LII Simpóso Brasileiro de Pesquisa Operacional
João Pessoa-PB, 3 a 5 de novembro de 2020

LOCALIZAÇÃO DE POSTOS PARA TESTAGEM DE COVID-19

Christopher Feitosa
Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)
Rua Marquês de São Vicente, 225, Gávea – Rio de Janeiro,
christopherfeitosa@yahoo.com.br

Amanda Chiote Cabral
Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)
Rua Marquês de São Vicente, 225, Gávea – Rio de Janeiro,
amandachiotecabral@gmail.com

RESUMO

O Brasil está entre os locais com maior número de casos de COVID-19 no mundo (587 casos confirmados para cada 100.000 habitantes) até 25/06/2020; e o Estado do Rio de Janeiro se destaca também pelo elevado número de casos na mesma data (613 casos por 100.000 habitantes). Um dos principais problemas na pandemia é a subnotificação dos casos da doença devido à ausência de testagens em massa. Esta pesquisa busca resolver um problema de *facility location*, propondo um modelo de otimização estocástica para instalação de postos de testagem de COVID-19 para os municípios do Rio de Janeiro, em diferentes cenários, atendendo de forma eficiente toda a demanda da população do Estado. Os Resultados mostram o funcionamento do modelo proposto, com a decisão de localização dos postos nas cidades de Campos dos Goytacazes, Nova Iguaçu, Rio das Ostras, Rio de Janeiro, São Gonçalo e Volta Redonda.

PALAVRAS CHAVE. Facility Location, Otimização Estocástica, COVID-19.

Tópicos: PO na área de Gestão de Saúde, Modelagem Matemática, Programação Matemática

ABSTRACT

Brazil is among the places with the highest number of COVID-19 cases in the world (587 cases per 100.000 people) until 06/25/2020; and the State of Rio de Janeiro also stands out for its high number of cases at the same date (613 cases per 100.000 people). One of the main pandemic problems are the underreporting cases of the disease. This research seeks to solve a facility location problem, proposing a stochastic modeling of the installation of COVID-19 testing sites for the municipalities of Rio de Janeiro, in different scenarios, efficiently meeting all the demand of the population of the State. The results show the functioning of the proposed model, with the decision to locate the sites in the cities of Campos dos Goytacazes, Nova Iguaçu, Rio das Ostras, Rio de Janeiro, São Gonçalo and Volta Redonda.
KEYWORDS. Facility Location, Stochastic Optimization, COVID-19.

Paper topics: OR in Health Management, Mathematical Modeling, Mathematical Programming

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

1. Introdução

A doença COVID-19, causada pelo novo Coronavírus SARS-CoV-2, foi identificada em janeiro de 2020 em Wuhan, China. Seu surto foi declarado Emergência de Saúde Pública de Interesse Internacional em 30 de janeiro de 2020 e pandemia em 11 de março de 2020 (Gumbrecht e Howard, 2020). Segundo dados da Organização Mundial da Saúde, até o dia 25 de junho, o número total de casos ultrapassou 8.525.042 casos e 456.973 mortes em todo o mundo (WHO ,2020)(Universidade John Hopkins, 2020). Desde então o número de casos confirmados de COVID-19 mostrou um crescimento exponencial em diferentes países, o que resultou em uma sobrecarga nos sistemas de saúde de todo o mundo. No Brasil, o primeiro caso foi confirmado em 25 de fevereiro e o número de pessoas contaminadas aumentou rapidamente, com 587 casos confirmados para cada 100.000 habitantes, até o dia 25 de junho de 2020; e mais especificamente no Rio de Janeiro, a ocorrência de contaminados é ainda mais grave, com 613 casos por 100.000 habitantes, na mesma data, segundo dados do Ministério da Saúde.

