOLÓGICA.....	50

4.4	CENÁRIO 4: ANÁLISE INTEGRADA DE EXPANSÃO ESTRUTURAL E OTIMIZAÇÃO OPERACIONAL	52
4.5	ANÁLISE FINANCEIRA INTEGRADA À SIMULAÇÃO	55
4.5.1	Estrutura de custos considerados	55
4.5.2	Estimativa de receita por throughput.....	57
4.5.3	Análise comparativa dos cenários	59
4.5.4	Viabilidade econômica e retorno do investimento.....	62
5	CONCLUSÃO	66
	REFERÊNCIAS	69

6 INTRODUÇÃO

O propósito fundamental dos sistemas de saúde é proporcionar serviços acessíveis, assegurar atendimentos médicos pontuais e maximizar a satisfação dos pacientes. Esses sistemas têm papel importante no bem-estar da sociedade pois são responsáveis por garantir a manutenção da saúde, a prevenção de doenças e a recuperação dos indivíduos (PORTER, 2010). Além disso, impactam diretamente indicadores sociais e econômicos, como a produtividade da população, a redução da mortalidade evitável e a equidade no acesso aos serviços essenciais (IMPROTA *et al.*, 2020; LARRAIN; GROENE, 2021).

Neste contexto, as organizações de saúde enfrentam desafios crescentes relacionados à gestão operacional, aumentando a busca por métodos que permitam otimizar processos, reduzir custos e aumentar a eficiência dos serviços prestados (BANIK *et al.*, 2023). Entre os principais problemas enfrentados estão o tempo excessivo de espera dos pacientes (AHMAD *et al.*, 2021), alocação ineficiente de recursos humanos e físicos (BAHARI; ASADI, 2020), o desequilíbrio entre demanda e capacidade (SHAKOOR *et al.*, 2021), além da falta de integração entre os diferentes setores dos serviços de saúde (LARRAIN; GROENE, 2021). Tempo de espera no atendimento em serviços de diagnóstico por imagem é influenciado por múltiplos fatores operacionais e clínicos. No caso da ressonância magnética, a complexidade dos exames constitui uma variável crítica, podendo demandar entre 20 e 60 minutos, a depender do protocolo adotado e da necessidade de contraste.

Além disso, a variabilidade do perfil dos pacientes impacta significativamente o processo: idosos, indivíduos com mobilidade reduzida ou condições clínicas específicas exigem maior tempo de preparação, enquanto situações como claustrofobia podem levar à repetição ou interrupção do exame (SHAKOOR *et al.*, 2021). Soma-se a isso o tempo de setup entre procedimentos, que envolve limpeza da sala, troca de bobinas e ajustes técnicos no equipamento, acrescentando minutos relevantes ao ciclo operacional e gerando períodos alternados de sobrecarga e ociosidade (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012). O efeito acumulado dessas variabilidades impacta diretamente a capacidade produtiva da clínica: em unidades privadas de médio porte, um equipamento de ressonância magnética

realiza, em média, entre 15 e 25 exames por dia, dependendo da eficiência do agendamento e da disponibilidade da equipe (CAI; JIA, 2019). Quando falhas de gestão ocorrem como atrasos, sobreposição de agendamentos ou indisponibilidade de recursos, surgem gargalos que reduzem o *throughput* diário, comprometem a sustentabilidade financeira do serviço e prejudicam a experiência do paciente. Esses fatores comprometem tanto a qualidade do atendimento quanto a sustentabilidade financeira das instituições o que demanda soluções analíticas mais robustas, como a simulação computacional, que permite explorar cenários hipotéticos e apoiar decisões baseadas em dados (ROY; SHAH; GAJJAR, 2021; WANG; DEMEULEMEESTER, 2023).

Neste cenário, a modelagem e a simulação computacional surgem como ferramentas para avaliar cenários complexos sem interferência direta no ambiente real, além de apoiar decisões estratégicas baseadas em evidências (BANIK *et al.*, 2023). Essas ferramentas vêm sendo utilizadas na área da saúde para analisar e melhorar processos assistenciais e administrativos. A simulação permite representar de forma realista o comportamento dinâmico dos sistemas de saúde, testando diferentes cenários sem risco aos pacientes ou à operação real (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).

No âmbito do agendamento de exames, busca-se definir a alocação eficiente de pacientes em horários estratégicos durante um período de planejamento, com o intuito de garantir a disponibilidade adequada de recursos nos momentos de maior demanda (ALA; CHEN, 2022; KUIPER *et al.*, 2023). Esse arranjo impacta diretamente a redução dos tempos de espera, a equidade no acesso e a percepção de qualidade do atendimento prestado (AHMAD *et al.*, 2021).

Nas modelagens e simulação na saúde, as abordagens podem variar conforme o nível de detalhe e os objetivos da análise, ou seja, não existe um único método adequado para todos os problemas, uma vez que cada técnica possui potencialidades e limitações. Assim, a Simulação de Eventos Discretos (em inglês, *Discrete Event Simulation*, DES) é eficaz em cenários onde os processos são sequenciais e baseados em fluxos bem definidos como no caso de clínicas e hospitais que lidam com filas, tempos de espera e alocação de recursos (AHMAD *et al.*, 2021; ROY;

SHAH; GAJJAR, 2021). Quando o foco está em compreender a dinâmica de sistemas complexos com múltiplos agentes interativos, como políticas públicas de saúde ou redes regionais de atendimento, metodologias como a Dinâmica de Sistemas (em inglês, *System Dynamics*, SD) e a Simulação Baseada em Agentes (em inglês, *Agent Based Simulation*, ABS) são mais apropriadas (LARRAIN; GROENE, 2021; MITROPOULOS; ADAMIDES; MITROPOULOS, 2023). Essas técnicas permitem simular comportamentos adaptativos, interdependência entre elementos do sistema e efeitos de longo prazo. Seu uso é valorizado por apoiar o desenvolvimento de sistemas de saúde mais responsivos e sustentáveis, além de oferecer uma base sólida para avaliar intervenções antes de sua aplicação prática (SOORAPANTH; ELDABI; YOUNG, 2023; WANG; DEMEULEMEESTER, 2023). No entanto, quando o objetivo é analisar detalhadamente o fluxo operacional de pacientes, os tempos de espera e a utilização de recursos em processos assistenciais bem definido, a DES se mostra a abordagem mais adequada ao representar com precisão eventos que ocorrem em momentos específicos e apoiar decisões voltadas à eficiência operacional (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; SHAKOOR *et al.*, 2021).

Logo, este estudo propõe o desenvolvimento de modelo de simulação para avaliar e recomendar melhorias no processo de atendimento em uma clínica de diagnósticos por imagem no interior de Pernambuco. Tal contexto se justifica pela relevância do serviço de diagnóstico na jornada do paciente e pelo impacto direto que a espera prolongada pode causar em termos clínicos, econômicos e de experiência do usuário.

6.1 CONTRIBUIÇÕES

Do ponto de vista científico, este trabalho propõe uma metodologia e simulação aplicada aos serviços de saúde construídas a partir de dados reais de uma clínica de diagnóstico por imagem, contexto ainda pouco explorado pois a maior parte dos estudos concentra-se em hospitais de grande porte ou em análises macroestruturais. Além disso, a padronização proposta, que inclui desde a coleta de dados até a construção e validação do modelo, contribui para a replicabilidade e comparação de novos estudos, o que servirá de base para investigações futuras em cenários semelhantes.

Na perspectiva prática, o estudo fornece evidências quantitativas sobre gargalos operacionais e ineficiências na gestão de processos de unidades de diagnóstico por imagem, especificamente no setor de ressonância magnética, identificando oportunidades de melhoria e propondo soluções para redução de tempos de espera, melhoria da utilização de equipamentos de alto custo e qualificação do trabalho das equipes. A análise de cenários alternativos, construída por meio de simulação, permite que gestores testem mudanças sem impactar diretamente a rotina assistencial, favorecendo a tomada de decisão baseada em dados. Essa contribuição está alinhada à premissa de geração de valor em saúde ao associar melhores resultados assistenciais a uma gestão eficiente de recursos. Assim, simultaneamente se insere no debate acadêmico, ampliando a compreensão sobre a aplicação da simulação computacional em saúde, e oferece subsídios concretos para a melhoria da qualidade e da eficiência dos serviços de diagnóstico, reforçando sua relevância científica e social.

6.2 OBJETIVOS

6.2.1 OBJETIVO GERAL

Modelar e simular o processo de atendimento de uma clínica de diagnóstico por imagem, com foco na identificação de gargalos e proposição de estratégias que promovam a redução do tempo de espera dos pacientes e a melhoria da eficiência operacional.

6.2.2 OBJETIVOS ESPECÍFICOS

Para o alcance do objetivo geral, tem-se os seguintes objetivos específicos:

- H) Mapear e descrever as etapas do processo de atendimento da clínica, identificando os principais pontos críticos relacionados ao tempo de espera;
- I) Coletar dados operacionais relevantes como, tempo de execução, recursos disponíveis, volume de atendimentos;
- J) Desenvolver um modelo de simulação utilizando a abordagem de DES;
- K) Testar cenários alternativos de atendimento, avaliando o impacto de diferentes estratégias operacionais;

- L) Avaliar os ganhos potenciais em termos de tempo de espera, capacidade de atendimento e uso de recursos;
- M) Propor melhorias com base nos resultados da simulação, considerando aspectos como agendamento, alocação de pessoal e recursos físicos;
- N) Documentar o processo de modelagem, simulação, análise e recomendação, contribuindo para replicabilidade futura.

6.3 ESTRUTURA DO DA DISSERTAÇÃO

Este trabalho está estruturado em outros cinco capítulos a seguir:

O Capítulo II trata da fundamentação teórica sobre a qual foi desenvolvida esta dissertação. Inclui também uma revisão de literatura.

O Capítulo III apresenta os procedimentos metodológicos desse estudo.

O Capítulo IV apresenta a aplicação do método e os resultados encontrados.

No Capítulo V são descritas as conclusões e sugestões de trabalhos futuros.

7 FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA

Este capítulo tem como objetivo apresentar a fundamentação teórica e a revisão bibliográfica que sustentam esta pesquisa, abordando (i) inicialmente os desafios da prestação de serviços de saúde e da gestão de processos em sistemas complexos, caracterizados por restrições de recursos, alta demanda e necessidade de eficiência; (ii) as principais metodologias de simulação computacional aplicadas à saúde, destacando definições, estruturas, vantagens, limitações e aplicações práticas; (iii) estudos aplicados que evidenciam a relevância da simulação na melhoria de fluxos assistenciais, na alocação de recursos e na redução de gargalos em serviços de saúde; e (iv) a análise crítica da literatura aponta lacunas, como a escassez de pesquisas em clínicas especializadas, a integração entre diferentes técnicas de simulação e a ausência de estudos que considerem simultaneamente eficiência operacional e experiência do paciente.

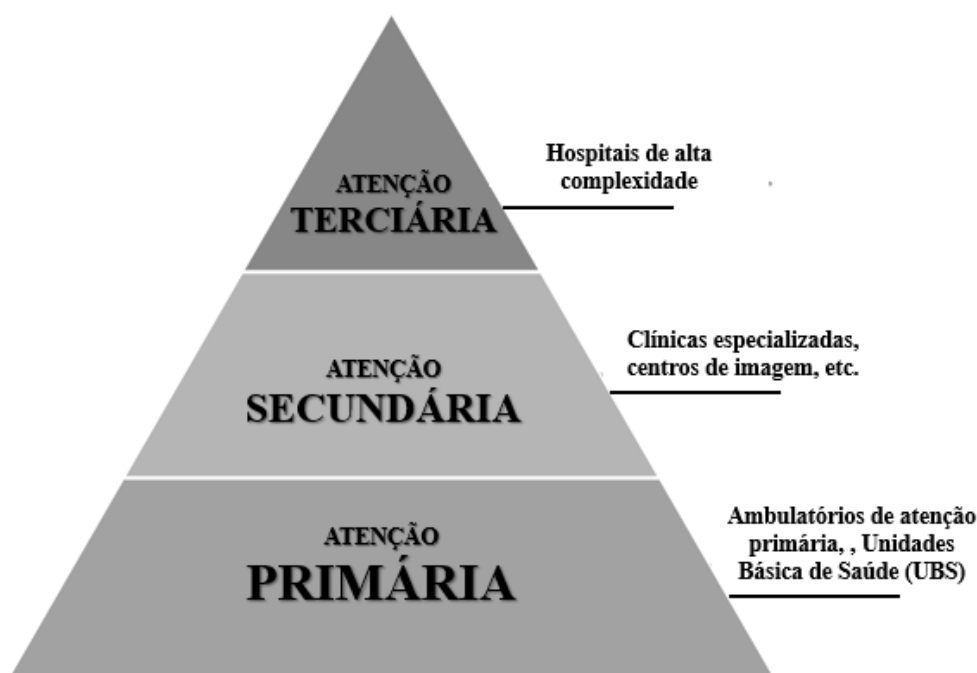
7.1 PRESTAÇÃO DE SERVIÇOS EM SAÚDE E GESTÃO DE PROCESSOS

A prestação de serviços de saúde constitui um dos pilares essenciais da sociedade, englobando ações de promoção, prevenção, recuperação e reabilitação da saúde, sempre com foco no acesso e na qualidade do cuidado ofertado (MINISTÉRIO DA SAÚDE, 2010). No entanto, os sistemas de saúde apresentam crescente complexidade, impulsionada pelo aumento da demanda, pela limitação de recursos humanos e tecnológicos e pela pressão por custos cada vez mais controlados. Nesse cenário, a gestão eficiente de processos torna-se indispensável para garantir a sustentabilidade e a resolutividade desses serviços (WANG; DEMEULEMEESTER, 2023).

Segundo o Ministério da Saúde (2010), os sistemas de saúde podem ser organizados em diferentes níveis de atenção (Figura 19), cada um com papéis e desafios específicos. O nível primário compreende ações de atenção básica, como consultas médicas gerais, acompanhamento de condições crônicas e programas de promoção da saúde, é nele que ocorre o primeiro contato do paciente com o sistema, funcionando como porta de entrada e coordenador do cuidado. O nível secundário corresponde a serviços de média complexidade, incluindo especialidades médicas,

exames laboratoriais e de imagem, além de atendimentos ambulatoriais especializados. Já o nível terciário concentra procedimentos de alta complexidade, como cirurgias de grande porte, internações hospitalares especializadas e serviços de terapia intensiva. Cada um desses níveis depende de recursos distintos, fluxos de atendimento integrados e mecanismos eficientes de regulação para garantir continuidade e qualidade no cuidado prestado.

