

Medindo a Capacidade de Atendimento de um Hospital Modular para COVID-19: uma abordagem via Simulação de Eventos Discretos

Measuring the Care Capacity of a Modular Hospital to COVID-19: A Discrete Event Simulation approach

Yasmin Costa Tavore¹

¹Departamento de Engenharia de Produção, Universidade Federal de São Carlos – UFSCar, Sorocaba, SP, Brasil, e-mail: yasmin.tavore@estudante.ufscar.br

Resumo: Com o aumento da demanda por serviços de saúde ocasionada pela pandemia de COVID-19, diversos países observaram o colapso dos seus sistemas de saúde, por falta de recursos para o atendimento dos infectados. Muitos países recorreram à criação de hospitais temporários para o acolhimento de pacientes, com o objetivo de tratar quadros mais graves causados pelo vírus. A Organização Pan-Americana de Saúde (OPAS) publicou um guia para a configuração desses hospitais modulares para auxiliar na construção dessas estruturas. O objetivo deste trabalho é avaliar o desempenho do atendimento em um hospital modular proposto, através da simulação dinâmica desse sistema, para evidenciar qual a capacidade máxima do mesmo e sua aderência às variações da demanda mensal. Para isso, o hospital modular foi modelado computacionalmente via simulação de eventos discretos. Os cenários analisados tiveram a taxa de chegada dos pacientes variados de modo a aumentar o número de pacientes em cerca de 10% em cada cenário. Indicadores como tempo de permanência dos pacientes no sistema, tempo de espera e ocupação dos leitos foram comparados para a análise desempenho do hospital modular, dessa forma seria possível comparar o nível de serviço oferecido em cada cenário e avaliar qual tem maior conformidade e dessa forma definir a capacidade máxima da estrutura. Ao final da análise, a capacidade máxima do hospital modular estudados está entre 340 e 372 pacientes por mês, de modo a garantir a segurança dos pacientes e manter o nível de qualidade do sistema.

Palavras-chave: Análise da Capacidade, Simulação de Eventos Discretos, Hospital Modular, COVID-19

Abstract: *Abstract: With the increase in demand for health services caused by the COVID-19 pandemic, several countries have observed the collapse of their health systems, due to lack of resources to care for those infected. Many countries have resorted to the creation of temporary hospitals to receive patients, with the aim of treating more serious conditions caused by the virus. The Pan American Health Organization (PAHO) has published a guide for the configuration of these modular hospitals to assist in the construction of these structures. The objective of this work is to evaluate the performance of care in a proposed modular hospital, through the dynamic simulation of this system, to show the maximum capacity of the system and its adherence to variations in monthly demand. For this, the modular hospital was computationally modeled via discrete event simulation. The analyzed scenarios had the patient arrival rate varied in order to*

increase the number of patients by about 10% in each scenario. Indicators such as length of stay of patients in the system, waiting time and occupancy of beds were compared to analyze the performance of the modular hospital, in this way it would be possible to compare the level of service offered in each scenario and assess which one has greater compliance and thus define the maximum capacity of the structure.

Keywords: *Capacity Analysis, Discrete Event Simulation, Modular Hospital, COVID-19*

1. Introdução

Em março de 2020, a Organização Mundial da Saúde (OMS) declarou a pandemia de COVID-19. O rápido contágio da doença e a necessidade de recursos específicos para o tratamento de casos mais críticos causaram o aumento repentino da demanda por médicos, enfermeiros, EPIs, leitos e outros recursos relacionados ao tratamento de COVID-19.

Doenças infecciosas como Síndrome Respiratória Aguda Grave (SRAG), causada pelo COVID-19, possuem alto potencial pandêmico e epidemiológico. Esses surtos apresentam uma dinâmica de evolução e propagação bem estabelecida em quatro fases, cada qual com medidas específicas para contenção e controle da doença (OMS, 2018).

Na primeira fase da dinâmica, ocorre a identificação da doença e introdução para a comunidade. Logo em seguida, evolui para surtos com transmissão localizada. Nessas etapas, as medidas sugeridas são a antecipação dos riscos, para compreender o comportamento da doença, e a detecção precoce, para isolamento dos infectados. A terceira fase consiste na propagação do vírus em níveis maiores (epidemia ou pandemias), onde há infecção generalizada entre humanos. As medidas desta fase são voltadas à contenção do vírus e devem ser tomadas por profissionais qualificados para tal, que irão buscar mitigar o impacto e reduzir a incidência e mortalidade, assim como evitar perturbações em sistemas políticos, públicos e sociais. A última fase representa a redução da transmissão, onde a transmissibilidade do patógeno de humano para humano diminui, seja devido à imunidade adquirida ou as medidas efetivas tomadas nas fases anteriores. Nessa última fase, as medidas de eliminação e erradicação da doença são tomadas e a doença deixa de ser um problema de saúde pública.

Na pandemia de COVID-19, grande parte dos países optaram pela política de isolamento coletivo e práticas de prevenção de contágio, como uso de máscaras e higienização constante das mãos. Ainda assim, os números de infectados e mortos da pandemia são bem expressivos. No Brasil, desde o início da pandemia, até 15 de setembro de 2022, 34.568.838 pessoas já foram infectadas e 685.203 pessoas morreram em decorrência dos sintomas do vírus (BRASIL, 2022). O país ocupa a segunda posição no número de mortes a cada mil habitantes em todo continente americano, segundo a Global Change Data Lab (2022).

Em diferentes fases da pandemia, países optaram por criar unidades móveis especializadas para atender, tratar e isolar de pacientes infectados por coronavírus. Zhu et. al (2020) documentaram a implementação e gerenciamento de um hospital modular para tratamento de COVID-19, na China. Neste estudo, os autores concluíram que hospitais modulares são úteis para o controle de pandemias, visto que disponibilizam leitos com menor tempo e custo. Ainda,

destacam que a estratégia chinesa de admitir todo potencial paciente de COVID-19, com ou sem sintomas, corroborou a diminuição de contágio e controle da transmissão.

No continente americano, a Organização Pan-Americana de Saúde (OPAS) publicou, em abril de 2020, um guia de recomendações para a configuração de hospital modular especializado para o tratamento da Síndrome Respiratória Aguda Grave. Este guia faz a descrição dos recursos para a construção dos hospitais, como pessoal, instalações, equipamentos e suprimentos, e de como o fluxo adequado dado o quadro clínico do paciente.

