

PLANEJAMENTO DE HOSPITAIS TEMPORÁRIOS POR MEIO DE OTIMIZAÇÃO VIA SIMULAÇÃO: UMA ABORDAGEM BASEADA EM METAMODELAGEM ADAPTATIVA

João Victor Soares do Amaral¹

joao.victoramara196@hotmail.com

Carlos Henrique dos Santos²

carlos.henrique@unifal-mg.edu.br

José Arnaldo Barra Montevechi¹

montevechi@unifei.edu.br

Rafael de Carvalho Miranda¹

rafael.miranda@unifei.edu.br

¹Universidade Federal de Itajubá

Avenida BPS, 1303, Itajubá – MG

²Universidade Federal de Alfenas

Rodovia José Aurélio Vilela, 11999, Poços de Caldas – MG

RESUMO

Hospitais temporários são essenciais para aliviar a sobrecarga do sistema de saúde em emergências, como pandemias e desastres naturais. No entanto, seu planejamento exige estratégias eficazes para alocação de recursos e otimização operacional. Este estudo apresenta a Otimização de Simulação Baseada em Metamodelagem Adaptativa (AMSO), uma abordagem inovadora que utiliza técnicas avançadas, como Árvores de Reforço Gradiente com Bagging, otimização de hiperparâmetros e metaheurísticas. Aplicada a um hospital temporário no Brasil durante a COVID-19, a AMSO superou métodos tradicionais, como EGO e GA, obtendo resultados equivalentes à GA com menos experimentos e menor tempo computacional. Essa eficiência destaca a AMSO como uma ferramenta promissora para o planejamento otimizado de hospitais temporários, reduzindo o tempo de internação dos pacientes e contribuindo para uma gestão de saúde mais ágil e eficaz.

PALAVRAS CHAVE. Metamodelagem. Simulação a Eventos Discretos. Otimização.

Tópicos. SIM - Simulação

ABSTRACT

Temporary hospitals are essential to alleviating healthcare system overload during emergencies such as pandemics and natural disasters. However, their planning requires effective strategies for resource allocation and operational optimization. This study presents Adaptive Metamodeling-Based Simulation Optimization (AMSO), an innovative approach that utilizes advanced techniques such as Bagging Gradient Boosted Trees, hyperparameter optimization, and metaheuristics. Applied to a temporary hospital in Brazil during COVID-19, AMSO outperformed traditional methods like EGO and GA, achieving results equivalent to GA with fewer experiments and reduced computational time. This efficiency highlights AMSO as a promising tool for optimized temporary hospital planning, minimizing patient length of stay and contributing to a more agile and effective healthcare management system.

KEYWORDS. Metamodeling. Discrete Event Simulation. Optimization.

Paper topics. Sim - Simulation

1. Introdução

A indústria da saúde é uma das maiores globalmente e prioriza a qualidade dos serviços, pois afeta diretamente a segurança e a satisfação dos pacientes [Bhat et al. 2014]. Para aumentar a eficiência, clínicas e hospitais buscam otimizar processos e reduzir custos, mantendo padrões essenciais de atendimento. Além disso, diferentes instalações de saúde têm requisitos específicos que influenciam a tomada de decisão. Nesse contexto, hospitais temporários (HTs) surgem como alternativa crucial aos hospitais convencionais, especialmente em emergências como pandemias, desastres naturais e guerras [Fang et al. 2020].

HTs são estruturas improvisadas que necessitam de ajustes e geralmente são montadas em espaços públicos, como estádios, centros de exposições e praças [Shu et al. 2020]. Eles desempenham um papel essencial em emergências, atuando como alternativa quando os hospitais convencionais atingem sua capacidade máxima. Ao ampliar a admissão de pacientes, os HTs garantem atendimento adequado e oportuno [Lee 2020]. Essas instalações variam em função, indo desde unidades de triagem e avaliação inicial até centros de cuidados intensivos [Lee 2020], [Yuan et al. 2020]. No entanto, apesar dos benefícios, desafios de planejamento precisam ser enfrentados. A alocação eficiente de recursos é essencial para a sustentabilidade do sistema de saúde [Wu et al. 2020], especialmente para estruturas temporárias, destacando a necessidade de técnicas de suporte à decisão.

Dentre as diversas técnicas que podem auxiliar no planejamento de HTs, a simulação tem ganhado destaque por sua versatilidade e capacidade analítica na tomada de decisões em saúde [Gunal e Pidd 2010]. Estudos destacam seu uso no planejamento de recursos e layout, no agendamento de funcionários e na otimização do fluxo de pacientes [Campos et al. 2022]. Por meio de modelos virtuais, a simulação possibilita a avaliação de cenários, a otimização de decisões e a análise de impactos. No entanto, métodos tradicionais de simulação enfrentam limitações em HTs devido ao tempo necessário para análise de cenários e tomada de decisão ideal [Gunal e Pidd 2010], [Currie et al. 2020]. Para solucionar isso, a metamodelagem surge como uma alternativa viável para otimização de simulação mais rápida [Campos et al. 2022].