Figura 19 - Organização dos níveis de atenção à saúde.



Fonte: (Felix e Maior, 2025)

Os serviços de saúde configuram sistemas altamente complexos e interdependentes, nos quais a variabilidade da demanda e a escassez de recursos influenciam diretamente a qualidade do atendimento. Essa realidade é evidenciada em serviços ambulatoriais e de média complexidade, como clínicas de diagnóstico por imagem, onde a gestão do fluxo de pacientes, da agenda de exames e do uso de equipamentos impacta diretamente indicadores de desempenho, como o tempo médio de espera, a taxa de ocupação de recursos e o tempo total de permanência no sistema (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012). A ineficiência em qualquer dessas etapas pode gerar atrasos, gargalos e comprometimento da experiência do paciente.

Embora o treinamento da equipe seja importante para reduzir variabilidades e padronizar fluxos, a literatura mostra que a evolução tecnológica dos equipamentos exerce papel ainda mais determinante para ganhos expressivos de eficiência. Novas

gerações de aparelhos de imagem permitem maior velocidade de aquisição e *softwares* de reconstrução mais ágeis, reduzindo significativamente os tempos de exame e aumentando a capacidade de atendimento por turno (WANG; DEMEULEMEESTER, 2023).

Além da eficiência operacional, é fundamental que os serviços de saúde gerem valor para o paciente. Conforme discutido por Porter (2010), o valor em saúde deve ser mensurado pela relação entre os resultados clínicos obtidos e os custos necessários para alcançá-los. Isso significa que a redução de tempos de espera, a otimização da utilização de equipamentos e a melhor alocação da equipe não apenas aumentam a eficiência do serviço, mas também contribuem para entregar um cuidado mais acessível, assertivo e focado no paciente.

Nas clínicas de diagnóstico por imagem, fatores como atrasos entre agendamentos, tempo de preparação do equipamento e disponibilidade da equipe clínica exercem papel crítico no desempenho do processo assistencial. A ausência de estratégias adequadas de gestão pode resultar em sobrecarga de profissionais, longos períodos de ociosidade de equipamentos ou, ainda, perda de capacidade produtiva. Estudos têm mostrado que a aplicação de métodos quantitativos, como a modelagem e a simulação, permite avaliar diferentes cenários operacionais, identificar gargalos e propor alternativas de melhoria baseadas em evidências (SHAKOOR *et al.*, 2021).

Diante desse cenário, ferramentas de apoio à decisão tornam-se importantes para enfrentar o dinamismo e a incerteza dos serviços de saúde. Nesse sentido, a simulação computacional surge como uma estratégia promissora, pois possibilita a reprodução do funcionamento de sistemas reais, sem a interferência direta nas operações, permitindo testar alternativas, reduzir riscos e apoiar gestores na tomada de decisão (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; WANG; DEMEULEMEESTER, 2023).

7.2 SIMULAÇÃO COMPUTACIONAL APLICADA À SAÚDE

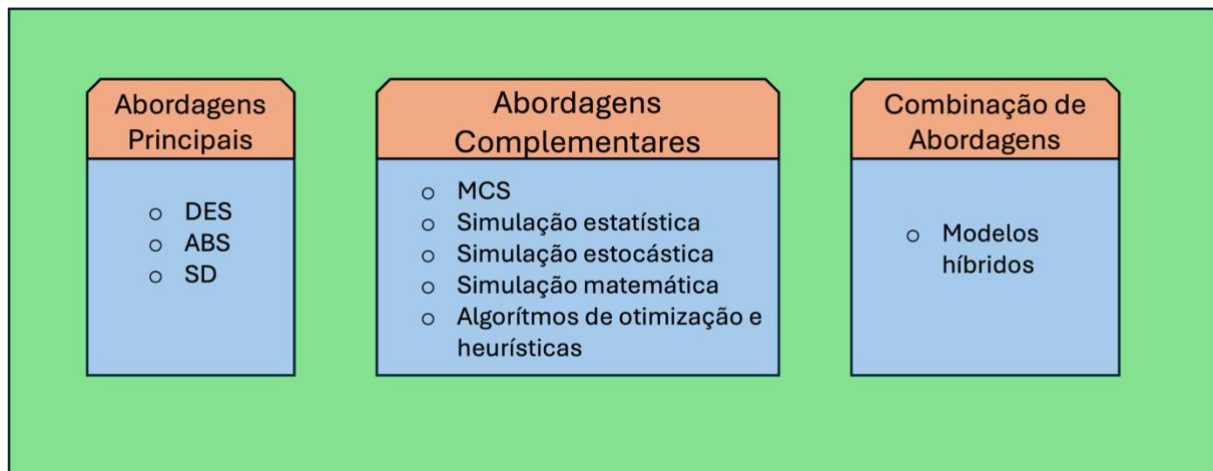
A simulação computacional tem sido utilizada como ferramenta de apoio à decisão na gestão de serviços de saúde. De maneira clássica, segundo Banks (1998), a simulação consiste na reprodução do funcionamento de processos ou sistemas do

mundo real ao longo do tempo, permitindo análises preditivas e avaliação de cenários sem a necessidade de interferir diretamente nas operações reais. Essa definição enfatiza a simulação como uma ferramenta de análise quantitativa, voltada para prever impactos de mudanças operacionais e apoiar decisões baseadas em dados.

Por outro lado, Datta et al. (2012) ressalta que a simulação deve também ser compreendida como uma técnica que substitui ou amplia experiências reais por experiências guiadas, capazes de reproduzir aspectos substanciais do mundo real de maneira interativa. Essa perspectiva amplia a noção clássica, ao considerar a simulação não apenas como uma ferramenta de análise, mas também como um recurso de aprendizagem e treinamento, que permite vivenciar situações complexas em ambiente seguro, reduzindo riscos e facilitando o desenvolvimento de competências práticas.

A aplicação da simulação na saúde pode assumir diferentes formas, de acordo com o nível de detalhe necessário e os objetivos do estudo. Conforme a Figura 20 na literatura destacam-se como principais metodologias de simulação aplicadas à saúde a DES, a ABS e a SD. No entanto, outras abordagens, como a Simulação de Monte Carlo (em inglês, *Monte Carlo Simulation*, MCS), modelos estatísticos e estocásticos, simulação matemática e algoritmos de otimização, têm sido utilizadas, especialmente quando integradas às técnicas clássicas, compondo modelos híbridos que buscam explorar os pontos fortes de cada metodologia (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; WANG; DEMEULEMEESTER, 2023). Cada uma dessas metodologias apresenta estrutura própria, vantagens e limitações, sendo aplicadas isoladamente ou de forma integrada conforme a complexidade do problema investigado (LARRAIN, 2021; ROY; SHAH; GAJJAR, 2021).

Figura 20 - Abordagens de simulação em saúde.



Fonte: Autor (2025)

Dentre os diferentes tipos de simulação, a DES é uma das técnicas mais consolidadas em estudos aplicados à saúde pois permite representar sistemas em que o estado muda apenas em instantes específicos no tempo, geralmente desencadeados por eventos como a chegada de pacientes, movimentação entre setores, início ou término de procedimentos e utilização de recursos (ROY; SHAH; GAJJAR, 2021). Sua estrutura básica é composta por três elementos principais: (1) entidades, que representam os pacientes ou recursos em circulação; (2) eventos, que modificam o estado do sistema; e (3) filas, que modelam os tempos de espera e os gargalos existentes no processo. Essa abordagem é utilizada para a análise de serviços hospitalares, pois possibilita mapear com precisão fluxos assistenciais, identificar pontos críticos e testar alternativas operacionais sem interferir diretamente na rotina operacional (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).

Entre as principais vantagens da DES estão a flexibilidade para representar processos bem estruturados, a capacidade de avaliar o impacto de diferentes cenários e o suporte à tomada de decisão baseada em dados. No entanto, sua limitação reside no fato desta ter foco em processos lineares e sequenciais, apresentando menor capacidade para capturar interações sociais complexas, comportamentos adaptativos de profissionais e pacientes ou efeitos de longo prazo, aspectos que podem ser melhor representados por outras metodologias, como a ABS ou a SD (LARRAIN; GROENE, 2021).

A ABS diferencia-se das demais abordagens por modelar o comportamento de unidades autônomas chamadas de agentes, que podem representar pacientes, profissionais de saúde, equipamentos ou até mesmo unidades organizacionais. Cada agente possui regras de decisão próprias e interage com outros agentes e com o ambiente, gerando dinâmicas emergentes que dificilmente seriam previstas apenas pela observação de processos agregados (MITROPOULOS; ADAMIDES; MITROPOULOS, 2023). A estrutura básica de um modelo ABS envolve a definição dos agentes, do ambiente em que atuam e das regras de interação que governam seu comportamento. Entre as vantagens da ABS está a capacidade de representar a heterogeneidade e a descentralização dos sistemas de saúde, capturando fenômenos como diferenças individuais entre pacientes, adesão a tratamentos ou dinâmicas de comunicação entre profissionais. Além disso, essa abordagem é aplicada em contextos em que decisões locais podem impactar significativamente o desempenho global do sistema. Contudo, uma limitação significativa da ABS é complexidade de modelagem, que demanda grande volume de dados e alto poder computacional para validar modelos com múltiplas variáveis, o que pode restringir sua aplicação em ambientes com recursos limitados.

Por outro lado, a SD adota uma perspectiva mais agregada e sistêmica, representando os serviços de saúde a partir de estoques, fluxos e laços de retroalimentação. Diferentemente da DES e da ABS, a SD busca compreender como diferentes variáveis se influenciam ao longo do tempo, permitindo identificar relações de causa e efeito e avaliar os impactos de políticas públicas ou mudanças estruturais em horizontes de médio e longo prazo (LARRAIN; GROENE, 2021). Essa abordagem é indicada para estudos de planejamento estratégico, como projeções de demanda por serviços. Entre suas principais vantagens estão a clareza conceitual, a capacidade de explorar cenários em escala macro e a possibilidade de analisar efeitos acumulativos e tendências de longo prazo. A SD apresenta, porém, limitações quanto ao detalhamento operacional, uma vez que trabalha com dados agregados e não representa com precisão a variabilidade individual dos pacientes ou os processos de atendimento em nível micro. Desta forma, embora importante para análise de sistemas complexos, sua aplicação em estudos de fluxos operacionais requer integração com outras metodologias, como a DES e a ABS, para gerar uma visão mais completa (WANG; DEMEULEMEESTER, 2023).

MCS é uma das técnicas clássicas de simulação, definida por Banks (1998) como um método baseado na geração repetida de cenários a partir de distribuições de probabilidade, permitindo analisar a incerteza em sistemas complexos. Na área da saúde, essa abordagem tem sido empregada para lidar com a variabilidade dos tempos de atendimento, da chegada de pacientes e do uso de recursos, fornecendo suporte à tomada de decisão em ambientes caracterizados por alto nível de incerteza. (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012) cita que a MCS é útil para representar processos estocásticos, como filas hospitalares e tempos de espera em setores de diagnóstico. Já Roy, Shah e Gajjar (2021), destacam que essa técnica pode auxiliar na avaliação de cenários de desempenho em operações de saúde, especialmente quando é necessário mensurar riscos ou prever impactos de mudanças em condições operacionais.

Embora a literatura frequentemente apresente MCS como uma técnica independente, é importante destacar que ela não constitui, por si só, um *framework* de modelagem de processos, mas sim um método estatístico de amostragem para lidar com incertezas. A MCS gera múltiplos cenários a partir de distribuições de probabilidade, permitindo explorar a variabilidade associada a tempos de atendimento, chegadas de pacientes ou uso de recursos (BANKS, 1998; MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012). Nesse sentido, sua aplicação isolada é comum em análises de risco, avaliação de custos e estudos de confiabilidade em saúde (ROY; SHAH; GAJJAR, 2021). Assim, DES e MCS não se situam exatamente no mesmo nível conceitual: a primeira é uma metodologia abrangente para representação de processos, e a segunda é uma técnica estatística que sustenta a variabilidade dentro desses modelos. Essa complementaridade explica por que muitos estudos relatam a integração de ambas, especialmente em setores como radiologia, emergências hospitalares e diagnóstico por imagem, nos quais a incerteza e a variabilidade são elementos centrais para a análise (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; SHAKOOR *et al.*, 2021).

Além dessas técnicas consolidadas, a literatura também destaca métodos como:

- Simulação matemática, que utiliza modelos analíticos de equações diferenciais e representações formais para capturar fenômenos em saúde, especialmente em situações epidemiológicas ou de crescimento populacional. Sua principal

vantagem é a clareza conceitual e rapidez de cálculo, mas sua limitação é a baixa adequação a sistemas muito complexos com múltiplas variáveis interdependentes (LARRAIN; GROENE, 2021).

- Simulação estatística (probabilística): fundamenta-se em métodos de inferência e em distribuições de probabilidade ajustadas a dados históricos, permitindo estimar tempos médios de atendimento, variabilidade da demanda e capacidade do sistema. Essa abordagem é útil para o planejamento de recursos e a avaliação de cenários operacionais, já que é baseada em observações reais. No entanto, sua principal limitação é a dependência da quantidade e da qualidade dos dados disponíveis, se os registros forem escassos ou enviesados, o modelo pode não representar adequadamente o comportamento do sistema (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).
- Simulação estocástica: incorpora de forma explícita a aleatoriedade intrínseca ao comportamento do sistema, admitindo que determinados fenômenos possuem variabilidade imprevisível mesmo quando não há dados suficientes para modelagem estatística detalhada. Essa abordagem é relevante em contextos de alta incerteza, como emergências hospitalares ou surtos epidêmicos, nos quais a demanda pode variar abruptamente. Sua vantagem é permitir explorar cenários plausíveis sob diferentes condições de incerteza, mas a limitação reside na dificuldade de validação prática, uma vez que os resultados são mais sensíveis a hipóteses sobre os processos aleatórios considerados (WANG; DEMEULEMEESTER, 2023).
- Algoritmos de otimização e heurísticas, frequentemente integrados a técnicas de simulação, contribuem para problemas de agendamento de pacientes, alocação de leitos e dimensionamento de equipes. Esses métodos podem gerar soluções eficientes em tempo reduzido, mas apresentam limitações quando aplicados a problemas de grande escala, nos quais a convergência para o ótimo depende da parametrização adequada (ORDU *et al.*, 2021).