As unidades de saúde sugeridas pela OPAS podem ser construídas em qualquer espaço amplo, com ou sem construção. Também apresenta flexibilidade quanto à estratégia de admissão dos pacientes, podendo ser utilizados para isolamento de pacientes moderados ou como opção de transferência para pacientes mais graves, suavizando a ocupação dos sistemas de saúde.

Apesar dos hospitais modulares representarem uma alternativa, como qualquer sistema, eles têm suas limitações. Gerenciar a demanda por serviços e avaliar o aumento de oferta por leitos para cuidado de pacientes críticos desempenham papel crucial para a fase de planejamento para informar planos de resposta à pandemia e na fase de resposta, para atualizar e elaborar planos a curto prazo. (CURRIE et al., 2020)

Por esse motivo, o uso de ferramentas para auxílio na compreensão do sistema e tomada de decisão neste setor não é incomum. Larrain e Groene (2021) mostraram que a simulação tem se mostrado cada vez mais presente para desempenhar esse papel, devido ao custo baixo e à facilidade em relacionar mudanças conforme as modificações no sistema.

Frente a esse contexto, o objetivo deste trabalho é avaliar o desempenho do atendimento em um hospital modular proposto, através da simulação dinâmica desse sistema. Os cenários analisados tiveram a taxa de chegada dos pacientes variados de modo a aumentar o número de pacientes em cerca de 10% em cada cenário. Indicadores como tempo de permanência dos pacientes no sistema, tempo de espera e ocupação dos leitos foram comparados para a análise de desempenho do hospital modular, dessa forma seria possível comparar o nível de serviço oferecido em cada cenário e avaliar qual tem maior conformidade e dessa forma definir a capacidade máxima da estrutura. A análise de cenários pôde sugerir a capacidade máxima comparando os indicadores entre os cenários.

2. Referencial Teórico

Segundo Chwif e Medina (2015), simulação computacional é a representação de um sistema por meio de um computador, de modo a reproduzir o mesmo comportamento quando submetido às mesmas condições. Corroborando para a definição, Law (2014) e Banks (1998),

definem simulação como uma ferramenta de imitação de um sistema e seus processos ao longo do tempo.

Ainda que seja uma ferramenta útil, Chwif e Medina (2015) ressaltam que a simulação deve ser utilizada quando o sistema modelado possui alto volume de variáveis e relações causais não explícitas. Em sistemas mais simples, com relações causais explícitas e/ou baixo número de variáveis, existem alternativas de representação como programação linear, fluxogramas, probabilidade e Teoria das Fila. A maioria dos sistemas reais possuem relações mais complexas, ou seja, maior volume de entidades e de variáveis. Deste modo, uma das alternativas para estes sistemas serem analisados de forma analítica seria a simulação computacional.

Law (2014) divide a simulação em três aspectos diferentes: quanto ao estado do sistema ao longo do tempo (estática ou dinâmica), quanto suas variáveis (estocástica ou determinísticas) e quanto a evolução do tempo ao longo da simulação (contínua ou discreta).

A simulação estática não considera a modificação do sistema ao longo do tempo, portanto é a análise de um sistema em apenas um momento. Oposta a esta classificação, a simulação dinâmica analisa o sistema e suas modificações ao longo do tempo.

Simulação de sistemas determinísticos são aquelas que suas variáveis não são aleatórias, ou seja, possuem valores pré-determinados e a saída do modelo é, portanto, conhecida. Já os sistemas estocásticos, possuem ao menos uma variável aleatória, tornando a saída aleatória e condicionada às variáveis de entrada.

Por fim, as modificações dentro de uma simulação de sistema podem ocorrer de maneira contínua, ou seja, constantemente. Já em uma simulação discreta, as modificações do sistema ocorrem de maneira demarcada e finita.

Desde modo, “a simulação de eventos discretos (SED) diz respeito à modelagem de um sistema à medida que este evolui ao longo do tempo por uma representação na qual as variáveis do estado mudam instantaneamente em pontos separados do tempo” (LAW, 2014), logo, pode ser caracterizada como uma simulação de sistemas dinâmicos, estocásticos e discretos.

Os sistemas de saúde são sistemas integrados, porque apresentam, ao longo da continuidade do cuidado, diversos provedores e componentes que os constituem. Larrain e Groene (2021) afirmam que boa parte das reformas propostas por esses sistemas são para fortalecer esses vínculos e melhor coordená-los. Entretanto, existem problemas para avaliar o desempenho dessas propostas e os reais impulsionadores dos indicadores coletados, dado as abordagens de avaliação utilizadas, as quais têm dificuldade de capturar a complexidade do sistema e definir as vias causais dos resultados.

Além do uso para avaliação do desempenho, Yousefi, Yousefi e Fogliatto. (2021) evidenciam em sua revisão sistemática que o uso da simulação como base para aplicação de

métodos de otimização requer baixo esforço prático e em um ambiente livre de riscos, auxiliando na busca constante de melhorias sensíveis e empiricamente testáveis, com baixos custos operacionais.

Nesse sentido, os estudos apontam que o uso de simulação para a avaliação de desempenho e compreensão dos sistemas integrados de saúde tem se mostrado promissor. Sendo a SED a técnica mais indicada e mais utilizada para estudar e analisar efeitos individuais de sistemas com eventos simultâneos e concorrentes, assim como a formação de filas (LARRAIN e GROENE, 2021). Ainda, a SED possibilita, com modelagem baseada em processos, adaptabilidade e foco em pacientes específicos, tem capacidade de modelar estados complexos, estocásticos e não lineares e capacidade para representar graficamente os fluxos de pacientes (YOUSEFI, YOUSEFI e FOGLIATTO, 2021).

Em contraponto, algumas desvantagens do uso da SED são a necessidade de dados representativos do sistema e o esforço técnico e computacional para montar um modelo fidedigno à realidade.

No cenário pandêmico de COVID-19, no qual as decisões são emergentes, Currie et al. (2020) propuseram um guia indicando metodologias de simulação a partir da decisão que necessita ser tomada com o apoio da ferramenta. São quatro as metodologias de modelagem analisadas: simulação de eventos discretos, sistemas dinâmicos, modelo baseado em agentes e híbrido. O artigo categoriza as decisões para níveis global, nacional, organizacional e individual de abrangência e para as diferentes fases de evolução da pandemia, sendo elas o preparo, a resposta e a recuperação da pandemia.

Neste guia, a SED se adequa para determinar o impacto da disponibilidade de recursos, avaliar tempos de espera e número de entidades esperando nas filas ou passando pelo sistema, pois considera a chegada estocástica de pacientes, o fluxo do paciente e duração da estadia no sistema.