A metamodelagem eleva o problema a um nível de abstração mais alto [Amaral et al. 2022a]. Essa abordagem busca definir e aproximar a relação entre os insumos e os resultados de um modelo de simulação, criando uma representação simplificada que auxilia na avaliação de soluções potenciais durante a otimização [Rojas-Gonzalez e Van Nieuwenhuyse 2020]. Uma vez desenvolvida e validada, a metamodelagem pode substituir o modelo de simulação original na tomada de decisão, reduzindo significativamente o tempo computacional necessário para a convergência da otimização [Parnianifard et al. 2020]. Uma extensão importante desse método é a Metamodelagem Adaptativa (MA), também conhecida como "*infill-search*", que aloca estrategicamente experimentos em regiões promissoras. Inicialmente, poucos experimentos geram metamodelos básicos, que são refinados iterativamente à medida que mais dados são coletados [Amaral et al. 2022a]. Essa abordagem é especialmente eficaz na otimização de modelos complexos onde a execução de muitas simulações é computacionalmente cara ou inviável.

Aplicações da MA podem ser encontradas em diversos estudos e, embora tenha demonstrado resultados promissores na literatura, destacamos seu uso no planejamento de HTs, pois permite diretrizes mais rápidas e eficientes para a tomada de decisão. Assim, este estudo apoia o planejamento de um HT voltado para situações críticas de saúde, como pandemias. Para isso, propomos uma nova estrutura, chamada "Otimização de Simulação Baseada em Metamodelagem Adaptativa" (AMSO), que integra conceitos de MA com *Bagging*, *Gradient Boosted Trees* (GBT), otimização de hiperparâmetros (HPO) e metaheurísticas para resolver problemas de otimização de simulação. Dessa forma, esta pesquisa contribui tanto para a literatura acadêmica sobre MA quanto para aplicações práticas no planejamento e na gestão de hospitais temporários, que exigem decisões cada vez mais ágeis e eficientes.

O restante do artigo está estruturado em quatro seções. A Seção 2 apresenta a fundamentação teórica, enquanto a Seção 3 descreve os materiais e métodos adotados. A Seção 4

explora a implementação da abordagem proposta por meio de um estudo de caso real, um HT planejado para situações críticas de saúde. Por fim, a Seção 5 resume os achados.

2. Revisão de Literatura

Segundo [Misra e Maurya 2021], desastres naturais estão se tornando mais frequentes e complexos, impactando severamente os serviços de saúde. Para eles, eventos como enchentes, terremotos e ciclones destroem infraestruturas, interrompem o fornecimento de suprimentos essenciais e aumentam o risco de surtos de doenças infecciosas. Um desafio crítico é a escassez de recursos de saúde, medicamentos, leitos hospitalares e profissionais médicos. Nesse contexto, hospitais temporários (HTs) desempenham um papel vital na resposta a desastres, fornecendo atendimento médico imediato, controlando a disseminação de doenças e reduzindo a pressão sobre os hospitais permanentes. Sua implantação estratégica melhora a preparação para emergências e fortalece a resiliência em regiões afetadas por desastres. [Santos et al. 2019] revelam que HTs devem ser projetados para oferecer atendimento médico eficiente, garantindo a capacidade de lidar com a demanda de pacientes.

Embora os HTs possam ser uma boa alternativa aos hospitais convencionais, [Yuan et al. 2020] afirmam que há desafios a serem superados, pois a construção de um HT exige a definição de diversos aspectos, como layout, configuração, modo de trabalho dos profissionais de saúde, gerenciamento de pacientes, critérios de admissão e alta, além da operação hospitalar. Além disso, planejar HTs de maneira eficiente pode ser ainda mais desafiador, pois as regiões onde ocorrem desastres podem apresentar limitações em serviços essenciais, como eletricidade, água potável, comunicação, transporte e abastecimento de alimentos e medicamentos [Santos et al. 2019].

[Kheybari et al. 2023] destacam que as decisões sobre o planejamento de HTs devem ser tomadas de forma mais ágil em comparação aos hospitais tradicionais. Nesse caso, várias variáveis devem ser consideradas, como localização, recursos físicos e humanos disponíveis, entre outras. A implementação de hospitais envolve altos custos para governos e partes interessadas, sendo essencial tomar decisões eficientes, especialmente em contextos de recursos limitados [Zolfani et al. 2020]. Considerando essa necessidade, diversos estudos propõem técnicas e ferramentas para apoiar o planejamento de HTs, incluindo os trabalhos de [Kheybari et al. 2023], [Misra e Maurya 2021] e [Zolfani et al. 2020], entre outros.