Essas diferentes abordagens podem ser utilizadas isoladamente ou de forma integrada conforme os objetivos do estudo e a complexidade do sistema a ser modelado. Nos últimos anos, estudos têm destacado a relevância de modelos híbridos, que integram diferentes técnicas de simulação, como DES, ABS, SD e

algoritmos de otimização, buscando aproveitar os pontos fortes de cada abordagem (Tabela 9). Esses modelos permitem, representar ao mesmo tempo o detalhamento operacional dos fluxos assistenciais, os comportamentos emergentes das interações entre pacientes e profissionais e os efeitos de longo prazo no sistema (WANG, L.; DEMEULEMEESTER, 2023). Ordu et al. (2021), utilizaram um modelo híbrido de previsão, simulação e otimização para alocação de recursos em unidades de saúde, possibilitando maior eficiência no planejamento. Já Mitropoulos, Adamides e Mitropoulos (2023) empregaram a integração entre DES e SD para redesenhar a rede de atenção primária, explorando tanto a dinâmica operacional de centros de saúde quanto o impacto estratégico das mudanças propostas. Além disso, a combinação de DES e ABS pode auxiliar na alocação de leitos hospitalares, ao trabalhar simultaneamente as restrições de capacidade e os comportamentos adaptativos dos pacientes no sistema (WU; LI; CHU, 2019). Esses exemplos evidenciam como a utilização de modelos híbridos amplia a capacidade analítica da simulação, oferecendo uma visão mais completa e realista da complexidade dos serviços de saúde modernos.

Nos últimos anos, estudos têm destacado a relevância de modelos híbridos, que integram diferentes técnicas de simulação, como DES, ABS, SD e algoritmos de otimização, buscando aproveitar os pontos fortes de cada abordagem (Tabela 9). Esses modelos permitem, representar ao mesmo tempo o detalhamento operacional dos fluxos assistenciais, os comportamentos emergentes das interações entre pacientes e profissionais e os efeitos de longo prazo no sistema (WANG, L.; DEMEULEMEESTER, 2023). Ordu *et al.* (2021), utilizaram um modelo híbrido de previsão, simulação e otimização para alocação de recursos em unidades de saúde, possibilitando maior eficiência no planejamento. Já Mitropoulos, Adamides e Mitropoulos (2023) empregaram a integração entre DES e SD para redesenhar a rede de atenção primária, explorando tanto a dinâmica operacional de centros de saúde quanto o impacto estratégico das mudanças propostas. Além disso, a combinação de DES e ABS pode auxiliar na alocação de leitos hospitalares, ao trabalhar simultaneamente as restrições de capacidade e os comportamentos adaptativos dos pacientes no sistema (WU; LI; CHU, 2019). Esses exemplos evidenciam como a utilização de modelos híbridos amplia a capacidade analítica da simulação,

oferecendo uma visão mais completa e realista da complexidade dos serviços de saúde modernos.

Tabela 9- Comparação das principais abordagens de simulação aplicadas à saúde e suas evidências na literatura.

Tipo de Simulação	Definição	Vantagens	Limitações	Estudos na literatura
DES	Modela processos em que mudanças ocorrem em instantes discretos, desencadeados por eventos.	Ideal para mapear fluxos, gargalos e testar alternativas operacionais.	Foca em processos lineares, com dificuldade em capturar interações sociais complexas.	AHMAD, A. N. A. et al., 2021; MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; ROY; SHAH; GAJJAR, 2021; SHAKOOR et al., 2021
ABS	Modela unidades autônomas (agentes) que interagem entre si e com o ambiente.	Representa heterogeneidade e comportamentos emergentes.	Alta complexidade de modelagem e necessidade de muitos dados.	MITROPOULOS, P.; ADAMIDES; MITROPOULOS, I., 2023; WU; LI; CHU, 2019)
SD	Representa sistemas agregados por meio de estoques, fluxos e laços de retroalimentação.	Útil para planejamento estratégico e análise de longo prazo.	Menor detalhamento operacional, trabalha com dados agregados.	LARRAIN; GROENE, 2021; MITROPOULOS, P.; ADAMIDES; MITROPOULOS, I., 2023
MCS	Baseia-se em experimentos repetitivos com distribuições de probabilidade para lidar com incertezas.	Flexibilidade para explorar inúmeros cenários possíveis.	Exige poder computacional elevado e definição precisa das distribuições.	JERRY BANKS, 1998; ROY; SHAH; GAJJAR, 2021
Simulação Matemática	Utiliza equações e modelos analíticos para	Clareza conceitual e rapidez em	Pode não capturar o	LARRAIN; GROENE, 2021

	representar sistemas de saúde e prever comportamentos.	cálculos analíticos.	dinamismo de sistemas reais.	
Simulação Estatística	Usa modelos probabilísticos para estimar variabilidade e capacidade de processos.	Útil para planejamento de recursos e análise de capacidade.	Dependência de dados representativos e de qualidade.	MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012)
Simulação Estocástica	Incorpora aleatoriedade diretamente no modelo para representar incertezas reais do sistema.	Adequada para sistemas altamente imprevisíveis e dinâmicos.	Pode gerar cenários de difícil validação prática.	WANG, L.; DEMEULEMESTER, 2023
Algoritmos de Otimização e Heurísticas	Métodos computacionais que buscam soluções eficientes em problemas de alocação, escalonamento e otimização.	Soluções rápidas e aplicáveis a problemas reais de grande escala.	Dependem da parametrização correta e podem não garantir ótimo global.	BELHOR <i>et al.</i> , 2023; ORDU <i>et al.</i> , 2021

Fonte: Autor (2025)

Além das metodologias conceituais de simulação, *softwares* viabilizam suas aplicações práticas em saúde. Esses programas traduzem modelos teóricos em ambientes computacionais, permitindo análises detalhadas de fluxos assistenciais e recursos que, por sua vez, apresentam características próprias em termos de vantagens, limitações e aplicabilidade:

- FlexSim Healthcare: possui bibliotecas pré-configuradas para ambientes hospitalares como, salas de espera, triagem, exames e leitos, destaca-se pela capacidade de visualização 3D, que facilita a comunicação de cenários simulados a gestores e equipes não técnicas. É muito usado em hospitais que buscam otimizar fluxos de pacientes e reduzir gargalos sem necessidade de grande expertise em programação. A limitação, entretanto, é que, por ser muito

especializado, apresenta restrições na customização de modelos fora do contexto hospitalar (SHAKOOR *et al.*, 2021).

- Arena: amplamente consolidado na literatura de DES, utilizado em estudos de filas, prontos-socorros e agendamentos. Sua robustez e integração com Excel/VBA são pontos fortes, enquanto sua curva de aprendizado elevada e o tempo de modelagem são limitações (AHMAD *et al.*, 2021).
- Simul8: reconhecido pela interface amigável e rapidez de modelagem, sendo indicado para processos ambulatoriais e administrativos. A limitação está na menor flexibilidade para integração com modelos híbridos (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).
- AnyLogic: considerado o mais versátil, pois integra DES, ABS e SD, possibilitando o desenvolvimento de modelos híbridos aplicados a redes de saúde e epidemias. Sua flexibilidade é um diferencial, mas exige conhecimento avançado em programação e investimento em licenças (WU; LI; CHU, 2019).
- Vensim e Stella: especializados em Dinâmica de Sistemas, são recomendados para políticas de saúde, análises de longo prazo e projeções epidemiológicas. A vantagem é a clareza conceitual, enquanto a limitação é a falta de detalhamento micro operacional (LARRAIN; GROENE, 2021).
- Matlab/Simulink: amplamente usado em modelagem matemática e simulação estocástica, aplicado a epidemiologia e confiabilidade de equipamentos. Oferece poder computacional elevado e bibliotecas robustas, mas apresenta custo de licença alto e demanda conhecimento técnico avançado (WANG; DEMEULEMEESTER, 2023).
- Python e R: ferramentas de código aberto, cada vez mais utilizadas devido às bibliotecas como SimPy (DES), Mesa (ABS), PySD (SD) e Simmer (R). São flexíveis, gratuitas e permitem integração com *machine learning*, mas requerem esforço significativo em programação e validação (ORDU *et al.*, 2021).

7.3 APLICAÇÕES PRÁTICAS DE SIMULAÇÃO EM SERVIÇOS DE SAÚDE

A literatura evidencia aplicações de simulação de forma ampla e progressivamente mais sofisticada para apoiar decisões clínicas e gerenciais em contextos diversos de saúde. Em processos assistenciais de linha de frente, estudos

combinando simulação e *Lean* mostram reduções consistentes de tempos de espera e eliminação de desperdícios por meio de ajustes de layout, balanceamento de tarefas e realocação de recursos (AHMAD et al., 2021; ALKHER et al., 2019; CREMA; VERBANO, 2019; IMPROTA et al., 2020; TLAPA et al., 2022). Grande parte desses estudos foi conduzida em softwares generalistas de simulação discreta, como Arena e Simul8, que oferecem flexibilidade para modelar fluxos de pacientes e avaliar cenários alternativos de configuração. Simultaneamente, a gestão do acesso recebe especial atenção via problemas de agendamento e combinação paciente–prestador, explorando DES, otimização e regras de decisão para minimizar atrasos, cancelamentos e ociosidade (ALA; CHEN, 2022; CHEN et al., 2019; KUIPER et al., 2023). Nesses casos, o AnyLogic aparece com maior frequência, pois permite integrar DES e simulação baseada em agentes, possibilitando a análise simultânea da eficiência operacional e dos comportamentos emergentes dos pacientes e profissionais.

No suporte à operação, a simulação vem combinada a decisões de inventário e manutenção, reduzindo custos logísticos por meio de simulação, otimização e meta-heurísticas (BUSCHIAZZO; MULA; CAMPUZANO-BOLARIN, 2020; MWANZA; TELUKDARIE; IGUSA, 2023). Nessas aplicações, MATLAB e Python têm sido utilizados como ferramentas de apoio, principalmente para integração com algoritmos de otimização e parametrização de distribuições de probabilidade. Em *home healthcare*, abordagens de otimização e meta-heurísticas reduzem deslocamentos e janelas de atendimento, com ganhos em cobertura e qualidade (BELHOR et al., 2023).

Modelos integrais ou em rede têm sido empregados para avaliar sistemas integrados de saúde, orientar redesenhos de redes de atenção primária e definir capacidade em alianças, frequentemente combinando DES, SD e otimização (GAO; WEN; SONG, 2020; LARRAIN; GROENE, 2021; MITROPOULOS; ADAMIDES; MITROPOULOS, 2023). Em cenários de riscos e choques, a simulação apoia estratégias de desvio de pacientes e de planejamento para desastres e pandemias, gerando cenários de demanda, acessibilidade e ocupação (GROVES-KIRKBY et al., 2023; LIN; LIN; LIN, 2023).

Na perspectiva metodológica, nota-se um direcionamento a simulação-otimização para problemas de alocação, roteamento e reconfiguração de setores,

apontado por revisões de literatura recentes como campo promissor (BELHOR et al., 2023; MWANZA; TELUKDARIE; IGUSA, 2023; ORDU et al., 2021; TEYMOURIFAR, 2024; WANG; DEMEULEMEESTER, 2023). No setor de radiologia, o FlexSim Healthcare tem se mostrado particularmente eficiente, pois dispõe de bibliotecas pré-configuradas para modelar processos de diagnóstico por imagem, permitindo avaliar escalas, gargalos e utilização de equipamentos de forma detalhada (SHAKOOR et al., 2021). Por outro lado, há aplicações focadas na sustentabilidade e gestão verde da cadeia de suprimentos, como redução de resíduos e logística reversa, conectando métricas operacionais e ambientais (CHANG *et al.*, 2019; SRIVASTAVA, 2007). neste mesmo setor, aplicações específicas de DES demonstram identificação de gargalos, cenários de escalas e equipamentos e redução de tempos porta-exame (SHAKOOR *et al.*, 2021).

A literatura também discute valoração e custos de projetos baseados em modelagem e boas práticas de ciência aberta, como compartilhamento de modelos e código, elementos-chave para difusão e impacto (MONKS; HARPER, 2023; SOORAPANTH; ELDABI; YOUNG, 2023; YOUNG *et al.*, 2020). Por fim, estudos sobre análise pós desastres indicam como mudanças de processo apoiadas por modelagem podem fortalecer a segurança do paciente em contextos remotos (FLORIDIS, 2023).

7.4 LIMITAÇÕES E OPORTUNIDADES DA LITERATURA

Apesar dos avanços na literatura sobre simulação aplicada à saúde, muitos estudos concentram-se em hospitais de grande porte ou em sistemas de saúde públicos, deixando em segundo plano clínicas privadas de médio porte, particularmente no contexto brasileiro (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012). Esse cenário é crítico no setor de diagnóstico por imagem, onde o tempo de espera prolongado e a subutilização de equipamentos comprometem a eficiência e a experiência do paciente (SHAKOOR *et al.*, 2021). Além disso, verifica-se escassez de pesquisas voltadas especificamente para exames de ressonância magnética, mesmo sendo um dos procedimentos de maior complexidade e demanda crescente (CAI; JIA, 2019).

Outro ponto crítico refere-se ao uso de dados. Muitos estudos ainda utilizam suposições simplificadas ou distribuições genéricas para parametrizar seus modelos,

sem validação a partir da realidade operacional de clínicas e hospitais (AHMAD et al., 2021; BAHARI; ASADI, 2020). É importante destacar que toda simulação gera cenários artificiais, porém a limitação está em não confrontar os resultados com dados observados em campo, reduzindo a confiabilidade das análises. Neste presente estudo, esse desafio é mitigado por meio da coleta de dados reais para parametrizar as distribuições utilizadas, embora hipóteses adicionais ainda sejam necessárias, como o comportamento do paciente e a disponibilidade da equipe, que não podem ser totalmente capturadas em campo.

Além disso, a literatura mostra que a integração entre simulação e otimização representa um caminho promissor quando associada a heurísticas como algoritmos genéticos, permitindo explorar soluções mais eficientes para alocação de recursos e agendamento (WANG; DEMEULEMEESTER, 2023). Entretanto, ainda há carência de trabalhos que apliquem essa integração em unidades de diagnóstico, restringindo sua aplicação prática.