Ao analisar os estudos de natureza aplicada, é possível aferir que a SED é utilizada para avaliar o desempenho do sistema em aspectos como a capacidade total, a utilização de recursos e os tempos de permanência e espera, como demonstrado na tabela 1.

O estudo produzido por Badilla-Murillo et al. (2020), a SED demonstrou grande impacto para conhecimento do sistema e auxiliou na geração de sugestões de melhorias que culminaram em cenários a serem simulados. Produzido para representar uma clínica de angiografia, o modelo inicial apontou que a capacidade instalada do sistema estava bem abaixo do necessário, visto que a taxa média de ocupação dos equipamentos para o exame correspondia a 99% e a fila aguardando pelo procedimento alcançou 24 pacientes.

Sethi et al. (2020), de modo similar, aplicaram a SED para entender como as restrições para enfrentamento de COVID-19 impactavam no atendimento de uma clínica de oftalmologia.

Com restrições espaciais e o aumento da demanda, o estudo concluiu que para atender a um maior número de pacientes seria necessário aumentar o tempo de trabalho da clínica e o número de recursos, para evitar filas de espera e lotação das salas.

O número de pacientes atendidos é focal no estudo de Campos et al. (2020), no qual reportam que a simulação computacional foi utilizada para planejar uma unidade de pronto atendimento (UPA) especializada no tratamento de quadros clínicos de COVID-19, antes mesmo da implementação dessa. O objetivo foi analisar qual o número máximo de pacientes que poderiam ser atendidos mantendo o nível de atendimento da instituição ao avaliar indicadores de qualidade como tempos de permanência dentro de um limite estabelecido. Ainda, o estudo faz uma programação linear para minimizar os custos dos recursos humanos dentro da UPA.

Analisando todo o fluxo do paciente, os autores concluíram que os gargalos dos sistemas após a consulta médica, em procedimentos como teste de COVID-19, foram tomografia e raio-x, relacionando o número máximo de pacientes atendidos e tempos de esperas com a proporção das prescrições para esse procedimento, tidos como gargalos.

Cudney et al. (2018) exploraram a simulação como suporte à tomada de decisão do gerenciamento de leitos em unidades de terapia intensivas (UTI) e as transferências internas e externas dessas. A pesquisa realizada identifica que para além da necessidade de mais leitos, é necessário a reformulação do processo de alocação deles, diminuindo a necessidade de transferência dos pacientes entre departamentos. Com isso, o tempo de permanência dos pacientes reduziria.

Autores	Ano	Objetivo	Objeto de estudo	Técnica de Simulação	Indicadores analisados
Campos et al.	2020	Estimar a capacidade máxima do sistema e minimizar custos	Unidade de pronto atendimento para doenças respiratórias	SED com otimização linear	Tempo médio de permanência, quantidade pacientes atendidos, taxa de utilização dos recursos e percentual conformidade
Badilla-Murillo et al.	2020	Analisar capacidade instalada e solucionar gargalos	Clínica de angiografia	SED	Taxa de utilização dos recursos, pacientes atendidos, pacientes em espera e tempo médio de espera
Cudney et al.	2018	Analisar os impactos das variáveis no gerenciamento dos leitos	Leitos de tratamento intensivos	SED	Tempo médio de permanência, tempo médio de espera e tempo médio em fila

Williams, Sperneas e Holborn	2020	Analisar impactos das variáveis na ocupação dos leitos	Leitos de tratamento intensivos	SED	Taxa de utilização dos recursos, percentual acima da ocupação de segurança
Sethi et al.	2021	Analisar os impactos das medidas de segurança à COVID-19 na capacidade de atendimento	Clínica de oftalmologia	SED	Tempo médio de permanência, tempo médio de espera e número máximo de pacientes em espera
Tavakoli et al.	2022	Avaliação dos gargalos de acordo com a previsão da chegada de pacientes com COVID-19	Hospital	SED e previsão de demanda	Tempo médio de permanência, tempo médio de espera
Alban et al.	2020	Identificar a capacidade de unidade de tratamento de intensivos com a variação da demanda	Unidade de tratamento intensivo para paciente com COVID-19	Modelo de filas estocástico	Taxa de ocupação dos leitos

Tabela 1: Síntese das aplicações de SED em sistemas de saúde

Ainda sobre avaliação de leitos de UTI, Williams, Sperneas e Holborn (2020) corroboram com o estudo anterior ao afirmarem que mesmo com o aumento da oferta por leitos, em cenário de demanda maior, as atividades operacionais devem ser revistas para evitar lotação. Ainda reforçam que a SED se mostra uma ferramenta sofisticada para tomada de decisão ao oferecer resultados mais precisos.

O estudo realizado por Tavakoli et al. (2022) propõe descrever a previsão de demanda de chegada de pacientes e, junto a SED, identificar gargalos nos cenários com maior número de pacientes. O modelo se mostrou útil para uso como auxílio à administração hospitalar indicando que o tempo limite até o colapso do hospital. Em seu cenário mais próspero foi identificado que o sistema colapsaria em 14 dias, devido ao gargalo gerado pelas UTIs.

A necessidade por ferramenta de apoio ao dimensionamento de leitos de UTI foi o que motivou o desenvolvimento de icu-covid-sim, software criado por Alban et al. (2020) que avalia qual a taxa máxima de pacientes por dia para hospitais que possuem UTI para pacientes com COVID-19 e sem COVID-19. Nele, os autores se propõem a oferecer uma ferramenta que suporte decisões a nível de gerenciamento hospitalar.

De modo geral, a literatura apresenta que a SED é uma ferramenta muito útil para testar alternativas e propor soluções focadas na diminuição da permanência dos pacientes, avaliação dos recursos e diminuição de gastos, embora apresente desvantagens quanto à coleta extensiva de

dados, conhecimento técnico para modelagem, aproximação com o processo real e ferramentas de suporte estatístico.

3. Metodologia

A pesquisa realizada por esse trabalho se caracteriza, segundo Turrioni e Melo (2012, p. 81), como uma pesquisa exploratória, pois “visa proporcionar maior familiaridade com o problema com vistas a torná-lo explícito ou a construir hipóteses”, ao trazer a configuração da Organização Pan-Americana de Saúde (OPAS) para cenário real e testá-la quanto à capacidade de atendimento. Para isso, a pesquisa utilizou de uma abordagem quantitativa, ao modelar e simular o hospital modular.