Entre as decisões relacionadas ao planejamento de HTs, destacamos vários objetivos. [Zolfani et al. 2020] e [Kheybari et al. 2023] utilizaram abordagens multicritério para avaliar melhores localizações para HTs, enquanto [Gu et al. 2020] analisaram aspectos técnicos por meio de simulação computacional. Também com ferramentas de simulação, [Campos et al. 2022] examinaram métricas de segurança em HTs, incluindo fluxos de pacientes e equipe, otimização de layout e estratégias operacionais. Por fim, destacamos abordagens de otimização de simulação (OS), como a proposta por [Campos et al. 2022], que planejaram recursos físicos e humanos para HTs.

A OS desempenha um papel crucial na otimização de sistemas complexos, onde a função objetivo (FO) e restrições estão diretamente relacionadas a um modelo de simulação, permitindo uma análise mais precisa do comportamento do sistema [Belgin 2019]. Em OS, [Fu 2002] afirma que a simulação fornece a estrutura para avaliar o sistema em diferentes cenários, enquanto as técnicas de otimização permitem a busca pelos melhores conjuntos de decisões ou parâmetros que maximizam ou minimizam a FO. Portanto, como a OS viabiliza a otimização de processos, o design eficiente de sistemas, a alocação de recursos e a tomada de decisão estratégica, contribuindo para maior eficiência, redução de custos e melhorias significativas no desempenho dos sistemas estudados.

No entanto, embora a OS tenha se destacado como uma valiosa ferramenta de suporte à decisão, quanto maior for a complexidade do sistema estudado, mais tempo será necessário para a otimização [Amaral et al. 2024]. Nesses casos, para obter resultados de qualidade dentro de prazos adequados, o problema deve ser elevado a um nível mais abstrato, conhecido como metamodelo [Parnianifard et al. 2020]. A metamodelagem é uma abordagem comumente utilizada para

desenvolver um modelo representativo de um modelo de simulação. O metamodelo captura a relação entre os valores das variáveis de decisão e os resultados da simulação, proporcionando uma estimativa da função objetivo em um tempo significativamente menor do que a própria simulação.

Assim, metamodelos podem ser definidos como representações matemáticas usadas para substituir modelos de simulação complexos que seriam caros de executar [Rojas-Gonzalez e Van Nieuwenhuysen 2020]. Um modelo de simulação é uma abstração de um sistema real e, de forma semelhante, um metamodelo é uma abstração de um modelo de simulação (um modelo de outro modelo), tornando as avaliações mais simples e rápidas, embora representem sistemas reais com menor precisão [Parnianifard et al. 2020].

Segundo [Amaral et al. 2022a], estruturas de metamodelagem podem ser classificadas em duas categorias: a estratégia de design experimental fixo (*one-shot*) e a estratégia de design incremental ou adaptativo (*infill-search*). A estratégia de experimentação fixa envolve a seleção de um único conjunto de amostras de tamanho w no início do projeto, com o metamodelo sendo treinado apenas nessas amostras.

Por outro lado, a estratégia de metamodelagem adaptativa (MA) começa com uma amostra inicial de tamanho ξ , sobre a qual o metamodelo é treinado e otimizado para avaliar a precisão e a direção da região onde se encontra o ótimo. O conjunto de dados é então incrementado com um novo conjunto de amostras de tamanho δ_i a cada iteração do algoritmo. O metamodelo é retreinado com a base experimental atualizada de tamanho $\xi_{i+1} = \xi_i + \delta_i$, onde i representa o número de iterações [Razali et al. 2020]. A seleção de pontos a serem simulados e adicionados em cada iteração é determinada pela chamada Função de Aquisição.

Nesse contexto, vários algoritmos de metamodelagem surgiram na literatura para criar metamodelos mais precisos, como Regressão Polinomial, *Kriging*, *Radial Basis Function* (RBF) e Redes Neurais Artificiais (RNA). Em uma revisão sistemática da literatura conduzida por [Amaral et al. 2022c], *Kriging*, Regressão Polinomial, RNA, *Gradient Boosted Trees* (GBT), *Random Forest*, RBF e *Support Vector Machine* foram identificadas como os principais metamodelos utilizados na OS. Focando na metamodelagem com design experimental fixo para otimizar modelos DES, [Amaral et al. 2022a] e [Amaral et al. 2022b] compararam algoritmos de metamodelagem em diversos problemas de manufatura e concluíram que o algoritmo GBT obteve o melhor desempenho e flexibilidade, demonstrando o melhor equilíbrio entre métricas de erro, valor ótimo alcançado e tempo de treinamento.

3. Materiais e Métodos

3.1. Objeto de Estudo: Hospital Temporário

O objeto de estudo examinado neste artigo foca em um hospital temporário (HT) projetado para atender pacientes durante a pandemia de COVID-19 no Brasil. O principal desafio deste sistema é a alta variabilidade na demanda de pacientes, que oscila conforme a gravidade dos sintomas e as taxas de infecção. O planejamento de recursos torna-se especialmente desafiador em situações emergenciais, pois os sistemas de saúde tradicionais frequentemente enfrentam dificuldades para gerenciar aumentos repentinos na demanda. O modelo de simulação foi desenvolvido para analisar o fluxo de pacientes e otimizar a alocação de recursos, considerando tanto variáveis controláveis, como o número de leitos e equipe disponível, quanto fatores incontroláveis, como chegadas de pacientes e a proporção de casos positivos de COVID-19.