Por fim, é possível observar a ausência de padronização nos métodos de modelagem de processos ambulatoriais. Isso significa que cada estudo adota técnicas, variáveis e níveis de detalhamento diferentes, alguns focam apenas no fluxo de pacientes, outros incluem recursos humanos, tempos de setup ou logística de resultados, o que dificulta a comparação entre pesquisas e a replicação de boas práticas em diferentes contextos (MITROPOULOS; ADAMIDES; MITROPOULOS, 2023; WU; LI; CHU, 2019). Desta forma, torna-se fundamental a adoção de modelos que explicitem as variáveis utilizadas, as distribuições estatísticas aplicadas e as hipóteses assumidas, de modo a facilitar futuras análises comparativas e promover maior robustez na construção de evidências para a gestão em saúde (AHMAD et al., 2021; BAHARI; ASADI, 2020; MITROPOULOS; ADAMIDES; MITROPOULOS, 2023; WANG; DEMEULEMEESTER, 2023; WU; LI; CHU, 2019).

8 METODOLOGIA

Este capítulo apresenta o caminho metodológico adotado para o desenvolvimento da pesquisa, descrevendo as etapas de caracterização do estudo, coleta e parametrização dos dados, construção do modelo de simulação e análise dos cenários propostos.

8.1 CARACTERIZAÇÃO DA PESQUISA

Esta pesquisa é classificada como aplicada, uma vez que busca oferecer soluções práticas a um problema real enfrentado em uma clínica de diagnóstico por imagem localizada no interior de Pernambuco. Quanto à abordagem, caracteriza-se como quantitativa, pois trabalha com dados numéricos coletados diretamente do processo assistencial, analisados estatisticamente e transformados em distribuições de probabilidade para posterior simulação (GIL, 2017; SEVERINO, 2017)


No que se refere aos objetivos, apresenta natureza exploratória e descritiva. É exploratória pois procura identificar variáveis críticas que influenciam o tempo de espera dos pacientes e a utilização dos recursos, em um contexto ainda pouco investigado em clínicas privadas de médio porte. Ao mesmo tempo, é descritiva, pois busca detalhar o funcionamento do processo atual e comparar cenários alternativos simulados, sem alterar diretamente a rotina operacional da clínica (GIL, 2017; SEVERINO, 2017; VERGARA, 2016).

O método de pesquisa adotado foi o estudo de caso, apropriado para analisar em profundidade uma realidade específica e contextualizada, integrando observação direta, análise de dados e modelagem computacional (YIN, 2014). Essa escolha é reforçada por estudos que aplicam metodologias semelhantes em serviços de saúde para compreender fluxos assistenciais e propor melhorias (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; SHAKOOR *et al.*, 2021).

Definida a natureza metodológica desta pesquisa como aplicada, quantitativa e estruturada em estudo de caso, torna-se necessário apresentar o contexto em que o problema investigado se insere. A caracterização da pesquisa estabelece o enquadramento científico que justifica a escolha da simulação computacional como estratégia analítica. No entanto, é a descrição do funcionamento real da clínica de

diagnóstico por imagem que fundamenta a construção do modelo (Figura 21). Assim, a seção seguinte apresenta a caracterização do problema, detalhando os recursos disponíveis, o fluxo de pacientes e os gargalos que motivaram este estudo.

Figura 21 - Metodologia do estudo.



Fonte: Autor (2025).

8.2 CARACTERIZAÇÃO DO PROBLEMA

A clínica de diagnóstico por imagem analisada neste estudo está localizada em uma cidade de médio a grande porte no interior de Pernambuco e encontra-se em funcionamento há mais de 35 anos, contando atualmente com duas unidades em operação. Atua sob demanda crescente, oferecendo exames de Ressonância Magnética (RM) em regime contínuo, com funcionamento em turnos que garantem atendimento diário. No fluxo de RM, conta com duas máquinas de RM, duas recepcionistas, uma enfermeira para triagem e técnicas de radiologia responsáveis pelo setup e operação dos equipamentos.

Apesar de estruturado, o processo apresenta desafios relacionados ao tempo de espera dos pacientes e à utilização de recursos. Entre os principais fatores que comprometem a eficiência estão: (i) a variabilidade da demanda de pacientes, que

gera períodos de superlotação intercalados com momentos de ociosidade; (ii) o tempo de preparação (setup) das máquinas, que varia de acordo com o tipo de exame e reduz a cadência do atendimento; e (iii) a disponibilidade da equipe, frequentemente sobrecarregada em horários de pico. Esses fatores afetam diretamente indicadores como tempo médio de espera, taxa de ocupação de recursos e tempo total de permanência dos pacientes no sistema (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; SHAKOOR *et al.*, 2021), comprometendo não apenas a produtividade da clínica, mas também a experiência do paciente, uma vez que longos tempos de espera prejudicam a percepção de qualidade do atendimento (PORTER, 2010). Diante desse cenário, é essencial avaliar alternativas de melhoria que apoiem a tomada de decisão gerencial.

Considerando os desafios identificados no processo de atendimento da clínica, é essencial compreender quantitativamente como cada etapa contribui para os gargalos observados. Para isso, foi necessário realizar a coleta sistemática de dados operacionais e a sua parametrização em distribuições estatísticas representativas. Essa etapa possibilitou transformar observações empíricas em insumos confiáveis para a construção do modelo de simulação, garantindo que os cenários testados reflitam com maior precisão a realidade do sistema estudado.

8.3 ORIGEM E PARAMETRIZAÇÃO DOS DADOS

Os dados utilizados nesta pesquisa têm origem primária e foram parametrizados conforme descrito:

- Dados primários: coletados foram diretamente na clínica no mês de maio, com base no histórico de atendimento dos três meses anteriores para definir a quantidade necessária de observações. Os dados incluíram: tempos de recepção, triagem, preparação da máquina de ressonância magnética e duração dos exames.
- A parametrização foi realizada com auxílio do Python, por meio de bibliotecas estatísticas como SciPy. Esse recurso permitiu ajustar distribuições de probabilidade aos dados coletados, aplicando testes de aderência de Kolmogorov-Smirnov para representatividade estatística das variáveis (AHMAD *et al.*, 2021; BAHARI; ASADI, 2020). Dessa forma, o modelo foi

alimentado com dados validados, mitigando a limitação de estudos que utilizam apenas suposições ou distribuições genéricas (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).

8.4 SOFTWARE ESCOLHIDO

A modelagem foi implementada no FlexSim Healthcare, uma extensão do FlexSim direcionada ao setor da saúde, na versão acadêmica. A escolha desse software se justifica por três aspectos principais:

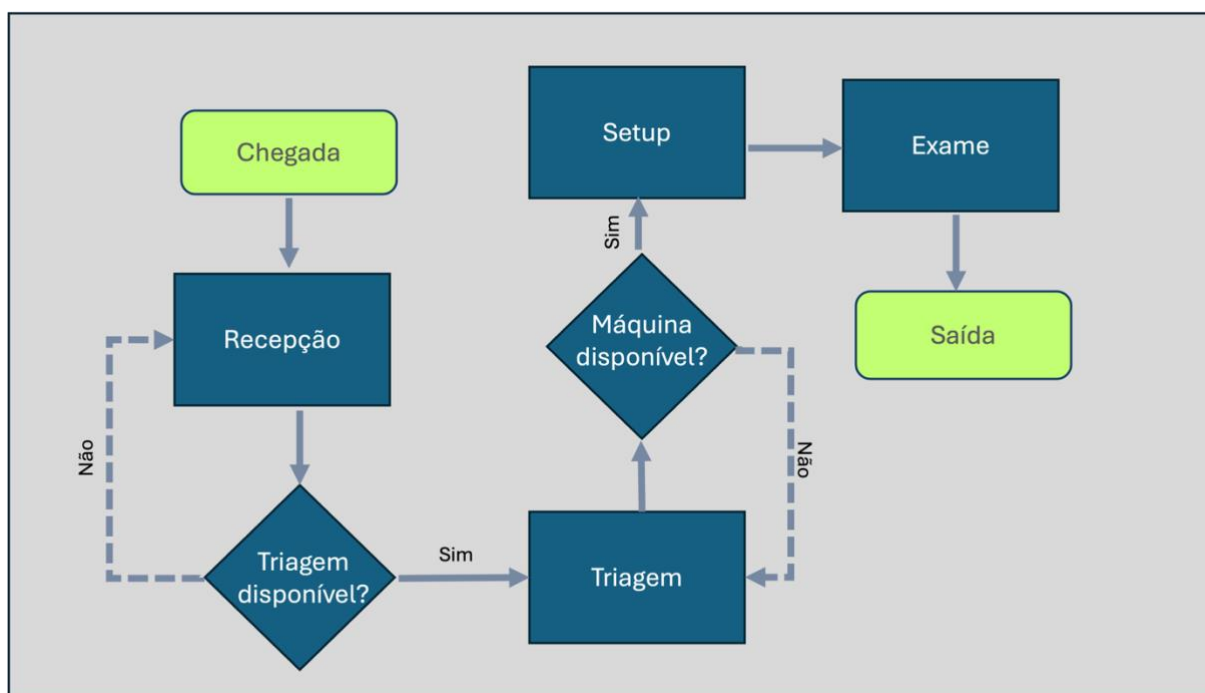
- Bibliotecas específicas para saúde: inclui objetos pré-configurados, como triagem, recepção e leitos, o que agiliza a modelagem e aumenta a precisão (SHAKOOR *et al.*, 2021).
- Visualização em 3D: facilita a comunicação dos resultados a gestores e profissionais sem conhecimento técnico aprofundado (CAI; JIA, 2019).
- Reconhecimento acadêmico: o *FlexSim Healthcare* tem sido utilizado em pesquisas recentes, confirmando sua adequação para cenários hospitalares e de diagnóstico (WANG; DEMEULEMEESTER, 2023).

9 APLICAÇÃO NA ÁREA DE SAÚDE

9.1 CENÁRIO ATUAL

O desenvolvimento desta pesquisa seguiu uma sequência estruturada de etapas que permitiu construir, validar e analisar o modelo de simulação. Inicialmente, realizou-se o mapeamento do processo assistencial, no qual foram identificadas todas as etapas do fluxo do paciente como mostra a Figura 22. Esse mapeamento foi desenvolvido em conjunto com a equipe da clínica e representado em fluxogramas, de modo a capturar a lógica operacional real (AHMAD et al., 2021).

Figura 22 - Mapa do fluxo assistencial.



Fonte: Autor (2025)

A etapa seguinte consistiu na coleta e tratamento dos dados, conduzida por meio de observação direta do funcionamento da clínica e análise de registros internos. Foram coletadas 135 observações válidas, distribuídas entre os tempos *setup* das máquinas e duração dos exames, considerando o período de um mês. A definição do número de observações baseou-se no histórico de atendimentos dos três meses anteriores, de modo a garantir representatividade estatística das variáveis analisadas.

Os tempos coletados foram organizados em planilhas para análise estatística, de forma a garantir consistência e comparabilidade entre variáveis relevantes, conforme recomendam estudos de simulação aplicados a serviços de saúde (BAHARI; ASADI, 2020).


Atualmente, os exames são agendados de forma aleatória, sem critérios específicos relacionados ao tipo de exame, ao tempo de duração ou ao preparo necessário para sua realização. Os horários disponíveis na agenda são simplesmente preenchidos conforme a demanda, de maneira sequencial, à medida que surgem vagas, independentemente das características técnicas do exame solicitado.

Para representar adequadamente a heterogeneidade operacional do processo, adotou-se uma estratificação por tipo de exame (Figura 23): abdome superior, abdome total, cervical, crânio, crânio (com contraste), joelho, lombar, membro inferior, ombro e próstata. Essa classificação foi utilizada como fator de agrupamento na etapa de ajuste estatístico, de modo que as amostras de tempo de *setup* e tempo de realização correspondentes a cada estrato fossem tratadas separadamente, como mostram as tabelas 2 e 3. A parametrização foi realizada com auxílio do Python, utilizando bibliotecas estatísticas como SciPy, que permitiram ajustar distribuições de probabilidade aos dados coletados e aplicar testes de aderência de Kolmogorov–Smirnov para avaliar sua representatividade. A seleção das distribuições candidatas foi fundamentada tanto na literatura de simulação aplicada à saúde quanto em critérios estatísticos de aderência aos dados observados.

Estudos que modelam fluxos assistenciais e tempos de atendimento em serviços hospitalares e de diagnóstico por imagem indicam a utilização recorrente das distribuições Normal, Exponencial, Lognormal e Weibull para representar tempos operacionais e processos estocásticos (MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012; ROY; SHAH; GAJJAR, 2021; SHAKOOR *et al.*, 2021). Essas distribuições foram selecionadas por sua capacidade de modelar diferentes comportamentos dos dados, incluindo simetria, assimetria positiva e taxas de ocorrência constantes ou variáveis ao longo do tempo. As distribuições que não apresentaram aderência estatisticamente satisfatória foram descartadas. Assim, a escolha final para cada variável foi baseada no melhor ajuste estatístico aliado à coerência teórica com o fenômeno modelado. Para a distribuição Normal, os parâmetros estimados correspondem à média (μ) e ao

desvio-padrão (σ), refletindo a tendência central e a dispersão dos tempos observados. Já na distribuição Exponencial, o parâmetro λ (lambda) representa a taxa de ocorrência dos eventos, sendo o inverso do tempo médio entre eles, além de um parâmetro de localização. Na distribuição Lognormal, os parâmetros indicam a média e o desvio-padrão do logaritmo dos tempos, adequada para fenômenos assimétricos e positivos, além de um parâmetro de localização. A distribuição Weibull é descrita pelos parâmetros de forma (β) e escala (α), além de um parâmetro de localização. A Tabela 10 apresenta as distribuições ajustadas e seus respectivos parâmetros para os tempos de setup por tipo de exame, enquanto a Tabela 11 mostra os resultados equivalentes para os tempos de realização dos exames.

Figura 23 - Frequência de observações por tipo de exame.



Fonte: Autor (2025)

Os parâmetros estimados por estrato foram então incorporados ao modelo no *FlexSim Healthcare*, assegurando que a simulação refletisse não apenas o fluxo agregado, mas também as diferenças estruturais entre protocolos e complexidades de exame, condição necessária para avaliar impactos sobre filas, utilização de recursos e tempos de permanência no sistema.

Tabela 10 - Frequência e distribuição de tempo de setup.

Tipo de Exame	Frequência	Distribuição Set up	Parâmetros		
Abdome Superior	5	Normal	31,1667	3,8042	
Abdome Total	3	Normal	52,8	10,6094	
Cervical	19	Normal	20,58	6,8734	
Crânio	28	Exponencial	1	2,89	
Crânio (c/contraste)	8	Exponencial	16	6,625	
Joelho	14	Exponencial	7	5,8571	
Lombar	38	Lognormal	0,7684	5,8548	5,7672
Membro inferior	6	Exponencial	9	14	
Ombro	9	Weibull	0,6782	9	8,393
Próstata	5	Weibull	0,5561	24	15,6797

Fonte: Autor (2025)

Tabela 11 - Distribuição de tempo de realização de exame.