O objeto de estudo da pesquisa foi o hospital modular sugerido pela OPAS (2020), em sua cartilha de recomendações técnicas para a estruturação física e técnica do mesmo, publicado em 5 de abril de 2020. A cartilha contém a descrição de todos os recursos que considera necessários para o atendimento de pacientes graves com Síndrome Respiratória Aguda, sintoma mais grave da COVID-19.

A configuração do hospital modular proposto pela OPAS é dividida em oito zonas para a formação e bom funcionamento do mesmo, explicitadas na tabela 2. Estas são áreas para recepção e tratamento dos pacientes, assim como para apoio e coordenação da equipe que operacionaliza o hospital modular.

Para cumprir com o objetivo do presente trabalho, apenas as zonas de recepção dos pacientes e de atendimento médico foram inteiramente consideradas e modeladas. São nessas áreas onde acontecem, respectivamente, os processos de admissão e triagem do paciente e a internação dos pacientes para lá direcionados.

As áreas de entrada e saída da equipe e do necrotério foram representadas no modelo para referência física dos espaços. As demais zonas não foram representadas dada a premissa de que os serviços realizados nela não interferem no tempo de permanência dos pacientes e ela não são compostas por recursos compartilhados pelos pacientes durante a internação, não interferindo na análise da capacidade de atendimento do estudo para internação de pacientes com COVID-19.

Zona	Descrição	Status de modelagem
1. Zona de recepção de pacientes	Área para triagem e direcionamento dos pacientes.	Completamente modelada
2. Zona de entrada e saída da equipe	Área para paramentação e desinfecção da equipe, assim como entrada e saída.	Não modelada

3. Zona de atendimento médico	Área de hospitalização dos pacientes e de procedimentos médicos e de enfermagem.	Completamente modelada
4. Zona de serviços de apoio	Área de esterilização dos equipamentos, laboratório e farmácia.	Não modelada
5. Zona de saneamento	Área de armazenamento de resíduos e descontaminação das ambulâncias	Não modelada
6. Zona administrativa	Área do posto de comando do hospital modular e da logística.	Não modelada
7. Zona de apoio da equipe	Área de dormitórios, chuveiros e banheiros para equipe. A cozinha e a área de alimentação também estão inclusas.	Não modelada
8. Zona do necrotério	Área onde são destinados os pacientes mortos.	Não modelada

Tabela 2: Descrição das Zonas do Hospital Modular

Como metodologia adotada para esse estudo, usou-se de base o ciclo de vida do modelo de simulação de Chwif (1999), o qual estrutura o desenvolvimento de um modelo, dividindo-o em três grandes etapas: a formulação, a implementação e a análise do modelo.

A etapa de formulação do modelo consistiu em definir o objetivo e escopo da simulação. O objetivo consiste em analisar a capacidade de atendimento de um hospital modular segundo as configurações da OPAS e definir qual a demanda mensal máxima suportada por este. O escopo abrange as áreas para cuidado e acolhimento dos pacientes, como descrito na Tabela 2. Definido o objetivo e escopo, foi possível descrever o modelo computacional através de um modelo conceitual, elucidando a formulação do modelo e o fluxo do paciente, como pode ser visto na figura 1.

O processo se inicia com a admissão dos pacientes no sistema. Eles são registrados e triados, na zona de recepção dos pacientes. Em seguida eles são classificados entre críticos, graves e leves. Os pacientes críticos e graves são direcionados para internação e os leves são liberados e dispensados do hospital.

Em ambos os processos, se não houver disponibilidade dos recursos recepção e triagem, as entidades esperam na sala de triagem até o recurso ser liberado.

Após a decisão de internação, os pacientes são direcionados para o leito de acordo com sua classificação, na zona de atendimento médico. Se não houver leitos disponíveis assim que o paciente é alocado, os pacientes aguardam em uma sala de pré-internação, de acordo com sua classificação, por até duas horas. Ao fim desse período o paciente é dispensado por falta de leito.

Se a internação ocorrer após o tempo desse processo, o paciente pode receber alta, e ser liberado, ou pode ser levado ao necrotério, em casos de óbito, finalizando o processo.

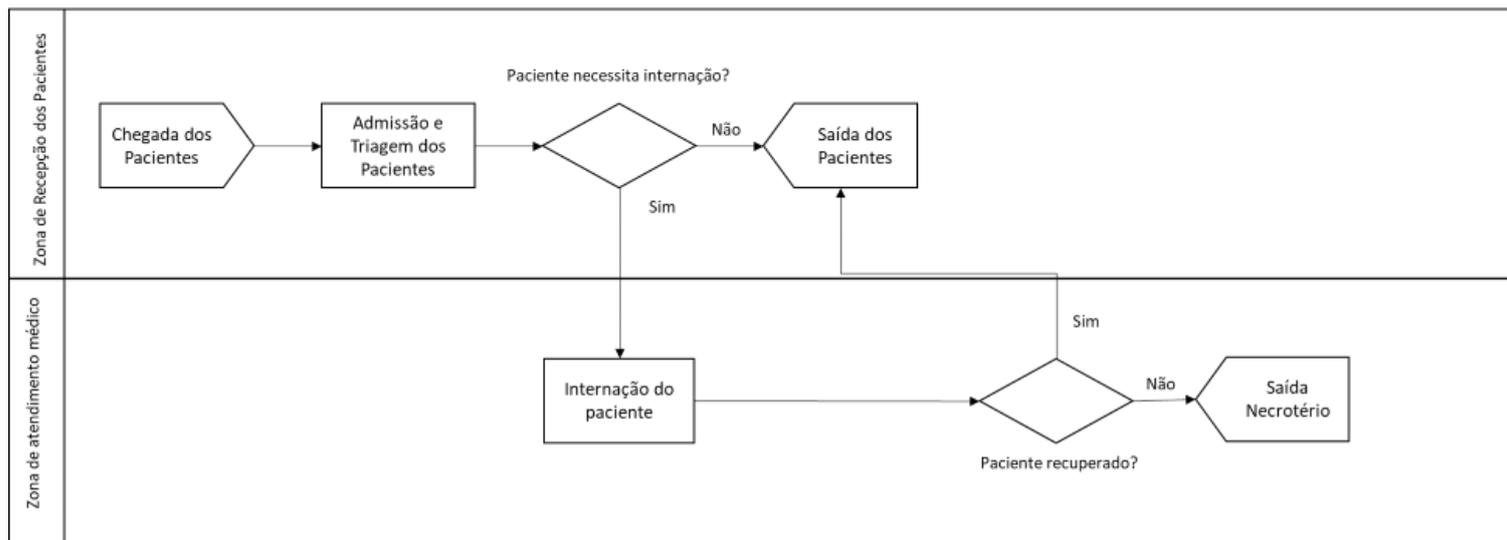


Figura 1: Modelo Conceitual

A etapa de implementação foi dedicada para a criação do modelo computacional e a verificação dele. Para representar o modelo foi utilizado o *software Flexsim* versão 21.2.4, ambiente *healthcare*, oferecido pela ferramenta.