Neste caso, optamos por um modelo de Simulação de Eventos Discretos (SED), pois é o tipo de simulação mais comum em estudos de saúde [Salleh et al. 2017], fornecendo diretrizes estabelecidas para analisar sistemas complexos e interconectados. Além disso, para construir o modelo, dados operacionais (tempo de processo, fluxo de pacientes etc.) foram coletados do principal hospital da região onde o HT foi planejado, enquanto informações sobre a doença foram obtidas por meio de relatórios de órgãos de saúde nacionais e internacionais. Mais detalhes sobre o modelo podem ser consultados em [Campos et al. 2022].

O HT foi estruturado em diversas áreas, incluindo triagem, diagnóstico, medicação, unidade de internação de curta duração e uma seção de atendimento de emergência para estabilizar

casos críticos. Os pacientes foram categorizados de acordo com a gravidade, o que influencia seu fluxo dentro do hospital. A otimização teve como objetivo determinar os recursos necessários para atender à média-alvo de tempo de internação (LOS) do HT. O LOS é uma métrica-chave de desempenho na área da saúde, representando o período entre a admissão e a alta do paciente. Um LOS menor aumenta a satisfação dos pacientes e melhora a capacidade do hospital de atender mais indivíduos de maneira eficiente.

As variáveis de decisão neste problema incluem equipe hospitalar: número de médicos (x_1), técnicos de enfermagem (x_2), funcionários de limpeza e higienização (x_3), enfermeiros de triagem (x_4) e enfermeiros da unidade de internação de curta duração (x_5). Além disso, são considerados recursos físicos: estações de triagem (x_6), leitos de emergência (x_7), salas de exame (x_8), postos de medicação (x_9) e leitos da unidade de curta duração (x_{10}). Os limites inferior e superior para essas variáveis são $l = [1 \ 5 \ 1 \ 1 \ 1 \ 1 \ 3 \ 10 \ 10]^T$ e $u = [5 \ 10 \ 5 \ 3 \ 3 \ 3 \ 5 \ 10 \ 20 \ 20]^T$ respectivamente. A Tabela 1 apresenta as variáveis de decisão e seus respectivos limites.

Tabela 1: Variáveis de Decisão e Limites

Variável	Descrição	Limite Inferior (l)	Limite Superior (u)
x_1	Número de médicos	1	5
x_2	Número de técnicos de enfermagem	5	10
x_3	Número de funcionários de limpeza	1	5
x_4	Número de enfermeiros de triagem	1	3
x_5	Número de enfermeiros da unidade de curta duração	1	3
x_6	Número de estações de triagem	1	3
x_7	Número de leitos de emergência	1	5
x_8	Número de salas de exame	3	10
x_9	Número de postos de medicação	10	20
x_{10}	Número de leitos da unidade de curta duração	10	20

A função objetivo ($F(x)$) é dada pela diferença absoluta entre o LOS médio dos pacientes atendidos no hospital e o LOS-alvo esperado para o HT (representando o nível de serviço desejado). Em outras palavras, se o LOS for maior que o alvo, isso indica que o hospital não está atingindo o nível de serviço esperado, possivelmente devido à insuficiência de recursos. Por outro lado, se o LOS for menor que o alvo, significa que o hospital está alocando mais recursos do que o necessário, gerando custos desnecessários e potencialmente desviando funcionários de outras unidades do sistema de saúde municipal. Portanto, o objetivo deste problema é minimizar essa diferença, conforme expresso na Equação (1).

$$F(x) = |LOS_{average} - LOS_{target}| \quad (1)$$

Na Eq. (1), $F(x)$ representa a diferença absoluta entre o LOS médio dos pacientes atendidos durante a simulação ($LOS_{médio}$) e o LOS exigido pelo sistema de saúde (LOS_{alvo}), que é de 146 minutos. O objetivo é minimizar a expectativa da função objetivo, calculada como a média de 10 repetições do modelo de simulação ($\tilde{\phi}$) com diferentes sementes aleatórias, ou seja, $f(x) = E_{\omega} \{ \tilde{\phi}[F(x, \omega)] \}$. O modelo matemático é dado pela minimização da função objetivo na Equação (2), sujeita às restrições apresentadas nas Equações (3) e (4), relacionadas ao espaço de busca.

$$f(x) = E_{\omega} \{ \tilde{\phi}[F(x, \omega)] \} \quad (2)$$

Sujeito a:

$$l_i \leq x_i \leq u_i \quad (3)$$

$$x_i \in Z, \forall i \in \{1, \dots, 10\} \quad (4)$$

É importante notar que o valor da função objetivo é derivado da média das repetições do modelo SED, representado por $\tilde{\phi}$. Esse modelo incorpora diversas restrições operacionais,

estocasticidade, interdependência e complexidades que não estão explicitadas no modelo matemático. Uma visualização 3D do modelo de simulação é apresentada na Figura 1.