Tipo de Exame	Distribuição tempo de exame	Parâmetros		
Abdome Superior	Exponencial	4	0,667	0,667
Abdome Total	Exponencial	2	2,6	
Cervical	Normal	3,5	1,1354	
Crânio	Lognormal	9,534	1	0,1757
Crânio (com contraste)	Lognormal	12,3344	1	0,0307
Joelho	Weibull	0,855	2	2,0761
Lombar	Lognormal	0,3917	-0,3474	3,3391
Membro inferior	Exponencial	3	1,3333	

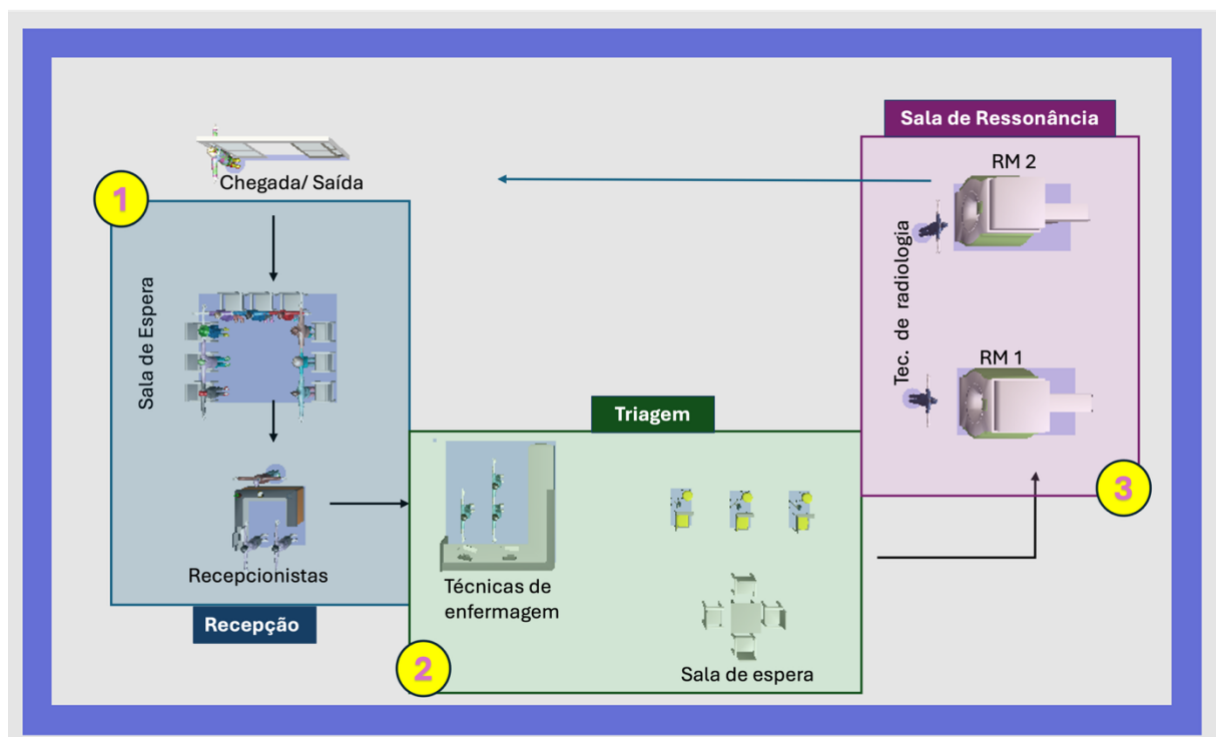
Ombro	Normal	4,5556	0,8315
Próstata	Normal	5,2	0,7483

Fonte: autor (2025)

9.1.1 Modelagem no Flexsim Healthcare

Para dar suporte à simulação e garantir que o modelo represente o funcionamento da clínica, foi elaborado no *FlexSim Healthcare* um diagrama operacional que incorpora todas as etapas do trajeto do paciente dentro do ambiente assistencial. Antes de inserir os dados e rodar cenários, foi necessário estruturar o fluxo de atendimento com as entidades lógicas interligadas, refletindo as restrições de recursos e as regras de espera entre etapas. Na Figura 24 é apresentada a sequência dos processos, da chegada do paciente à saída, que serve de base para parametrização, execução de cenários e análise dos resultados no ambiente de simulação.

Figura 24 - Fluxo de execução de exame no Flexsim.



Fonte: Autor (2025)

O modelo de simulação foi construído a partir do fluxo real percorrido pelo paciente dentro da clínica de diagnóstico por imagem:


- 4) O processo inicia-se na recepção, onde duas recepcionistas registram a chegada dos pacientes. Quando ambas estão ocupadas, o paciente aguarda em uma fila de cadeiras destinadas à recepção, configurada no FlexSim como recurso de espera. Essa etapa reflete a primeira interação do paciente com o sistema e já evidencia possíveis gargalos em horários de maior demanda.
- 5) Após o registro, o paciente é encaminhado à triagem, conduzida por duas técnicas de enfermagem responsáveis pela aplicação de um questionário sobre as condições clínicas e pelo preparo inicial. No modelo, foi considerada a possibilidade de espera: quando todas as enfermeiras estão ocupadas, o paciente permanece aguardando na área de recepção. Assim, é possível captar a dependência entre setores e a propagação de atrasos.
- 6) Concluída a triagem, o paciente segue para a sala de exames de ressonância magnética, onde estão disponíveis duas máquinas. Caso ambas estejam em uso, os pacientes permanecem em espera na sala de triagem. Antes de cada exame, ocorre um setup técnico, representado no modelo computacional como um processo adicional necessário para o posicionamento da bobina de acordo com o tipo de exame solicitado. Desta forma, pode-se representar a variabilidade operacional, uma vez que diferentes exames demandam tempos distintos de preparação. Por fim, após a realização do exame, o paciente retorna à triagem para finalizar o processo e deixar o sistema.

O modelo, portanto, avalia não apenas os tempos médios de espera em cada estação, mas também a utilização dos recursos, a ocorrência de gargalos e o impacto dos *setups* no desempenho do sistema.

Conforme a parametrização e o fluxo operacional previamente descritos, executou-se o modelo no *software* para um horizonte de cinco dias, obtendo-se um tempo médio de permanência no sistema de 139 minutos por paciente (Figura 25) e *throughput* total de 161 pacientes no período (aproximadamente 32,2 pacientes/dia;


com duas máquinas de RM, aproximadamente 16,1 exames/máquina/dia), como mostra a Figura 26.

Figura 25 - Tempo de permanência no sistema em minutos.



Fonte: Autor (2025)

Figura 26 - Quantidade de pessoas atendidas em 5 dias.



Fonte: Autor (2025)

A análise dos estados médios de utilização dos recursos humanos (*Avg State*), apresentada na Figura 27, apresenta diferenças na distribuição das atividades entre os profissionais envolvidos no processo de RM. No modelo parametrizado, o FlexSim Healthcare classifica o tempo dos recursos em categorias operacionais, *in transit*, *providing care*, *performing task* e *idle*, de acordo com a natureza das atividades executadas. A interpretação desses estados depende diretamente da modelagem do fluxo de trabalho. No caso das técnicas de radiologia, observou-se que 76,07% do de utilização total, maior parte do tempo foi categorizado como *Providing Care*. Embora, conceitualmente, se possa associar esse estado apenas a ações assistenciais, no ambiente do FlexSim foram incluídas todas as atividades que envolvem interação direta com o paciente, tais como acomodação na mesa, preparação das bobinas, orientações durante o exame, retirada de objetos metálicos e assistência na entrada e saída da sala. Como o processo de setup foi modelado como uma etapa que ocorre

com a presença do paciente e exige sua preparação física, o *software* alocou a maior parte desse período em *providing care*.

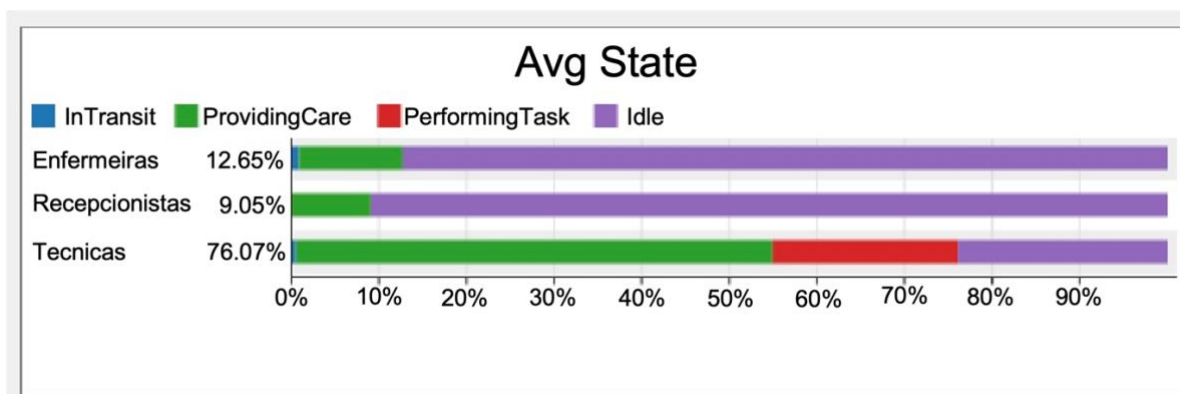
De maneira complementar, 21,11% do tempo das técnicas foi registrado como *performing task*, correspondendo às atividades técnicas e sem contato humano direto, como configuração de parâmetros do equipamento, ajustes internos e tarefas executadas pelo *task executer* fora da sala de exame. Esse padrão de distribuição é característico de modelos em que o *setup* envolve a participação no cuidado ao paciente, reforçando que a categorização depende da lógica interna do simulador e não exclusivamente da descrição clínica das tarefas.

Para as enfermeiras, registrou-se 12,65% do tempo em *providing care*, refletindo sua atuação concentrada nas fases iniciais do fluxo, acolhimento, triagem e orientações prévias, com longos intervalos de ociosidade entre atendimentos, dada a baixa variabilidade e curta duração das suas tarefas.

Para as recepcionistas, observou-se 9,05% do tempo em *providing care*, valor condizente com um processo de recepção padronizado, rápido e não contínuo dentro do fluxo específico da ressonância magnética. A predominância do estado *idle* não deve ser interpretada como ociosidade real, mas sim como um artefato da modelagem focada exclusivamente no processo de RM. Na operação real da clínica, as recepcionistas desempenham um conjunto de atividades não modeladas no simulador, incluindo recepção e cadastro de pacientes de outros processos, como tomografia computadorizada e ultrassonografia, agendamento de exames, prestam o serviço de informações gerais e suporte administrativo. Assim, a baixa utilização dentro do modelo reflete apenas o escopo restrito da simulação.

Assim, os resultados do *avg state* demonstram que a maior restrição operacional do sistema aponta as técnicas de radiologia, cuja elevada proporção de tempo em *providing care* e *performing task* indica dependência da capacidade instalada das salas de RM e alto envolvimento em atividades simultaneamente técnicas e assistenciais. As demais categorias profissionais apresentam folgas operacionais significativas, o que confirma que os gargalos do sistema estão concentrados na etapa de exame e *setup*, e não nas fases de triagem ou recepção.

Figura 27 - Média de tempo de cada setor realizando atividades.



Fonte: Autor (2025)

9.2 CENÁRIO 2: REORGANIZAÇÃO DA SEQUÊNCIA E LÓGICA DE AGENDAMENTO

Com base na análise do cenário atual, no qual foi observado um tempo médio de permanência no sistema de 139 minutos, 161 pacientes atendidos em cinco dias de simulação e alta utilização das técnicas em radiologia, foi trabalhado um novo cenário com o objetivo avaliar o impacto de intervenções exclusivamente operacionais, sem aumento de recursos físicos ou humanos, sobre o desempenho do processo de ressonância magnética. As mudanças propostas foram fundamentadas nos dados levantados na clínica, nos princípios de gerenciamento de filas, teoria das operações e boas práticas de gestão de serviços de saúde. O foco desse cenário foi reorganizar o fluxo por meio da padronização, sequenciamento inteligente e inserção de buffers operacionais, visando reduzir gargalos, tempos de espera e variabilidade.

9.2.1 Construção do novo fluxo

9.2.1.1 Agrupamento de exames por similaridade técnica

A primeira lógica adotada foi o agrupamento dos exames em blocos homogêneos, organizados segundo suas características técnicas, protocolos de aquisição e requisitos de configuração. Foram definidos quatro agrupamentos principais: (i) os exames de coluna (cervical, torácica e lombar), que utilizam as bobinas integradas da mesa e apresentam potencial de setup mínimo; (ii) o exame de

crânio; (iii) os exames musculoesqueléticos, como ombro e joelho, que requerem bobinas de superfície e maior intervenção manual; e (iv) os exames de abdome e pelve. Essa organização reduz trocas de bobina e reconfigurações sucessivas, favorecendo um fluxo mais estável e diminuindo a variabilidade operacional observada no cenário atual. As modificações fundamentaram-se em dois princípios operacionais:

- Redução da variabilidade interna do processo, evitando alternâncias entre sequências de procedimentos incompatíveis entre si.
- Diminuição do número de *setups*, uma vez que transições frequentes entre tipos de exame representam uma das maiores causas de tempo improdutivo no processo de imagem.

Esse agrupamento permitiu a criação de um fluxo mais previsível e contínuo, alinhando-se ao conceito de *single-piece flow* aplicado de maneira adaptada ao contexto de saúde.

9.2.2 Alternância estratégica entre exames curtos e longos

Após a definição dos blocos, os exames foram distribuídos ao longo do turno de maneira a equilibrar a carga sobre as máquinas e equipes. Assim, exames de menor duração, cuja média variou entre 25 e 30 minutos segundo os dados coletados, foram intercalados com exames mais longos, cuja duração média ultrapassou 35 minutos. Essa decisão foi baseada no entendimento de que:

- Em turnos com muitos exames prolongados consecutivos, há maior probabilidade de formação de filas e atrasos acumulados.
- Em turnos com muitos exames curtos consecutivos, a equipe pode sofrer sobrecarga por setups repetidos e ritmo acelerado.

A alternância introduzida no cenário buscava reduzir o efeito de pico de demanda, mantendo o sistema em equilíbrio e evitando o acúmulo de pacientes na fila de exame, particularmente nos períodos críticos de atendimento.