A configuração da cartilha da OPAS possui três opções para a construção dos leitos, sendo elas:

- Configuração 01: Área de tratamento para pacientes em condição grave (10 leitos), área de tratamento para pacientes críticos com suspeita de COVID-19 (10 leitos), e área de tratamento para pacientes críticos com COVID-19 confirmada (10 leitos).
- Configuração 02: Área de tratamento para pacientes graves com COVID-19 (10 leitos) e área de tratamento para pacientes críticos com COVID-19 confirmada (20 leitos) ou vice-versa.
- Configuração 03 (30 graves): Área de tratamento para pacientes em condição grave.

Para esse estudo a configuração será de 20 leitos para casos críticos da doença e 10 leitos para os casos graves, visto que, na análise de dados, a cidade estudada teve uma necessidade maior de leitos para casos críticos.

A estrutura do hospital modular foi criada no espaço 3D do *software* e o controle da lógica foi feito pelo “*Process Flow*”, ambiente *low code* do *Flexsim*. No modelo, os pacientes são criados na entrada do paciente de acordo com uma curva estatística exponencial, a qual teve a taxa λ variada nos cenários de modo a aumentar a demanda. Qual o paciente é criado no ambiente 3D a lógica é ativada e essa entidade é enviada para o processo de recepção, no qual tenta adquirir o

único recurso recepcionista. Se essa aquisição não é feita imediatamente, a entidade vai para a sala de espera, onde fica aguardando a liberação do recurso recepcionista.

Depois de adquirido o recurso, o paciente caminha até a recepção e tem o processo de registro processado de acordo com o tempo imputado no modelo. Após esse processo, a entidade tenta adquirir um, dos dois existentes, recursos triagem. Da mesma forma que no processo de aquisição da recepcionista, se o paciente não conseguir adquiri-lo, ele aguarda na sala de espera, enquanto espera a disponibilidade. Quando um dos recursos triagem fica disponível, o paciente caminha até a triagem e aguarda o processo. Após isso, o paciente é categorizado, de acordo com a probabilidade inserida no modelo.

Pacientes leves e moderados, são encaminhados para a saída e deixam o sistema. Por sua vez, os pacientes críticos e graves são direcionados para seu fluxo de internação respectivos que possuem mesmo funcionamento.

No fluxo de internação, a entidade tenta adquirir um leito de sua classificação e se a aquisição não for imediata, ele é direcionado para uma sala de pré-internação com espaço para até 20 entidades. Essa sala foi definida para não causar travamentos no fluxo dos pacientes e auxiliar com o controle espacial dentro do modelo, já que no hospital modular, o distanciamento entre pacientes deve existir.

Caso o paciente não consiga adquirir o leito em até duas horas, ele é dispensado e sai do sistema. Essa regra foi colocada visto que esperas maiores desse período favorecem a transmissão do patógeno e foi estabelecido como premissa que após esse período o sistema é caracterizado como incapaz de absorver o paciente.

Caso positivo, o paciente consiga adquirir o leito, ele é acompanhado até o leito e aguarda pelo processo de internação, de acordo com cada classificação da doença. Por fim, após o processo de internação, o paciente é liberado do sistema.

Durante a modelagem, foram estabelecidos pontos de coleta de espera e tempo de processo, quando a entidade sai dos processos, entra no sistema e sai do mesmo. Dessa forma, dados de tempo e ocupação dos leitos foram coletados por todo o percurso dos pacientes.

A coleta dos dados de entrada foi feita através de dados presentes em sistemas similares apresentados na bibliografia disponível relativa ao tema do trabalho, em bancos de dados de divulgação dos números da propagação de COVID-19 disponibilizados pelo governo federal e em entrevistas informais com técnicos de laboratório de um hospital em São Paulo, como descrito na tabela 3.

Dados

Período de Referência

Fonte

Número de pacientes infectados e internados	jan 2021- fev 2022	Open DataSUS (BRASIL, 2021)
Tempo de internação	fev 2020 - ago 2020	RANZANI, O et al. (2021)
Classificação dos pacientes	jan 2021- fev 2022	Open DataSUS (BRASIL, 2021)
Taxa de recuperados e óbitos	jan 2021- fev 2022	Open DataSUS (BRASIL, 2021)
Tempo de procedimentos secundários (triagem e registro de paciente)	Indeterminado	Entrevistas informais com profissionais da área

Tabela 3: Relação dos Dados de Entrada

Embora a metodologia adotada preveja uma etapa de validação do modelo, devido às limitações da autora a sistemas similares ao modelado, foi feita uma verificação dele, portanto, foi observado seu comportamento lógico durante a simulação. Para isso, foi apurado se os eventos de decisão direcionam o fluxo de acordo com os dados de entrada, seguindo a proporção definida e se as variáveis se alteravam conforme alteração nos dados de entrada.

Os dados de entrada foram configurados de acordo com os dados da tabela 4, e se mantêm os mesmos em todos os cenários analisados. Após a triagem do paciente, o paciente era classificado entre 2 casos: leves e moderados ou críticos e graves. 73,97% dos pacientes devem ser classificados como leves e moderados, segundo os dados de notificação, e são dispensados do hospital. Casos críticos e graves são novamente classificados e separados em dois grupos: 28,41% deles são casos críticos, e são internados na UTI, e os outros 71,59% são graves e são internados na enfermaria.

O tempo de permanência entre os dois tipos de quadro clínicos é determinado por uma distribuição triangular, retirada de Ranzani et al (2021).

Dados	Valor referência
Taxa pacientes leves e moderados	73,97%
Taxa pacientes críticos	28,41%
Taxa pacientes graves	71,59%
Tempo internação pacientes críticos (dias)	Distribuição: Triangular(min: 4, mod: 8, máx: 14)
Tempo internação pacientes graves	Distribuição: Triangular(min: 3, mod: 7, máx: 13)

(dias)

Tabela 4: Relação dos Dados de Entrada

A análise do cenário base observou qual a quantidade de pacientes atendidos e quantos deles deixaram de ser atendidos por conta de filas maiores de duas horas. Outros indicadores analisados serão a taxa de utilização dos recursos, o tempo de permanência dos pacientes internados em dias, o tempo de espera em horas pelos leitos e o percentual de conformidade do sistema. Juntos, esses indicadores caracterizaram se e como o sistema absorveu a demanda inserida.