Figura 1: Modelo SED do HT desenvolvido no FlexSim®

3.2. Método Proposto: Adaptive Metamodeling-based Simulation Optimization (AMSO)

A abordagem apresentada neste estudo foi inicialmente proposta por [Amaral et al. 2024] para problemas industriais e este artigo estendeu essa estrutura para resolver o problema de alocação de recursos em um hospital temporário (HT). Essa abordagem, chamada AMSO, utiliza o conceito de Bagging combinado com o algoritmo GBT (atuando como modelo base), em uma técnica conhecida como *Bagging-based Gradient Boosted Trees* (B-GBT) [Louk e Tama 2023]. Bagging e GBT contribuem com pontos fortes distintos para modelos de aprendizado de máquina. Bagging, ao realizar a média das previsões de vários modelos, reduz efetivamente a variância e melhora a precisão preditiva [Pérez-Rodríguez et al. 2023]. Além disso, aumenta a robustez do modelo ao minimizar a influência de valores discrepantes e lidar com dados desbalanceados. Por outro lado, GBT melhora a previsão ao focar iterativamente na correção dos erros cometidos por modelos anteriores, reduzindo o viés. Quando Bagging é combinado com GBT, o modelo resultante se beneficia tanto da redução da variância quanto do viés, levando a um desempenho preditivo superior e maior resiliência contra irregularidades nos dados.

Além disso, em abordagens adaptativas, a definição da Função de Aquisição é um fator decisivo para o sucesso da aplicação. Neste caso, a abordagem proposta emprega a função de aquisição *Balanced Expected Improvement* (BEI). Adicionalmente, o Algoritmo Genético (AG) é utilizado para otimizar a função BEI em cada iteração do algoritmo. AG é uma metaheurística inspirada na teoria biológica da seleção natural, inicialmente conceituada por [De Jong 1975].

O AMSO tem como base cinco técnicas principais: *Latin Hypercube Design* (LHD), otimização de hiperparâmetros via Algoritmo Genético, *Bagging-based Gradient Boosted Trees* e Algoritmo Genético para otimização da função de aquisição (*Balanced Expected Improvement*). A Figura 2 apresenta a estrutura do AMSO.




Figura 1: *Framework Adaptive Metamodeling-based Simulation Optimization*

Na fase de inicialização, amostras iniciais são geradas usando *Latin Hypercube Design*, garantindo uma distribuição uniforme de pontos no espaço de solução. As soluções amostradas são avaliadas em um modelo de simulação com múltiplas réplicas, executadas em paralelo para otimizar o tempo de processamento. Após essa etapa, os hiperparâmetros do modelo GBT são otimizados usando AG e validados por meio de *k-fold cross-validation* para obter um metamodelo adequado ao conjunto de dados experimental. A normalização dos dados (média 0 e desvio padrão 1) é aplicada para garantir a consistência nos cálculos. O modelo resultante é adotado como o modelo base para a fase adaptativa.

Na fase adaptativa, o metamodelo B-GBT é atualizado iterativamente com novos pontos gerados utilizando a função de aquisição BEI, que combina estratégias de exploração e exploração no espaço de solução. O critério de busca é definido com base no equilíbrio entre o coeficiente de determinação (R^2) do metamodelo e suas previsões. O ponto ótimo é selecionado usando AG e posteriormente avaliado no modelo de simulação, com os resultados incorporados ao conjunto de treinamento para refinar o metamodelo. A função BEI é apresentada na Equação (5).

$$BEI(x) = (1 - \lambda)\sigma\phi\left(\frac{f_{min} - \hat{f}(x)}{\sigma}\right) + \lambda\hat{f}(x) \quad (5)$$

Onde ϕ representa a função de densidade de probabilidade, f_{min} é o menor valor observado no conjunto de treinamento, $\hat{f}(x)$ e σ são a previsão e o desvio padrão da previsão do metamodelo para o ponto x . λ é uma variável binária definida em cada iteração do AMSO pela Equação (6), alternando a busca entre exploração (primeiro termo da função BEI) e exploração (segundo termo) com base no R^2 do metamodelo e na variável aleatória $\rho \sim Uniform(0.85, 1.00)$.

$$\lambda = \begin{cases} 1, & \text{se } \rho < R^2 \\ 0, & \text{caso contrário} \end{cases} \quad (6)$$

O processo iterativo continua até que um dos critérios de parada seja atendido. O critério de parada utilizado neste estudo foi o número máximo de iterações ($i < I_{max}$), definido pelo usuário. Ao final, a melhor solução encontrada é reportada como o resultado do problema de otimização, fornecendo um modelo eficiente para a tomada de decisão.