9.2.3 Estruturação de intervalos operacionais entre blocos

Entre cada bloco de exames, foram introduzidas pausas calculadas de 10 minutos, que funcionam como *buffers*, elementos que são recomendados em sistemas de serviços complexos. Essas pausas tiveram como finalidades:


- Absorver desvios naturais dos tempos de exame e *setup*, evitando atrasos sucessivos.
- Permitir ajustes na máquina, reposicionamento da equipe ou reconfiguração pontual sem impactar o bloco seguinte.
- Reduzir a pressão operacional contínua, permitindo maior constância produtiva ao longo do dia.

A utilização de *buffers* é apresentada na literatura de simulação em saúde como uma ferramenta eficaz para controlar a variabilidade e reduzir tempos de espera em ambientes com alta dependência tecnológica (DATTA; UPADHYAY; JAIDEEP, 2012; MIELCZAREK; UZIAŁKO-MYDLIKOWSKA, 2012).

A aplicação desse conjunto de princípios demonstrou, de acordo com a simulação computacional, impactos positivos no desempenho do sistema. Os resultados sintetizam como a reorganização do fluxo contribuiu para um processo mais estável, menos sujeito a variações e mais produtivo. Os principais efeitos observados foram a redução do tempo de permanência no sistema de 139 para aproximadamente 119 minutos (Figura 28), uma experiência mais eficiente para o paciente, e o aumento da capacidade produtiva, de 161 para 178 pacientes em cinco dias, sem alteração de recursos (Figura 29). De forma complementar, observaram-se:


- Redução de aproximadamente 23% no tempo médio de fila, devido à alternância entre exames curtos e longos e ao amortecimento proporcionado pelos buffers;
- Redução da carga operacional sobre as técnicas de radiologia (Figura 30), caiu para 68.90% devido à menor necessidade de ajustes técnicos e reconfigurações frequentes do equipamento, contribuindo para um ritmo de trabalho mais equilibrado.

Figura 28 - Tempo de permanência no sistema no cenário 2.




Fonte: Autor (2025)

Figura 29 - Quantidade de pessoas atendidas no cenário 2.



Fonte: Autor (2025)

Figura 30 - Média de tempo de cada setor realizando atividades no cenário 2.



Fonte: Autor (2025)

Comparando a Figura 27 e a Figura 30 é possível compreender de forma mais clara como a reorganização da sequência de exames e a redução das transições desnecessárias entre protocolos tornaram o trabalho no setor de RM mais estável e previsível. Entre as técnicas de radiologia, nota-se uma redução proporcional do tempo em *providing care*, ainda que a duração dos exames tenha permanecido a mesma. Essa mudança não significa diminuição do cuidado ou da presença junto ao


paciente, mas sim um processo mais fluido, com menos interrupções e retrabalhos ao longo do exame. É importante destacar que o tempo de *setup* está registrado no estado *performing task*, contudo, quando o número de *setups* diminui, o impacto é sentido também no *providing care*. Com menos trocas de bobinas, menos ajustes inesperados e menos reinícios de posicionamento, a técnica consegue acompanhar o paciente de maneira mais contínua e sem tantas intervenções corretivas.

9.3 CENÁRIO 3: AMPLIAÇÃO DA CAPACIDADE TECNOLÓGICA

O terceiro cenário proposto teve como objetivo avaliar o impacto da expansão da capacidade instalada na etapa de exame, por meio da adição de uma terceira máquina de RM e da incorporação de um terceiro técnico de radiologia responsável pela sua operação. Todos os demais parâmetros operacionais, como tempos de *setup*, duração dos exames, regras de agendamento, lógica de fluxo e número de pacientes agendados por dia, foram mantidos idênticos aos do cenário atual, permitindo isolar o efeito da nova capacidade produtiva sobre o desempenho do sistema. Do ponto de vista da lógica de modelagem, a etapa de exame passou a operar como um conjunto de três recursos paralelos (RM1, RM2 e RM3) alimentados pela mesma fila de pacientes, sem escalonamento adicional ou alteração da política de prioridade.

A simulação realizada no *software* evidenciou mudanças nos principais indicadores operacionais. Primeiramente, como esperado, observou-se redução expressiva no tempo médio de permanência do paciente no sistema, que caiu de 139 minutos (cenário atual) e 119 minutos (cenário 2) para 74,67 minutos no cenário 3 (Figura 31). Essa redução decorre da eliminação quase completa das filas nas salas de ressonância, uma vez que a capacidade instalada passou a exceder amplamente a demanda simulada. A presença de três máquinas capazes de absorver o mesmo perfil de exames distribuiu a carga de forma mais homogênea, minimizando tempos de espera e ampliando a fluidez geral do processo.


Figura 31 - Tempo de permanência no sistema no cenário 3.



Fonte: Autor (2025)

Outro efeito significativo foi o aumento do throughput semanal. Mantendo a lógica de agendamento aleatório e os mesmos parâmetros da agenda base, o sistema foi capaz de concluir 227 atendimentos em cinco dias (Figura 32), valor substancialmente superior ao observado nos cenários anteriores. Esse incremento reflete a capacidade adicional instalada, que permitiu que os pacientes entrassem e saíssem do sistema de forma mais rápida, liberando vagas para novos atendimentos sem que o fluxo sofresse congestionamentos.

Figura 32 - Quantidade de pessoas atendidas no cenário 3.




Fonte: Autor (2025)

A análise da utilização dos recursos, *avg state* (Figura 33), confirma essa tendência de melhor distribuição operacional. A utilização média dos técnicos de radiologia caiu para 54,74%, valor inferior ao observado nos cenários anteriores. Essa redução pelo fato que ao adicionar uma terceira máquina e um novo técnico, o sistema passa a operar com capacidade ociosa estrutural, permitindo que a demanda seja absorvida de forma distribuída entre os três equipamentos. Assim, o tempo dedicado

às atividades de *performing task* diminui proporcionalmente, enquanto o estado *idle* passa a representar parcela significativa da jornada, um indicativo de que nesse cenário, o equipamento deixa de ser o gargalo do processo.

Figura 33 - Média de tempo de cada setor realizando atividades no cenário 3.



Fonte: Autor (2025)


Comportamento semelhante foi observado entre enfermeiras e recepcionistas. Embora seus tempos no estado *providing Care* tenham aumentado, esses valores permanecem dentro de faixas inferiores ao limite de saturação, mostrando que a adição da nova máquina não provocou sobrecarga em setores adjacentes. Isso ocorre porque a redução do tempo de permanência dos pacientes evita acúmulo simultâneo de atendimentos, preservando a estabilidade do fluxo.

9.4 CENÁRIO 4: ANÁLISE INTEGRADA DE EXPANSÃO ESTRUTURAL E OTIMIZAÇÃO OPERACIONAL

O cenário 4 foi desenvolvido com o objetivo de avaliar o desempenho máximo potencial do sistema combinando as duas estratégias investigadas nos cenários anteriores: (i) a reorganização do fluxo assistencial por meio do agrupamento de exames e estruturação de intervalos operacionais entre bloco e (ii) a ampliação da capacidade instalada com a inclusão de uma terceira máquina de ressonância magnética e a contratação de um terceiro técnico de radiologia. A simulação foi conduzida no FlexSim utilizando os mesmos parâmetros e distribuições do cenário base, permitindo isolar o efeito exclusivo dessas intervenções estruturais e operacionais.

Os resultados indicaram que esta combinação produziu o melhor desempenho global entre todos os cenários analisados. O *throughput* semanal atingiu 280 pacientes (Figura 34), valor 42,5% superior ao observado no cenário atual e ainda 18,92% maior do que o obtido no cenário 3. Este aumento resultou da eliminação quase completa do gargalo previamente localizado na sala de exame, agora suportada por três máquinas operando em fluxo equilibrado.


Figura 34 - Quantidade de pessoas atendidas no cenário 4.



Fonte: Autor (2025)

Simultaneamente, nota-se uma redução no tempo médio de permanência do paciente no sistema, que caiu para 50 minutos (Figura 35). Essa diminuição refletiu a estabilização do processo, a menor formação de filas na etapa de exame e a maior fluidez entre triagem, preparação e realização do procedimento.

Figura 35 - Tempo de permanência no sistema no cenário 4.




Fonte: Autor (2025)

Enquanto no cenário atual os técnicos permaneciam 76,07% ocupados, no cenário 4 a utilização caiu para aproximadamente 40% no estado de *performing task*, 23% em *providing care*. Essa distribuição equilibrada indica que, embora a capacidade produtiva tenha aumentado e a proporção relativa de *providing care* tenha diminuído em relação ao cenário atual, a utilização efetiva aumentou, pois, a capacidade adicional favoreceu um fluxo contínuo e evitou gargalos gerados por esperas internas

no processo. Isso explica o aumento da utilização total das técnicas de 54,74% no cenário 3 para 63,45% no cenário 4 (Figura 36). Esse resultado não indica maior sobrecarga, mas sim uma operação mais estável, com menor variabilidade, menos transições entre estados que não geram valor ao processo e melhor sincronização entre o fluxo de pacientes e os recursos disponíveis.

Figura 36 - Média de tempo de cada setor realizando atividades no cenário 4.



Fonte: Autor (2025)

Para as enfermeiras, foram observados 11,92% em *providing care*, porcentagem semelhante aos cenários anteriores, coerente com o papel concentrado em etapas iniciais do fluxo, cuja duração é curta e pouco variável. A predominância do estado *idle* é esperada, pois suas atividades são restritas à triagem e orientações preliminares, não sendo influenciadas diretamente pela inclusão de uma nova máquina. As recepcionistas registraram 9,11% em *providing care*, proporção semelhante aos cenários anteriores. Importante destacar que a baixa utilização no modelo não representa subutilização real, mas sim um reflexo da modelagem focada exclusivamente no processo de RM. Com base nesses indicadores, o cenário 4 representou o estado de melhor desempenho observado em toda a investigação. A combinação de um fluxo mais previsível com o aumento de capacidade estrutural permitiu elevar significativamente o *throughput*, reduzir o tempo de permanência no sistema e distribuir a carga de trabalho de forma mais sustentável entre os profissionais, sem transferir o gargalo para outras etapas do processo. Em síntese, o cenário demonstrou que intervenções simultaneamente técnicas e operacionais podem produzir efeitos sinérgicos na performance global do serviço de ressonância magnética.

9.5 ANÁLISE FINANCEIRA INTEGRADA À SIMULAÇÃO

A análise financeira foi conduzida de forma integrada aos resultados da simulação computacional, com o objetivo de avaliar economicamente e comparar os cenários operacionais modificados, baseados na reorganização dos recursos existentes e aqueles que envolvem a ampliação da capacidade tecnológica por meio da aquisição de uma nova máquina de ressonância magnética.

Assim, buscou-se diferenciar os ganhos econômicos decorrentes de melhorias operacionais daqueles associados a investimentos estruturais, assegurando coerência entre o comportamento do sistema observado na simulação, a utilização dos recursos e os resultados financeiros. As estimativas de custos e receitas foram realizadas com base no *throughput* obtido em cada cenário, considerando explicitamente os recursos humanos, os custos operacionais e a base de ativos envolvidos.

9.5.1 Estrutura de custos considerados

A estrutura de custos adotada engloba (a) recursos humanos, (b) custos de manutenção e (c) reposição de peças e depreciação dos equipamentos de ressonância magnética. Esses custos foram tratados de forma semelhante entre os cenários analisados, variando em função da configuração operacional simulada, de forma a garantir comparabilidade econômica entre as alternativas analisadas.

9.5.1.1 Custos com recursos humanos

Foram considerados os custos mensais dos profissionais diretamente envolvidos no fluxo de atendimento de RM, obtidos a partir de informações disponibilizadas pela própria empresa estudada, com base em suas políticas internas de remuneração vigentes no período da coleta de dados. Esses valores correspondem aos salários brutos praticados pela clínica para as funções de recepção, enfermagem e técnicos em radiologia, incluindo os adicionais legais aplicáveis, como o adicional de insalubridade no caso dos técnicos de radiologia. como apresentados Tabela 12. No cenário com ampliação tecnológica, foi incorporado um técnico adicional de radiologia para operação da terceira máquina de RM.

Tabela 12 - Custos mensais com recursos humanos no cenário com três RM

Cargo	Quantidade	Salário Mensal Individual (R\$)	Custo mensal total (R\$)
Recepcionista	2	2.041,41	4.082,82
Técnica de enfermagem	2	2.932,90	5.865,80
Técnico em radiologia	3	3.990,00	11.970,00
Total mensal	—	—	21.918,62

Fonte: Autor (2025)

Nos cenários com duas máquinas, o custo mensal com recursos humanos é inferior, uma vez que não há a necessidade do terceiro técnico em radiologia, permanecendo inalterados os demais cargos.

9.5.1.2 Custos de manutenção e reposição de peças

Os valores referentes aos custos de manutenção preventiva, corretiva e reposição de peças das máquinas de RM foram obtidos a partir de informações disponibilizadas pela empresa estudada, com base nos contratos firmados junto ao fabricante dos equipamentos. Esses contratos estabelecem os valores de R\$360.834,79 anualmente, o que equivale a R\$ 30.069,57 mensais de manutenção e cobertura técnica aplicáveis a cada máquina em operação. Dessa forma, o custo total de manutenção varia de acordo com o número de máquinas em operação em cada cenário.

No cenário de ampliação tecnológica, adotou-se a hipótese contratual de garantia integral de um ano para a nova máquina. Assim, durante os primeiros 12 meses de operação, os custos de manutenção incidem apenas sobre as máquinas já existentes. A partir do segundo ano, com o término da garantia, os custos passam a refletir a operação de todas as máquinas disponíveis.

9.5.1.3 Depreciação dos equipamentos

A depreciação dos equipamentos de RM foi considerada em todos os cenários, proporcionalmente ao número de máquinas em operação, uma vez que o objetivo da análise financeira é comparar economicamente configurações distintas do sistema simulado.

Foi adotado o método de depreciação linear, considerando uma vida útil econômica de 10 anos e valor de aquisição de R\$ 2.000.000,00 por equipamento. A Tabela 13 apresenta os parâmetros e o cálculo da depreciação unitária adotada neste estudo.