A definição dos cenários consistiu na variação de taxa de chegada dos pacientes, de modo a aumentar o número de pacientes em cerca de 10% em cada cenário, como descrito na tabela 4.

	Cenário 1	Cenário 2	Cenário 3	Cenário 4	Cenário 5	Cenário 6
Pacientes por mês	300	330	360	390	420	450
Taxa de chegada (h)	2.40	2.18	2.00	1.85	1.71	1.60

Tabela 5: Pacientes esperados e taxa de chegada por cenário

Foram rodadas 30 replicações de todos os seis cenários para comparação dos resultados, utilizando a ferramenta de replicação de cenários do *software*. Todas as réplicas inicialmente por um tempo de *warm up* de duas semanas e por mais um mês, para coleta dos dados

Como forma de aferir um nível mínimo de qualidade, o indicador de ocupação dos leitos foi considerado seguro até o valor de 85% (MATEEN et al, 2021). Uma taxa de conformidade foi coletada para medir quanto tempo, do período modelado, a taxa média de ocupação dos leitos de manteve acima de 85% (CAMPOS et al., 2020). Com todos esses indicadores, a demanda foi avaliada em quanto foi atendida e se estava dentro dos níveis de qualidade discutidos pela comunidade acadêmica.

4. Resultados e Discussões

Os resultados dos cenários modelados foram apontados de acordo com cinco indicadores, sendo eles:

1. Pacientes atendidos: registra o número médio de atendimentos finalizados. O indicador é separado segundo as classes de pacientes atendidos pelo hospital

- (leves/moderados, críticos e graves) e os pacientes que são dispensados por falta de leito, separados nas classes que são admitidos para internação (críticos e graves);
2. Tempo de permanência (em dias): tempo médio em dias que os pacientes passam internados, separados nas duas classificações consideradas na modelagem (críticos e graves);
 3. Tempo de espera por leitos (em horas): tempo médio de espera por leitos em horas, consideradas na modelagem (críticos e graves);
 4. Ocupação dos leitos (%): percentual de ocupação dos leitos durante o período de simulação, segundo as classes consideradas na modelagem (críticos e graves);
 5. Conformidade (%): apresenta o percentual do tempo de simulação que a ocupação dos leitos se manteve acima de 85%, conforme nível de qualidade definido, consideradas na modelagem (críticos e graves).
 6. Paciente não atendidos (%): percentual de pacientes que não foram atendidos devido a espera por leito maior que duas horas.

Todos os indicadores são referentes ao período de um mês de simulação e os valores em colchetes representam o desvio padrão das réplicas simuladas, como descrito na tabela 6.

	Cenário 1	Cenário 2	Cenário 3	Cenário 4	Cenário 5	Cenário 6
Pacientes Atendidos	311.21 [30.33]	340.70 [32.98]	372.43 [33.85]	400.83 [36.29]	432.25 [37.43]	461.79 [38.05]
Leves/Moderados	228.6 [16.24]	251.33 [17.38]	275.56 [18.00]	297.3 [19.19]	320.5 [20.43]	342.16 [20.69]
Críticos	54.3 [6.15]	57.6 [6.12]	60.76 [5.82]	62.3 [4.95]	64.16 [4.18]	65.76 [4.71]
Graves	22.03 [4.62]	23.9 [5.06]	25.56 [4.03]	27.06 [4.20]	28.76 [3.88]	29.56 [3.44]
Dispensados Críticos	4.85 [2.81]	6.44 [3.90]	8.07 [4.97]	11.0 [6.32]	15.3 [6.87]	19.7 [6.85]
Dispensados Graves	1.42 [0.49]	1.42 [0.49]	2.46 [1.00]	3.10 [1.61]	3.52 [2.06]	4.56 [2.35]
Tempo de Permanência (em dias)						
Críticos	8.23 [0.23]	8.22 [0.19]	8.16 [0.20]	8.24 [0.21]	8.24 [0.18]	8.23 [0.18]
Graves	7.13 [0.37]	7.18 [0.33]	7.23 [0.26]	7.23 [0.32]	7.21 [0.26]	7.19 [0.25]
Tempo de Espera por Leito (em horas)						
Críticos	1.86 [0.20]	1.81 [0.19]	1.82 [0.14]	1.82 [0.19]	1.85 [0.10]	1.83 [0.14]
Graves	1.97 [0.07]	1.99 [0.06]	1.82 [0.42]	1.80 [0.28]	1.86 [0.20]	1.94 [0.09]
Ocupação Leitos (%)						
Críticos	72.75%	76.73%	80.37%	83.98%	86.48%	88.86%
Graves	51.46%	55.51%	60.24%	62.93%	66.50%	68.33%
Conformidade (%)						
Críticos	79.29%	73.32%	66.07%	56.29%	52.20%	45.84%

Graves	94.77%	90.39%	86.06%	81.62%	76.87%	77.00%
--------	--------	--------	--------	--------	--------	--------

Pacientes não atendidos (%)

Críticos	8.12%	10.00%	11.64%	15.01%	18.96%	22.43%
Graves	5.98%	5.53%	8.60%	10.30%	10.87%	13.24%

Tabela 6: Indicadores por cenários

É importante ressaltar que a utilização da sala de espera da triagem e admissão dos pacientes se manteve abaixo de 1% em todos os cenários simulados, o que indica que não há filas nesses processos. Apenas o processo de aquisição de leitos apresenta fila em todos os cenários. Dessa forma é possível aferir que o gargalo desse sistema são os leitos, independente do número de pacientes, assim como apontam os estudos de Tavakoli et al (2022) e Deschepper et al (2021). Campos et al. (2020) também apontaram que os recursos após esses procedimentos são os gargalos.

Como no estudo de Ranzani et al. (2021) os tempos médios de permanência dos pacientes ficaram entre 7, 2 e 8,2 dias, respectivamente, para pacientes críticos e graves. A falta de variação significativa entre os cenários é justificada pelo uso desse dado como variável no sistema, ou seja, o tempo de internação que foi inserido no modelo representa o tempo de permanência dos pacientes.

Já a pouca variação dos tempos de espera por leitos se deve a premissa de que pacientes com mais de duas horas de espera seriam dispensados do hospital. Ainda assim, pode-se inferir pelo número de pacientes dispensados e o percentual de pacientes não atendidos, que o sistema se torna mais congestionado ao aumentar a taxa de chegada dos pacientes.