Como referência para a estrutura AMSO, também aplicamos a *Efficient Global Optimization* (EGO) [Bouhlel et al. 2019] e métodos de otimização AG do pacote *geneticalgorithm2* em Python. Destacamos que este estudo não tem como objetivo realizar uma comparação sistemática entre vários métodos de otimização, mas fornecer uma referência para avaliar o desempenho do AMSO no problema apresentado. Os algoritmos foram implementados em Python 3.0, com controle direto do ambiente SED (FlexSim 22.2) e simulações paralelas. Todas as aplicações foram desenvolvidas em um sistema Windows 64 bits com um processador Intel i7-3770 (4 núcleos, 3,40 GHz), 24 GB de RAM e uma GPU NVIDIA GeForce GTX 660. Além disso, para avaliar a robustez da estrutura, todas as execuções de otimização foram repetidas dez vezes com diferentes sementes aleatórias.

4. Resultados

Conforme destacado na Seção 3, para avaliar a eficácia da estrutura AMSO, realizamos uma análise comparativa com dois métodos de otimização amplamente utilizados: EGO e AG. No caso do EGO, a função de aquisição Expected Improvement (EI) foi aplicada, utilizando o mesmo tamanho de amostra inicial e o número máximo de iterações definidos para o AMSO.

Considerando os resultados obtidos com AMSO e EGO, a Figura 3 apresenta os gráficos de convergência para ambos os métodos.




Figura 3: Gráfico de convergência do EGO (a) e AMSO (b)

Com um orçamento de simulação de 100 experimentos, a Figura 3 (a) ilustra a média e as barras de erro dos resultados de convergência obtidos pelo EGO. O valor médio da função objetivo (FO) alcançado pelo EGO foi 35,09, com um desvio padrão de 2,77. Entre as repetições, a melhor solução encontrada pelo EGO foi $x^* = [1 \ 7 \ 2 \ 3 \ 2 \ 1 \ 2 \ 5 \ 11 \ 16]$, resultando em $f(x^*) = 30.22$. Por

outro lado, conforme mostrado na Figura 3 (b), a estrutura AMSO proposta obteve um valor médio de FO de 25,13, com um desvio padrão de 3,04. A melhor solução obtida entre as repetições foi $x^* = [1\ 6\ 5\ 1\ 3\ 3\ 5\ 4\ 12\ 13]$, com $f(x^*) = 22.39$.

Conforme apresentado na Figura 4 (a), o teste de Mann-Whitney comparando os dois *frameworks* confirmou que o AMSO superou significativamente o EGO (p-valor = 0,00), com diferenças de 9,27 na mediana e 9,95 na média dos valores da função objetivo. Além disto, conforme mostrado na Figura 4 (b), nenhuma diferença estatisticamente significativa foi observada no tempo computacional exigido pelo EGO e pelo AMSO.




Figura 4: *Boxplot* com o melhor valor encontrado após 100 experimentos (a) e o tempo gasto nas otimizações (b)

Diferentemente do AMSO e do EGO, o AG não foi restrito ao mesmo orçamento experimental, mas recebeu um número considerável de gerações para avaliar sua capacidade de superar os resultados do AMSO. O AG foi configurado com uma população de 20 indivíduos e um máximo de 100 iterações, utilizando os parâmetros padrão do pacote *geneticalgorithm2* em Python.

A Figura 6 apresenta a média e as barras de erro da convergência do AG ao longo de 10 repetições. Notavelmente, em todas as execuções, o AG convergiu antes de atingir 100 iterações, com a convergência ocorrendo entre 25 e 41 gerações.




Figura 5: Gráfico de convergência do AG

Conforme destacado na Figura 5, o AG exigiu 264 experimentos para se estabilizar em um valor médio da função objetivo (FO) de 25,61, um resultado que permaneceu inalterado até a geração final, com 580 experimentos. O teste de Mann-Whitney indicou que esse resultado, embora ligeiramente superior, foi estatisticamente equivalente ao desempenho do AMSO com apenas 100 experimentos (p-valor = 0,821). Em termos de tempo de convergência, o AG demandou em média 16.916 segundos, quase três vezes o tempo necessário para o AMSO (5.888 segundos). Semelhante

ao AMSO, a melhor solução encontrada pelo AG ao longo das 10 repetições foi $x^* = [1 \ 10 \ 3 \ 1 \ 1 \ 3 \ 4 \ 4 \ 20 \ 12]$, com $f(x^*) = 22.39$.

É importante enfatizar que o objetivo desta comparação não é estabelecer a superioridade do AMSO sobre o AG, pois ambos pertencem a classes distintas de algoritmos de otimização, cada um com características e aplicações únicas. No entanto, os resultados demonstram que o AMSO atinge um desempenho comparável ao AG, exigindo significativamente menos experimentos e menor tempo computacional, o que destaca a eficiência da estrutura proposta para esta aplicação.