Tabela 13 - Parâmetros e cálculo da depreciação unitária das máquinas de RM

Parâmetro	Descrição	Valor
Valor de aquisição do equipamento	Custo por máquina de RM	R\$ 2.000.000,00
Vida útil econômica	Horizonte considerado	10 anos
Método de depreciação	Linear	—
Depreciação anual por máquina	$2.000.000 / 10$	R\$ 200.000,00
Depreciação mensal por máquina	$200.000 / 12$	R\$ 16.666,67

Fonte: Autor (2025)

A depreciação mensal unitária resultante é de R\$ 16.666,67 por máquina. A depreciação total considerada em cada cenário corresponde à soma da depreciação unitária de todas as máquinas em operação. Assim, nos cenários atual e reorganizado, que operam com duas máquinas, a depreciação mensal total é de R\$ 33.333,34, enquanto no cenário com ampliação tecnológica, que conta com três máquinas, a depreciação mensal total é de R\$ 50.000,01. A diferença entre esses valores decorre do maior número de ativos depreciáveis no cenário de ampliação de recursos, permanecendo constantes o valor unitário, a vida útil econômica e o método de depreciação adotados.

9.5.2 Estimativa de receita por throughput

A estimativa de receita foi realizada a partir da integração entre os resultados operacionais da simulação e os dados econômicos da clínica, tendo como base o

throughput de pacientes obtido em cada cenário analisado. O objetivo desta seção é apresentar de forma transparente o procedimento adotado para o cálculo da receita mensal, bem como os valores estimados para cada cenário operacional.

A receita unitária considerada na análise corresponde ao valor médio ponderado dos exames de RM (Equação 4), calculado a partir dos valores unitários praticados pela clínica e da frequência relativa de cada tipo de exame observada no fluxo real de pacientes (Figura 23). Por razões de confidencialidade institucional, os valores unitários individuais dos exames não são apresentados. O cálculo do valor médio ponderado foi realizado por meio da ponderação dos preços pelos respectivos percentuais de ocorrência no mix de exames, resultando em um valor médio de R\$ 747,50 por paciente atendido.

Equação 4 - Valor médio ponderado dos exames de RM

$$R_m = \sum_{i=1}^n (p_i \times f_i)$$

Onde:

- p_i é o valor unitário do exame i ;
- f_i é a frequência relativa do exame i no fluxo observado.

A receita mensal estimada de cada cenário foi obtida pela multiplicação desse valor médio ponderado pelo *throughput* mensal observado na simulação, conforme a Equação 5:

Equação 5 - Cálculo da receita mensal do cenário

$$Receita_{mensal} = Throughput_{mensal} \times R_m$$

Nos cenários em que o *throughput* foi obtido diretamente em base mensal, o valor foi utilizado conforme reportado pela simulação. Para o segundo cenário com ampliação tecnológica (cenário 4), o *throughput* foi inicialmente obtido a partir de uma simulação de cinco dias úteis, totalizando 280 pacientes. Para fins de comparabilidade com os demais cenários, esse valor foi convertido para base mensal, considerando-se quatro semanas operacionais, resultando em um *throughput* mensal estimado de 1.120 pacientes.

A Tabela 14 evidencia que as diferenças de receita mensal entre os cenários decorrem exclusivamente da variação do *throughput* obtido na simulação, uma vez que o valor médio ponderado por paciente foi mantido constante. O cenário reorganizado apresenta aumento de receita em relação ao cenário atual sem acréscimo da capacidade instalada, refletindo ganhos oriundos da otimização do fluxo de atendimento. Por sua vez, os dois cenários com ampliação tecnológica apresentam os maiores valores de receita mensal, em função do aumento da capacidade produtiva proporcionado pela adição de uma nova máquina de RM, sendo possível observar diferenças de desempenho econômico entre configurações operacionais distintas mesmo com a mesma base tecnológica.

Tabela 14 - Receita mensal estimada por cenário

Cenário	Throughput mensal (pacientes)	Receita mensal estimada (R\$)
Cenário 1	692	517.270,00
Cenário 2	765	571.087,50
Cenário 3	976	729.560,00
Cenário 4	1120	837.200,00

Fonte: Autor (2025)

9.5.3 Análise comparativa dos cenários

A análise comparativa dos cenários foi conduzida com base na integração entre os resultados operacionais obtidos por meio da simulação computacional e os indicadores econômicos estimados para cada configuração do sistema. Foram considerados quatro cenários distintos: o cenário 1, o cenário reorganizado sem ampliação da capacidade instalada (cenário 2) e dois cenários com expansão tecnológica por meio da aquisição de uma nova máquina de ressonância magnética (cenários 3 e 4), os quais diferem entre si pela configuração operacional adotada.

A comparação inicial entre os cenários com duas máquinas de RM evidencia que a reorganização operacional resulta em aumento do *throughput* e, conseqüentemente, da receita mensal estimada, sem acréscimo dos custos estruturais associados à base tecnológica. Esse resultado demonstra que ganhos

econômicos relevantes podem ser obtidos por meio da melhoria do fluxo de atendimento e da melhor alocação dos recursos existentes, configurando uma alternativa de baixo risco financeiro e de maior viabilidade no curto prazo.

Ao comparar o cenário 2 com os cenários que incorporam a aquisição de uma nova máquina, observa-se que a ampliação da capacidade tecnológica proporciona incrementos expressivos no *throughput* e na receita mensal. Entretanto, esses ganhos operacionais e econômicos estão condicionados a um conjunto de restrições estruturais e financeiras, que devem ser consideradas no processo decisório.

Do ponto de vista financeiro, a aquisição de uma nova máquina implica um investimento inicial elevado, associado não apenas ao custo de compra do equipamento, mas também à imobilização de capital e ao impacto sobre a capacidade de investimento da clínica. Além disso, mesmo considerando períodos de garantia para manutenção, a ampliação da base de ativos resulta em aumento dos custos estruturais ao longo do tempo, especialmente aqueles relacionados à depreciação dos equipamentos e à necessidade de ampliação do quadro técnico para operação contínua da nova máquina.

Sob a perspectiva de infraestrutura física, a incorporação de uma nova máquina de RM impõe restrições relacionadas à adequação do espaço físico da clínica. Esses requisitos incluem, entre outros aspectos, a disponibilidade de área compatível com o porte do equipamento, adaptações estruturais específicas, blindagem adequada, adequações elétricas e de climatização, além do atendimento às normas técnicas e regulatórias vigentes. Tais intervenções podem demandar investimentos adicionais e tempo de implementação, que não são capturados diretamente pelos indicadores financeiros do estudo, mas impactam a viabilidade prática da expansão.

A existência de dois cenários com ampliação tecnológica permite avaliar de forma mais aprofundada o papel da configuração operacional mesmo sob a mesma base tecnológica. Os resultados mostram que, embora os cenários 3 e 4 contem com três máquinas de RM, diferenças na organização do fluxo e na utilização dos recursos resultam em desempenhos econômicos distintos. O cenário 4, que apresenta maior *throughput* mensal, alcança a maior receita mensal estimada entre os cenários analisados, evidenciando que a efetividade dos benefícios do investimento depende

de uma configuração operacional adequada e de uma gestão alinhada à nova capacidade instalada.

De forma geral, a análise comparativa demonstra que os cenários podem ser organizados em uma hierarquia de desempenho econômico e de complexidade de implementação. O cenário atual apresenta o menor nível de eficiência operacional e econômica. O cenário reorganizado representa um avanço significativo, com ganhos obtidos sem investimento em novos ativos e com menores restrições financeiras e estruturais. Os cenários com ampliação tecnológica apresentam os maiores níveis de desempenho econômico potencial, porém estão associados a maiores restrições financeiras, estruturais e organizacionais, que devem ser cuidadosamente avaliadas.

Assim, os resultados evidenciam que estratégias baseadas exclusivamente em reorganização operacional e aquelas que envolvem expansão tecnológica não devem ser tratadas como excludentes, mas como alternativas com diferentes níveis de risco, investimento e complexidade. A decisão gerencial deve considerar não apenas o desempenho econômico estimado, mas também a capacidade financeira da organização, a viabilidade de adequação da infraestrutura física e a maturidade da gestão para operar um sistema mais complexo.

Com o objetivo de sintetizar os principais resultados da análise comparativa, a Tabela 15 apresenta as vantagens e restrições associadas a cada cenário avaliado, evidenciando as diferenças em termos de desempenho econômico, complexidade de implementação e viabilidade prática.

Tabela 15- Síntese comparativa de vantagens e restrições dos cenários analisados

Cenário	Configuração operacional	Principais vantagens	Principais restrições
Cenário 1	2 RMs – fluxo original	<ul style="list-style-type: none"> • Não requer investimentos adicionais • Estrutura física e organizacional já consolidada • Baixa complexidade de gestão 	<ul style="list-style-type: none"> • Menor <i>throughput</i> e receita • Maior tempo de espera dos pacientes • Gargalos operacionais persistentes • Uso ineficiente da capacidade instalada

Cenário	Configuração operacional	Principais vantagens	Principais restrições
Cenário 2	2 RMs – fluxo otimizado	<ul style="list-style-type: none"> • Aumento do <i>throughput</i> sem investimento em ativos • Ganhos econômicos com baixo risco financeiro • Melhor aproveitamento dos recursos existentes • Implementação rápida 	<ul style="list-style-type: none"> • Capacidade produtiva limitada à infraestrutura existente • Ganhos dependentes da disciplina operacional • Menor potencial de crescimento no médio e longo prazo
Cenário 3	3 RMs – configuração operacional atual	<ul style="list-style-type: none"> • Ampliação da capacidade produtiva • Redução adicional dos tempos de espera • Aumento significativo da receita mensal 	<ul style="list-style-type: none"> • Elevado investimento inicial • Necessidade de adequação da estrutura física • Ampliação do quadro técnico • Maior custo estrutural (depreciação e manutenção) • Risco de subutilização se a gestão não for adequada
Cenário 4	3 RMs – configuração operacional otimizada	<ul style="list-style-type: none"> • Maior <i>throughput</i> entre os cenários • Melhor captura dos benefícios do investimento • Maior potencial de receita mensal • Redução mais expressiva de gargalos 	<ul style="list-style-type: none"> • Mesmas restrições financeiras e estruturais do cenário 3 • Maior complexidade operacional • Dependência de demanda suficiente para sustentar a capacidade instalada

Fonte: Autor (2025)

9.5.4 Viabilidade econômica e retorno do investimento

A viabilidade econômica dos cenários analisados foi avaliada a partir da integração entre os resultados operacionais obtidos na simulação e os indicadores financeiros estimados para cada configuração do sistema. A análise tem como foco principal os cenários que incorporam a aquisição de uma nova máquina de RM, comparados ao cenário 2 que representa a melhor alternativa sem investimento adicional em ativos físicos.

Nos cenários sem ampliação da capacidade instalada, não há necessidade de investimento inicial em equipamentos. Assim, a avaliação econômica restringe-se à comparação entre receitas e custos operacionais correntes, evidenciando que o cenário reorganizado apresenta ganhos econômicos decorrentes da otimização do fluxo de atendimento, com baixo risco financeiro e rápida implementação.

Nos cenários com ampliação tecnológica, a viabilidade econômica passa a depender da capacidade do sistema em transformar o aumento do *throughput* em receita suficiente para compensar o investimento inicial e os custos estruturais adicionais. O investimento considerado corresponde à aquisição de uma nova máquina de RM, no valor de R\$ 2.000.000,00, além da ampliação do quadro técnico necessária para sua operação. Os custos recorrentes de manutenção, reposição de peças e depreciação dos equipamentos foram incorporados à análise conforme descrito nas seções anteriores.

Para avaliar o retorno do investimento, adotou-se o método do payback simples, definido como a razão entre o investimento inicial e o ganho incremental de receita mensal obtido em relação ao cenário reorganizado. Esse método foi escolhido por sua simplicidade e adequação a análises comparativas exploratórias, permitindo estimar a ordem de grandeza do tempo necessário para recuperação do capital investido. A Equação 6 apresenta a formulação utilizada:

Equação 6 - Equação de payback

$$Payback_{meses} = \frac{Invenstimento\ inicial}{Ganho\ incremental\ da\ receita\ mensal}$$

O ganho incremental de receita mensal foi calculado como a diferença entre a receita mensal estimada de cada cenário com nova máquina e a receita mensal do cenário reorganizado, isolando, assim, o efeito econômico da expansão tecnológica em relação à alternativa de otimização sem investimento.

A Tabela 16 apresenta os cálculos de retorno do investimento para os dois cenários com ampliação tecnológica.

Tabela 16 - Viabilidade econômica e retorno do investimento

Indicador	Cenário 3	Cenário 4
Receita mensal estimada (R\$)	729.560,00	837.200,00
Receita mensal – Cenário 2 (R\$)	571.087,50	571.087,50
Ganho incremental de receita mensal (R\$)	158.472,50	266.112,50
Investimento inicial	2.000.000,00	2.000.000,00
Payback simples (meses)	≈ 12,6	≈ 7,5
Payback simples (anos)	≈ 1,05	≈ 0,62

Fonte: Autor (2025)

Os resultados indicam que ambos os cenários com aquisição de nova máquina apresentam potencial de retorno do investimento em horizonte inferior a dois anos, sendo que o cenário 4 se destaca por apresentar maior ganho incremental de receita mensal e, conseqüentemente, menor tempo estimado de retorno. Esse resultado evidencia que a viabilidade econômica da expansão tecnológica depende fortemente da configuração operacional adotada, mesmo quando o investimento inicial é o mesmo.

Ressalta-se que o ganho incremental utilizado no cálculo do *payback* representa uma medida exploratória baseada na receita adicional gerada pelo aumento do *throughput*. Embora os custos estruturais adicionais tenham sido incorporados à análise econômica ao longo do capítulo, o uso da receita incremental como base para o *payback* visa fornecer uma estimativa da ordem de grandeza do retorno do investimento, adequada ao caráter comparativo do estudo.

Adicionalmente, o método do *payback* simples não considera o valor do dinheiro no tempo, tampouco incorpora explicitamente possíveis atrasos associados à implantação da nova máquina, tais como adequações da infraestrutura física, obtenção de licenças regulatórias e treinamento da equipe.

Por outro lado, o ganho incremental utilizado no cálculo do *payback* representa uma medida exploratória baseada na receita adicional gerada pelo aumento do *throughput*. Embora os custos estruturais adicionais tenham sido incorporados à análise econômica ao longo do capítulo, o uso da receita incremental como base para

o *payback* visa fornecer uma estimativa da ordem de grandeza do retorno do investimento, adequada ao caráter comparativo do estudo.