Corroborando com essa visão, a figura 2, apresenta o percentual de cada classificação de pacientes e a sua representação no total de pacientes. Nele é possível observar que as classificações de pacientes que atravessam todo o sistema (crítico e grave) só diminui ao passar dos cenários.

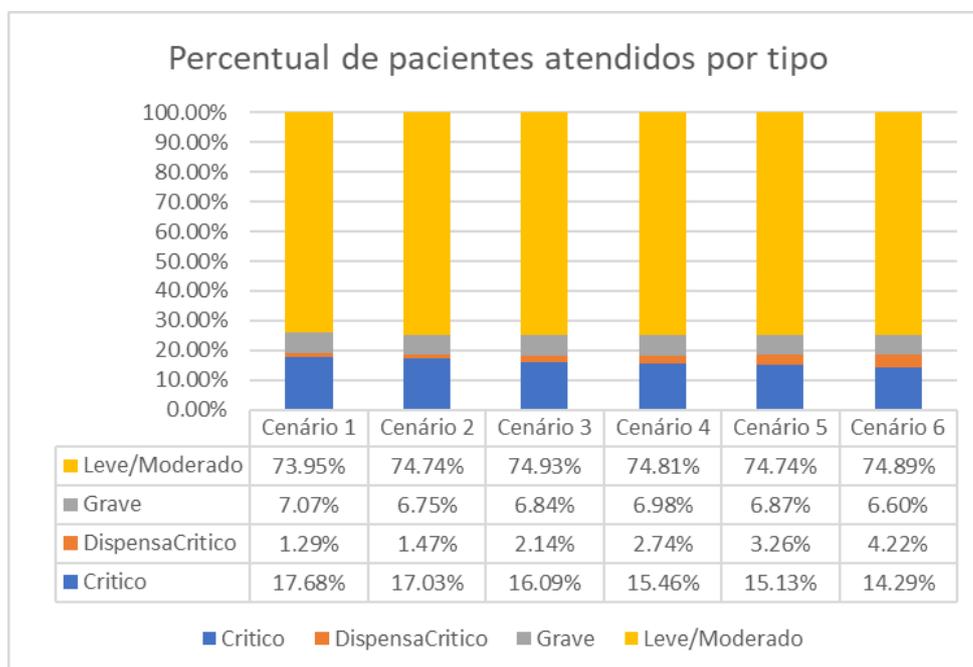


Figura 2: Percentual de pacientes por tipo

Apenas com a análise desses indicadores, seria possível afirmar que o sistema não possui capacidade para nenhuma das demandas testadas. Entretanto, para uma análise mais completa é necessário observar os indicadores de utilização de leitos e de conformidade.

Mateen et al. (2021) utilizou em seu estudo que o limite para ocupação segura de leitos é de 85%, acima dessa faixa, o gargalo do sistema passa a contribuir para o aumento da mortalidade. Dessa forma, para esse estudo, todos os cenários que apresentarem ocupação média dos leitos acima de 85%, não podem representar a capacidade máxima do hospital modular.

Ainda sobre a ocupação de leitos, Campos et al (2021) propuseram uma taxa de conformidade para que o gerenciamento do nível de qualidade fosse melhor aferido. No estudo, os autores afirmam que o nível de qualidade é mantido quando em 80% do período simulado, os resultados ficam abaixo do nível seguro.

Sendo assim, neste trabalho, será definida como a capacidade máxima do hospital modular, o cenário que apresenta variação das taxas de ocupação de leitos e de conformidade próximas aos valores propostos na literatura.

Os cenários 2 e 3 são os que mostram os indicadores mais promissores, visto que atendem aos critérios de nível de serviço do sistema. No segundo cenário, embora os leitos críticos tenham conformidade abaixo do esperado, a taxa de ocupação indica que ainda há como aumentar a demanda em um nível seguro. No mesmo cenário, os leitos graves também apresentam que é possível aumentar a demanda.

Já no cenário 3, a taxa de conformidade dos leitos críticos é muito abaixo do esperado, indicando que o sistema está além do limite seguro. Dessa forma, a capacidade máxima do hospital modular estudados está entre 340 e 372 pacientes por mês, de modo a garantir a segurança dos pacientes e manter o nível de qualidade do sistema.

5. Conclusões

O presente trabalho teve como objetivo estabelecer a capacidade máxima mensal de um hospital modular para COVID-19 e para isso utilizou como ferramenta a simulação de eventos discretos para obter indicadores do desempenho desse sistema.

Embora a aplicação SED seja bem difundida em sistemas de saúde, esse estudo apresentou novidades ao abordar o cenário da pandemia de COVID-19 e representar um fluxo exclusivo para pacientes com sintomas mais graves provocados pelo vírus. Ainda assim, a pesquisa se mostra aplicável para outras pandemias e cenários que necessitam de estudo para análise de capacidade em sistemas de saúde.

Outro aspecto novo para a comunidade científica é a utilização de uma cartilha de uma instituição de saúde para definir os recursos e layout do sistema, corroborando para o apoio de decisões a níveis de gerenciamento operacional.

Entretanto, o estudo apresenta limitações quanto ao estudo de recursos humanos, como médicos e enfermeiras, por não abordar a rotina de trabalho de cada cargo e abstrair a concorrência desses recursos por outras atividades. Todavia, essa característica pode apresentar uma nova abordagem do tema em trabalhos futuros.

A utilização de outras técnicas de simulação para predição da demanda é potencial melhoria para o estudo, visto que consideraria adaptações da demanda ao longo do tempo, se tornando úteis em cenários como os de pandemia.

Outra oportunidade de melhoria desse estudo seria o uso de alguma ferramenta de otimização para definir a capacidade ótima do hospital.

Por fim, é possível afirmar que ao longo do período deste estudo, houve grandes avanços quanto ao aprendizado das abordagens, técnicas e ferramentas para suporte à tomada de decisões em cenários emergentes como pandemias.

6. Referências

ALBAN, Andres *et al.* **ICU capacity management during the COVID-19 pandemic using a process simulation.** Springer-Verlag GmbH Germany, part of Springer Nature, vol. 46, p. 1624-1626, 2020. Disponível em: <https://doi.org/10.1007/s00134-020-060-7>. Acesso em: 19 set. 2022.

BADILLA-MURILLO F; VARGAS, B; ACUÑA. Analysis of the Installed Productive Capacity in a Medical Angiography Room through Discrete Event Simulation. **Processes.** v. 8, p 16, jun. 2020. DOI 10.3390/pr8060660. Disponível em: <https://www.mdpi.com/2227-9717/8/6/660>. Acesso em 18 out. 2021.