A melhor solução obtida pelo AMSO recomenda um quadro de 17 funcionários por turno de trabalho, composto por um médico, seis técnicos de enfermagem, cinco funcionários de limpeza, um enfermeiro de triagem e três enfermeiros da unidade de curta duração. Em relação ao layout e equipamentos, sugere-se que o HT disponha de três estações de triagem, cinco leitos de emergência, quatro salas de exame, doze postos de medicação e treze leitos na unidade de curta duração. Com essa configuração, o modelo previu um LOS médio de 123,61 minutos, 22,39 minutos abaixo do nível de serviço desejado de 146 minutos, evidenciando a capacidade do HT de atender os pacientes de maneira eficiente.

5. Conclusões

Hospitais temporários têm se mostrado indispensáveis para enfrentar crises na área da saúde, como pandemias, desastres naturais e outras emergências. Essas instalações fornecem um suporte essencial para sistemas de saúde sobrecarregados, garantindo atendimento adequado e oportuno aos pacientes. No entanto, seu planejamento e implementação apresentam desafios únicos, como alocação de recursos, otimização de layout e eficiência operacional. Essas complexidades demandam métodos avançados de apoio à decisão para aprimorar sua efetividade e sustentabilidade.

Nesse contexto, a estrutura AMSO foi introduzida como uma solução inovadora para melhorar o planejamento e a gestão de recursos em HTs. Ao utilizar metodologias avançadas, como Bagging, GBT, otimização de hiperparâmetros e metaheurísticas, AMSO supera as limitações das técnicas tradicionais de otimização por simulação. Sua abordagem adaptativa não apenas reduz o tempo computacional, mas também garante uma exploração robusta dos espaços de solução, tornando-a particularmente adequada para sistemas complexos e dinâmicos como os HTs.

A aplicação da estrutura AMSO em um estudo de caso real, um HT projetado para atender pacientes com COVID-19, evidenciou seu potencial. Comparado a métodos tradicionais, como EGO e AG, AMSO obteve resultados superiores com menos experimentos. Especificamente, AMSO alcançou um valor médio de função objetivo de 25,13 ($\pm 3,04$), superando o EGO, que obteve 35,09 ($\pm 2,77$). Além disso, AMSO identificou sua melhor solução com um valor de FO de 22,39 após 100 experimentos, enquanto o AG precisou de 264 experimentos para convergir a um resultado semelhante. Esses achados demonstram a eficiência e eficácia da AMSO na otimização da alocação de recursos em HTs, minimizando o tempo de internação dos pacientes.

Apesar dos resultados promissores, o estudo também apontou oportunidades para pesquisas e desenvolvimentos futuros. Por exemplo, a integração de dados em tempo real na estrutura AMSO poderia aprimorar sua adaptabilidade a cenários dinâmicos. Explorar sua aplicação em outras áreas da saúde, como planejamento de hospitais permanentes ou logística de resposta a desastres, também pode ampliar seu impacto. Além disso, o refinamento da função de aquisição e dos processos de otimização de hiperparâmetros pode proporcionar resultados ainda melhores para problemas mais complexos.

Além disso, estudos futuros poderiam investigar a escalabilidade da AMSO em sistemas de saúde de maior porte ou sua integração com outras tecnologias emergentes, como inteligência artificial e Internet das Coisas. Esses avanços podem viabilizar o desenvolvimento de sistemas abrangentes de apoio à decisão, capazes de enfrentar os desafios multifacetados da saúde moderna.

6. Agradecimentos

Agradecemos ao CNPq, CAPES e FAPEMIG pelo apoio a esta pesquisa.