Outra variável relevante refere-se à dependência da demanda. A viabilidade econômica dos cenários com ampliação tecnológica está condicionada à manutenção de níveis de demanda compatíveis com a capacidade instalada. Caso a demanda não seja suficiente para absorver o aumento do throughput simulado, os ganhos incrementais de receita tendem a ser reduzidos, impactando negativamente o tempo de retorno do investimento.

Assim, a análise de viabilidade econômica demonstra que, embora os cenários com nova máquina de ressonância magnética apresentem elevado potencial de retorno financeiro no médio e longo prazo, sua implementação está associada a maiores restrições financeiras, estruturais e organizacionais quando comparados ao cenário reorganizado. A decisão pela expansão tecnológica deve, portanto, considerar não apenas o retorno financeiro estimado, mas também a capacidade financeira da clínica, o tempo necessário para implantação da nova estrutura e a maturidade gerencial requerida para operar um sistema mais complexo.

10 CONCLUSÃO

Este estudo utilizou a simulação computacional fundamentada em dados reais como ferramenta de apoio à decisão para a gestão de serviços de diagnóstico por imagem. A partir da modelagem do fluxo de pacientes em uma clínica de ressonância magnética no interior de Pernambuco, foi possível compreender, quantificar e intervir sobre os principais fatores que impactam o desempenho operacional do sistema, especialmente os tempos de espera, a utilização dos recursos críticos e a capacidade produtiva.

Os resultados mostraram que os gargalos do processo se concentravam principalmente na etapa de exame, fortemente influenciada pela variabilidade dos tempos de setup e pela lógica de agendamento adotada. No cenário atual, a elevada utilização das técnicas de radiologia e das máquinas de RM confirmou a existência de restrições estruturais que limitam o número atendimentos e prolongam o tempo de permanência dos pacientes no sistema. A simulação permitiu tornar visíveis essas restrições, oferecendo uma visão sistêmica que dificilmente seria alcançada apenas por observação empírica.

A avaliação dos cenários alternativos demonstrou que intervenções exclusivamente operacionais, sem incremento de recursos físicos ou humanos, já são capazes de gerar ganhos relevantes. A reorganização da sequência de exames, o agrupamento por similaridade técnica, a alternância entre procedimentos de curta e longa duração e a introdução de buffers operacionais resultaram em redução significativa do tempo médio de permanência no sistema e aumento da capacidade de atendimento semanal. Esses achados reforçam que a eficiência do serviço não depende apenas de investimentos em tecnologia, mas também de decisões gerenciais baseadas em análise quantitativa e compreensão do fluxo assistencial.

De maneira integrada, os resultados obtidos nos quatro cenários permitiram identificar impactos operacionais decorrentes das intervenções simuladas. No entanto, apesar da redução do tempo médio de permanência observada, de aproximadamente 139 para 119 minutos no cenário reorganizado e para cerca de 75 minutos no cenário com três máquinas, tais melhorias devem ser interpretadas com criticidade, uma vez que dependem de condições específicas de demanda, disponibilidade da equipe e estabilidade do processo. De modo semelhante, o

incremento do *throughput* semanal, de 161 para 178 e posteriormente para 227 exames, indica potencial de expansão produtiva, mas não garante que tais níveis seriam sustentáveis em longo prazo diante da variabilidade real do serviço.

No que se refere ao desempenho financeiro, os resultados evidenciam que o aumento do *throughput* obtido nos cenários simulados está diretamente associado a incrementos relevantes na receita mensal estimada. A receita passou de aproximadamente R\$ 517.270,00 no cenário atual para R\$ 571.087,50 no cenário reorganizado, sem necessidade de investimento adicional em ativos. Nos cenários com expansão estrutural, a incorporação de uma nova máquina de RM elevou a receita mensal para valores entre R\$ 729.560,00 e R\$ 837.200,00, a depender da configuração operacional adotada. A análise financeira integrada incorporou explicitamente custos de recursos humanos, manutenção, reposição de peças e depreciação dos equipamentos, bem como a avaliação do retorno do investimento por meio do método do *payback* simples, indicando tempos estimados de retorno entre 7,5 e 12,6 meses para os cenários com ampliação tecnológica. Esses resultados indicam que, embora a expansão estrutural apresente maior potencial de geração de receita, sua viabilidade econômica está condicionada à adequada configuração operacional, à manutenção da demanda e à capacidade financeira da organização para absorver o investimento inicial e os custos estruturais associados.

Assim, embora os resultados indiquem benefícios potenciais do uso de simulação na gestão de serviços de imagem, tais achados representam apenas parte de um contexto mais amplo e não encerram a discussão sobre o tema. Os cenários simulados mostram tendências e possibilidades de melhoria, mas não substituem a complexidade da operação real, reforçando a necessidade de interpretações cautelosas e de aprofundamento contínuo.

Além das contribuições práticas, este trabalho também explorou um contexto ainda pouco investigado na literatura: clínicas privadas de médio porte, com foco específico em exames de ressonância magnética. A padronização metodológica adotada, desde a coleta de dados até a análise dos relatórios de simulação, amplia a replicabilidade do estudo e fortalece sua relevância científica.

Como oportunidades para trabalhos futuros, pode-se ampliar o escopo do modelo para incluir outros serviços da clínica, como tomografia e ultrassonografia,

possibilitando uma visão integrada da operação e da alocação compartilhada de recursos. A incorporação de comportamentos dos pacientes, como atrasos, faltas ou necessidade de repetição de exames, por meio de abordagens híbridas que integrem DES e ABS, também representa um avanço metodológico relevante. A integração entre simulação e técnicas de otimização, como algoritmos genéticos ou heurísticas de agendamento, visando identificar automaticamente sequências ótimas de exames e escalas de equipe. Outra possibilidade se refere à incorporação de indicadores econômicos mais detalhados, permitindo análises custo-benefício e avaliação do retorno sobre investimento em diferentes cenários de expansão. Por fim, a aplicação do modelo em outras unidades ou regiões permitiria análises comparativas e maior generalização dos resultados.

Desta forma, a simulação computacional se mostra como um instrumento estratégico para a melhoria contínua dos serviços de saúde, capaz de apoiar decisões mais eficientes, sustentáveis e alinhadas à geração de valor para o paciente. O presente estudo reafirma seu potencial tanto como ferramenta gerencial quanto como objeto de investigação científica, contribuindo para o avanço da engenharia de produção aplicada à saúde.

REFERÊNCIAS

AHMAD, A. N. A. *et al.* Implementation of Lean Technique towards Reducing Waiting Time in a Public Healthcare using Arena Simulation. **International Journal of Integrated Engineering**, 2021. v. 13, n. 5, p. 201–214.

ALA, A.; CHEN, F. **Appointment Scheduling Problem in Complexity Systems of the Healthcare Services: A Comprehensive Review**. *Journal of Healthcare Engineering*. Hindawi Limited.

ALKHER, M. *et al.* Case study of healthcare organization improvement with lean concept. **Tehnicki Vjesnik**, 2019. v. 26, n. 3, p. 845–851.

BAHARI, A.; ASADI, F. A simulation optimization approach for resource allocation in an emergency department healthcare unit. **Global Heart**, 11 fev. 2020. v. 15, n. 1.

BANIK, D. *et al.* A decision support model for selecting unmanned aerial vehicle for medical supplies: context of COVID-19 pandemic. **The International Journal of Logistics Management**, 14 mar. 2023. v. 34, n. 2, p. 473–496.

BELHOR, M. *et al.* Learning-Based Metaheuristic Approach for Home Healthcare Optimization Problem. **Computer Systems Science and Engineering**, 2023. v. 45, n. 1, p. 1–19.

BUSCHIAZZO, M.; MULA, J.; CAMPUZANO-BOLARIN, F. Simulation optimization for the inventory management of healthcare supplies. **International Journal of Simulation Modelling**, 1 jun. 2020. v. 19, n. 2, p. 255–266.

CAI, H.; JIA, J. Using Discrete Event Simulation (DES) To Support Performance-Driven Healthcare Design. **Health Environments Research and Design Journal**, 1 jul. 2019. v. 12, n. 3, p. 89–106.

CHANG, H. C. *et al.* The application of GSCM in eliminating healthcare waste: Hospital EDC as an example. **International Journal of Environmental Research and Public Health**, 1 nov. 2019. v. 16, n. 21.

CHEN, X. *et al.* Matching patients and healthcare service providers: a novel two-stage method based on knowledge rules and OWA-NSGA-II algorithm. **Journal of Combinatorial Optimization**, 15 jan. 2019. v. 37, n. 1, p. 221–247.

CREMA, M.; VERBANO, C. **Simulation modelling and lean management in healthcare: first evidences and research agenda. Total Quality Management and Business Excellence.** Routledge.

DATTA, R.; UPADHYAY, K. K.; JAIDEEP, C. N. Simulation and its role in medical education. **Medical Journal Armed Forces India**, 1 abr. 2012. v. 68, n. 2, p. 167–172. . Acesso em: 25 ago. 2025.

FELIX, L. T. X. E S.; MAIOR, C. B. S. Revisão Sistemática de Aplicações de Simulação em Serviços de Saúde. [S.l.]: [s.n.], 2025.

FLORIDIS, J. Debriefing after critical incidents in rural and remote healthcare settings - a remote clinician perspective. **Rural and Remote Health**, 2023. v. 23, n. 1.

GAO, X.; WEN, J.; SONG, J. Capacity allocation and revenue sharing in healthcare alliances. **Flexible Services and Manufacturing Journal**, 1 dez. 2020. v. 32, n. 4, p. 829–851.

GIL, A. C. **Como elaborar projetos de pesquisa**. 6. ed. São Paulo: Atlas, 2017.

GROVES-KIRKBY, N. *et al.* Large-scale calibration and simulation of COVID-19 epidemiologic scenarios to support healthcare planning. **Epidemics**, 1 mar. 2023. v. 42.

IMPROTA, G. *et al.* Agile six sigma in healthcare: Case study at santobono pediatric hospital. **International Journal of Environmental Research and Public Health**, 1 fev. 2020. v. 17, n. 3.

JERRY BANKS. **Handbook of Simulation: Principles, Methodology, Advances, Applications, and Practice**. 1. ed. Atlanta: John Wiley & Sons, Inc., 1998.

KUIPER, A. *et al.* A flexible and optimal approach for appointment scheduling in healthcare. **Decision Sciences**, 1 fev. 2023. v. 54, n. 1, p. 85–100.

LARRAIN, N.; GROENE, O. Simulation modeling to assess performance of integrated healthcare systems: Literature review to characterize the field and visual aid to guide model selection. **PLoS ONE**, 1 jul. 2021. v. 16, n. 7 July.

LIN, Y. X.; LIN, Chi Hao; LIN, Chih Hao. Post-earthquake Patient diversion strategies for improving regional emergency healthcare accessibility. **International Journal of Disaster Risk Reduction**, 1 out. 2023. v. 96.

MIELCZAREK, B.; UZIAŁKO-MYDLIKOWSKA, J. Application of computer simulation modeling in the health care sector: a survey. **SIMULATION**, 15 fev. 2012. v. 88, n. 2, p. 197–216.

MINISTÉRIO DA SAÚDE. **Normas e Manuais Técnicos Cadernos de Atenção Primária**. Brasília: [s.n.], 2010. V. 29.

MITROPOULOS, P.; ADAMIDES, E.; MITROPOULOS, I. Redesigning a network of primary healthcare centres using system dynamics simulation and optimisation. **Journal of the Operational Research Society**, 2023. v. 74, n. 2, p. 574–589.

MONKS, T.; HARPER, A. Computer model and code sharing practices in healthcare discrete-event simulation: a systematic scoping review. **Journal of Simulation**, 2023.

MWANZA, J.; TELUKDARIE, A.; IGUSA, T. Optimising Maintenance Workflows in Healthcare Facilities: A Multi-Scenario Discrete Event Simulation and Simulation Annealing Approach. **Modelling**, 1 jun. 2023. v. 4, n. 2, p. 224–250.

ORDU, M. *et al.* A novel healthcare resource allocation decision support tool: A forecasting-simulation-optimization approach. **Journal of the Operational Research Society**, 2021. v. 72, n. 3, p. 485–500.

PORTER, M. E. What Is Value in Health Care? **New England Journal of Medicine**, 23 dez. 2010. v. 363, n. 26, p. 2477–2481. Disponível em: <<http://www.nejm.org/doi/abs/10.1056/NEJMp1011024>>.

ROY, S. N.; SHAH, B. J.; GAJJAR, H. **Application of Simulation in Healthcare Service Operations**. **ACM Transactions on Modeling and Computer Simulation**. Association for Computing Machinery.

SEVERINO, A. J. **Metodologia do trabalho científico**. 24. ed. São Paulo: Cortez, 2017.

SHAKOOR, M. *et al.* Application of discrete event simulation for performance evaluation in private healthcare: The case of a radiology department. **International Journal of Healthcare Management**, 2021. v. 14, n. 4, p. 1303–1310.

SOORAPANTH, S.; ELDABI, T.; YOUNG, T. Towards a framework for evaluating the costs and benefits of simulation modelling in healthcare. **Journal of the Operational Research Society**, 2023. v. 74, n. 3, p. 637–646.

SRIVASTAVA, S. K. Green supply-chain management: A state-of-the-art literature review. **International Journal of Management Reviews**, 28 mar. 2007. v. 9, n. 1, p. 53–80.

TEYMOURIFAR, A. Simulation-based optimization for resectorization in healthcare systems. **Journal of Simulation**, 2024. v. 18, n. 3, p. 311–330.

TLAPA, D. *et al.* **Effects of Lean Interventions Supported by Digital Technologies on Healthcare Services: A Systematic Review**. **International Journal of Environmental Research and Public Health**. MDPI.

VERGARA, S. C. **Projetos e relatórios de pesquisa em administração**. 16. ed. São Paulo: Atlas, 2016.

WANG, L.; DEMEULEMEESTER, E. Simulation optimization in healthcare resource planning: A literature review. **IISE Transactions**, 3 out. 2023. v. 55, n. 10, p. 985–1007. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/24725854.2022.2147606>>.

WU, X.; LI, J.; CHU, C. H. Modeling multi-stage healthcare systems with service interactions under blocking for bed allocation. **European Journal of Operational Research**, 1 nov. 2019. v. 278, n. 3, p. 927–941.

YIN, R. K. **Case Study Research: Design and Methods**. 5. ed. Thousand Oaks, CA: SAGE, 2014.

YOUNG, T. *et al.* The costs and value of modelling-based design in healthcare delivery: five case studies from the US. **Health Systems**, 2 jul. 2020. v. 9, n. 3, p. 253–262.