BRASIL. Ministério da Saúde (BR), Secretaria de Vigilância em Saúde. Painel Coronavírus. 2022. Disponível: <https://covid.saude.gov.br/>. Acesso: 19 set. 2022.

BANKS, J. (ED.). **Handbook of Simulation: Principles, Methodology, Advances, Applications, and Practice.** 1. ed. New York: John Wiley and Sons Inc., 1998.

CAMPOS T; TEODORO, G; SANTOS, C; MONTEVECHI, J. **Resposta à pandemia de Covid-19: planejamento e otimização de uma unidade de pronto atendimento utilizando simulação computacional.** Encontro Nacional de Engenharia de Produção, 40, 2020, Foz do Iguaçu, Anais [...]. Itajubá. Universidade Federal de Itajubá. 2020. Disponível em: <http://www.abepro.org.br/publicacoes/artigo.asp?e= enegep & a= 2020 & c=41152>. Acesso em: 18 out. 2021.

CHWIF, L. **Redução de modelos de simulação de eventos discretos na sua concepção: uma abordagem causal.** Tese de Doutorado. Escola Politécnica da USP. Departamento de Engenharia Mecânica, 1999.

CHWIF, L; MEDINA, A. C. **Modelagem e Simulação de Eventos Discretos: teoria e aplicações.** 4.ed. São Paulo: Ed. Bravarte, 2015.

CUDNEY, E *et. al.* A decision support simulation model for bed management in healthcare. **International Journal of Healthcare Quality Assurance.** v. 32, p 499-515, 2020. DOI 10.1108/IJHCQA-10-2017-0186. Acesso em 18 out. 2021.

CURRIE, S. M. *et al.* **How simulation modelling can help reduce the impact of COVID-19,** Journal of Simulation, n. 14, p. 83-97, 2020. Disponível em: <https://doi.org/10.1080/17477778.2020.1751570>. Acesso em: 19 set. 2022.

DESCHEPPER, M. *et al.* **Prediction of hospital bed capacity during the COVID– 19 pandemic.** BMC Health Services Research, vol. 21, p. 1-10, 18 de maio de 2021. Disponível em: <https://bmchealthservres.biomedcentral.com/articles/10.1186/s12913-021-06492-3>. Acesso em: 19/09/2021.

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**, e0254334, jul. 2021. DOI 10.1371/journal.pone.0254334. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0254334>. Acesso em 18 out. 2021. 25 p.7

LAW, A. **Simulation Modeling and Analysis.** 5. ed. New York: McGraw-Hill Education, 2014.

MATEEN, B. A. *et al.* **Hospital bed capacity and usage across secondary healthcare providers in England during the first wave of the COVID-19 pandemic: a descriptive analysis.** *BMJ Open*, vol. 11, 2021. Disponível em: <https://bmjopen.bmj.com/>. Acesso em: 19 set. 2022.

OMS - Organização Mundial da Saúde (2018). **Managing epidemics: key facts about major deadly diseases.** World Health Organization. Disponível em: <https://apps.who.int/iris/handle/10665/272442>. Licença: CC BY-NC-SA 3.0 IGO. Acesso em: 19 set de 2022.

OPAS - Organização Pan-Americana de Saúde. **Recomendações técnicas para a configuração de uma Unidade de Saúde de Emergência especializada para o tratamento de SRAG.** OPAS, 05 abr. 2020. 23 p.

OPAS - Organização Pan-Americana de Saúde.. **COVID-19: Recomendações para a configuração de uma área de triagem de pacientes com sintomas respiratórios.** Documento preliminar - Versão 2.3. 5 de abril de 2020. Disponível em: <https://iris.paho.org/handle/10665.2/52061>. Acesso em: 19 set. 2022.

RANZANI, O et al. Characterisation of the first 250000 hospital admissions for COVID-19 in Brazil: a retrospective analysis of nationwide data. **The Lancet**, v. 09, abr. 2021. DOI [https://doi.org/10.1016/S2213-2600\(20\)30560-9](https://doi.org/10.1016/S2213-2600(20)30560-9). Acesso em 27 jul. 2022

SHETI, K. et al. Modeling the impact of COVID-19 on Retina Clinic Performance. **BMC Ophthalmology**, 2021. Disponível em: <https://doi.org/10.1186/s12886-021-01955-x>. Acesso em: 19 set. 2022.

TAVAKOLI, M. *et al.* **Simulation of the COVID-19 patient flow and investigation of the future patient arrival using a time-series prediction model: a real-case study.** *International Federation for Medical and Biological Engineering*, vol. 60, p. 969-990, 2022. Disponível em: <https://doi.org/10.1007/s11517-022-02525-z>. Acessado em: 19 set. 2022.

THE GLOBAL CHANGE DATA LAB. **Our world in Data. Daily confirmed deaths.** Oxford (UK): Oxford Martin School/University of Oxford; 2021. Disponível em: <https://ourworldindata.org/grapher/confirmed-covid-19-deaths-cumulative-vs-daily?tab=table>. Acesso em: 19 set. 2022.

TURRIONI, J. B.; MELLO, C. H. P. **Metodologia de pesquisa em engenharia de produção: estratégias, métodos e técnicas para condução de pesquisas quantitativas e qualitativas.** 2012. Programa de Pós-graduação em Engenharia de Produção, Universidade Federal de Itajubá, Itajubá, 2012

WILLIAMS, E; SPERNAES, I; HOLBORN, P. **Discrete-Event Simulation Modeling of Critical Care Flow: New Hospital, Old Challenges.** *Critical Care Explorations*, vol. 2, set. 2020. DOI. 10.1097/CCE.000000000000174. Acesso em: 19 set. 2022.

YOUSEFI, M; YOUSEFI, M; FOGLIATTO, F. Simulation-based optimization methods applied in hospital emergency departments: A systematic review. **Simulation: Transactions of the Society for Modeling and Simulation International** 96(10), v. 96, p 791-806, jul. 2020. DOI. [10.1177/0037549720944483](https://doi.org/10.1177/0037549720944483). Disponível em: <https://journals.sagepub.com/doi/10.1177/0037549720944483>. Acesso em: 18 out. 2021.

ZHU, W. *et al.* **Establishing and Managing a Temporary Coronavirus Disease 2019 Specialty Hospital in Wuhan, China.** *Anesthesiology*, vol. 30, p 1-7, Junho de 2020. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7155903/>. Acesso em: 19 set. 2022.