Referências

- Amaral, J. V. S. do, et al. (2022a). Data envelopment analysis for algorithm efficiency assessment in metamodel-based simulation optimization. *International Journal of Advanced Manufacturing Technology*, 121(11–12):7493–7507.
- Amaral, J. V. S. do, et al. (2022b). Data envelopment analysis for algorithm efficiency assessment in metamodel-based simulation optimization. *International Journal of Advanced Manufacturing Technology*, 121(11–12):7493–7507.
- Amaral, J. V. S. do, et al. (2022c). Metamodel-based simulation optimization: a systematic literature review. *Simulation Modelling Practice and Theory*, 114.
- Amaral, J. V. S. do, et al. (2024). Adaptive metamodeling-based simulation optimisation. *Journal of the Operational Research Society*.
- Belgin, O. (2019). Data envelopment analysis-based metamodeling for multi-objective simulation optimization in a manufacturing line. *Sigma Journal of Engineering and Natural Sciences*, 37(4):1435–1449.
- Bhat, S., Gijo, E. V. e Jnanesh, N. A. (2014). Application of lean six sigma methodology in the registration process of a hospital. *International Journal of Productivity and Performance Management*, 63(5):613–643.
- Campos, A. T., Gabriel, G. T., Torres, A. F., Santos, C. H. e Montevechi, J. A. B. (2022). Integrating computer simulation and the normalized normal constraint method to plan a temporary hospital for COVID-19 patients. *Journal of the Operational Research Society*.
- Coelho, G. F. e Pinto, L. R. (2018). Kriging-based simulation optimization: an emergency medical system application. *Journal of the Operational Research Society*, 69(12):2006–2020.
- Currie, C. S. M., Fowler, J. W., Kotiadis, K., Monks, T., Onggo, B. S., Robertson, D. A. e Tako, A. A. (2020). How simulation modelling can help reduce the impact of COVID-19. *Journal of Simulation*, 14(2):83–97.
- De Jong, K. A. (1975). Analysis of the behavior of a class of genetic adaptive systems. Tese – University of Michigan, Hampton, Virginia.
- Fanelli, D. e Piazza, F. (2020). Analysis and forecast of COVID-19 spreading in China, Italy, and France. *Chaos, Solitons & Fractals*, 134:109761.
- Fang, D., Pan, S., Li, Z., Yuan, T., Jiang, B., Gan, D., Sheng, B., Han, J., Wang, T. e Liu, Z. (2020). Large-scale public venues as medical emergency sites in disasters: lessons from COVID-19 and the use of Fangcang shelter hospitals in Wuhan, China. *BMJ Global Health*, 5(6):e002815.
- Fu, M. C. (2002). Optimization for simulation: theory vs. practice. *INFORMS Journal on Computing*, 14(3):192–215.
- Gu, D., Zheng, Z., Zhao, P., Xie, L., Xu, Z. e Lu, X. (2020). High-efficiency simulation framework to analyze the impact of exhaust air from COVID-19 temporary hospitals and its typical applications. *Applied Sciences*, 10(11).

Günel, M. M. e Pidd, M. (2010). Discrete event simulation for performance modelling in health care: a review of the literature. *Journal of Simulation*, 4(1):42–51.

Kheybari, S., Ishizaka, A. e Salamiad, A. (2023). A new hybrid risk-averse best-worst method and portfolio optimization to select temporary hospital locations for COVID-19 patients. *Journal of the Operational Research Society*, 74(2):509–526.

Lee, J. (2020). COVID-19 screening center: how to balance between the speed and safety? *Journal of Korean Medical Science*, 35(15).

Louk, M. H. L. e Tama, B. A. (2023). Dual-IDS: a bagging-based gradient boosting decision tree model for network anomaly intrusion detection system. *Expert Systems with Applications*, 213.

Misra, A. K. e Maurya, J. (2021). Modeling the importance of temporary hospital beds on the dynamics of emerged infectious disease. *Chaos*, 31(10).

Parnianifard, A., et al. (2020). A new approach for low-dimensional constrained engineering design optimization using design and analysis of simulation experiments. *International Journal of Computational Intelligence Systems*, 13(1):1663–1678.

Pérez-Rodríguez, J., Fernández-Navarro, F. e Ashley, T. (2023). Estimating ensemble weights for bagging regressors based on the mean–variance portfolio framework. *Expert Systems with Applications*, 229:120462.

Razali, C. M. C., et al. (2020). Adaptive infill sampling strategy for metamodeling: challenge and future research directions. *Bulletin of Electrical Engineering and Informatics*, 9(5):2020–2029.

Rojas-Gonzalez, S. e Van Nieuwenhuyse, I. (2020). A survey on kriging-based infill algorithms for multiobjective simulation optimization. *Computers and Operations Research*, 116:104869.

Salleh, S., Thokala, P., Brennan, A., Hughes, R. e Booth, A. (2017). Simulation modelling in healthcare: an umbrella review of systematic literature reviews. *PharmacoEconomics*.

Santos, C. H., Gabriel, G. T., Campos, A. T., Queiroz, J. A. de e Montevechi, J. A. B. (2019). Application of the discrete event simulation integrated with lean concepts for implementing improvements in a military field hospital. *Revista Pesquisa Naval*, 31:2–13.

Shu, L., Ji, N., Chen, X. e Feng, G. (2020). Ark of life and hope: the role of the cabin hospital in facing COVID-19. *Journal of Hospital Infection*, 105(2):351–352.

Wu, J. T., Leung, K., Bushman, M., Kishore, N., Niehus, R., Salazar, P. M. de, Cowling, B. J., Lipsitch, M. e Leung, G. M. (2020). Estimating clinical severity of COVID-19 from the transmission dynamics in Wuhan, China. *Nature Medicine*, 26(4):506–510.

Yuan, Y., Qiu, T., Wang, T., Zhou, J., Ma, Y., Liu, X. e Deng, H. (2020). The application of temporary ark hospitals in controlling COVID-19 spread: the experiences of one temporary ark hospital, Wuhan, China. *Journal of Medical Virology*, 92(10):2019–2026.

Zolfani, S. H., Yazdani, M., Torkayesh, A. E. e Derakhti, A. (2020). Application of a gray-based decision support framework for location selection of a temporary hospital during COVID-19 pandemic. *Symmetry (Basel)*, 12(6).