Apesar de medidas drásticas tomadas para limitar a disseminação, essa pandemia levará a um número significativo de mortos e a um impacto imprevisível nos sistemas de saúde e na economia mundial. Isso mostra a necessidade de dados precisos sobre a prevalência para melhor informar a tomada de decisões políticas e de saúde pública e identificar amplamente os indivíduos infectados. No entanto, as verdadeiras taxas de prevalência são desconhecidas, pois na maioria dos países ainda não foram introduzidos testes populacionais em larga escala. Os testes geralmente são restritos a grupos específicos de populações, como profissionais de saúde, indivíduos com exposição conhecida à SARS-CoV-2, sintomas de COVID-19 ou com fatores de risco para doenças graves (Nogueira et al, 2020).

O objetivo deste artigo é apresentar um modelo estocástico com o objetivo de resolver o problema de *facility location* para instalação de postos para testagem de COVID-19; e testar o modelo em uma aplicação para atender os 92 municípios do Estado do Rio de Janeiro.

2. Revisão de Literatura

2.1) Facility Location para Logística Humanitária e Gerenciamento de Operações de Desastres

A logística humanitária pode ser definida como o processo de planejamento, gerenciamento e controle do fluxo de algum tipo de recurso de ajuda a pessoas afetadas (Kovacs e Spens, 2007), (Sheu, 2007); (Natarajarathinam et al., 2009); (Caunhye et al. , 2012). Na logística humanitária se observa que as principais métricas da cadeia de suprimentos, ou seja, uma cadeia humanitária ou de ajuda humanitária, são diferentes das de uma cadeia de suprimentos comercial. Nas cadeias de suprimentos comerciais, consideram-se algumas métricas direcionadas monetariamente para medir o desempenho, enquanto a satisfação das necessidades humanitárias é o foco nas cadeias humanitárias. É possível classificar os estudos de logística humanitária em três categorias: (i) alocação de instalações; (ii) distribuição de suprimentos e transporte de vítimas de desastres; (iii) outras operações como controle de tráfego e restauração de condições normais de vida (Caunhye et al., 2012). Por outro lado, também é observado em muitos estudos que os problemas de alocação são geralmente considerados em conjunto com as operações de distribuição e evacuação de suprimentos de forma integrada, visando minimizar algum tipo de custo humanitário.

As operações de ajuda humanitária frequentemente envolvem decisões sobre onde abrir instalações de serviço e quais devem ser suas capacidades. A localização da instalação, tradicionalmente vista como um problema estratégico, torna-se um problema tático e operacional quando a demanda não é conhecida, a necessidade muda espacialmente e temporalmente à medida

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

que a resposta se desdobra; as organizações respondentes desejam abrir e fechar as instalações e os horizontes de curto prazo possuem necessidades dinâmicas e níveis de recursos variados. (Muggy e Stamm, 2017)

Uma importante área de pesquisa em logística de assistência humanitária é a alocação de instalações. Em um cenário geral de problemas, seu envolvimento com diferentes fases do Gerenciamento de Operações de Desastres torna a alocação de instalações um problema mais desafiador, uma vez que agora exige a consideração de parâmetros estocásticos, como quantidade de demanda, localização, status da estrada e capacidade e disponibilidade de recursos. Diferentes abordagens são usadas para lidar com esses parâmetros de problemas estocásticos, como a consideração do pior cenário ou mesmo a consideração do cenário mais provável. Nesses casos, uma versão determinística do problema correspondente a cada um desses cenários é resolvida. Em alguns outros estudos, abordagens de solução baseadas em otimização estocástica são usadas. Em particular, essas abordagens de solução são comumente usadas para resolver problemas de alocação em Gerenciamento de Operações de Desastres (Cavdur et al., 2020).

2.2) A testagem para COVID-19

A quantidade de casos não documentados de COVID-19, porém capazes de transmitir a doença, é uma característica epidemiológica crítica que avalia o potencial de pandemia de um vírus respiratório emergente. Dependendo da transmissibilidade e do número de infectados assintomáticos, uma parcela da população muito maior do que a efetivamente contabilizada é exposta ao vírus, aumentando sua taxa de propagação de forma alarmante (Nogueira et al, 2020). Li et al. (2020) estimou que, até o início da implementação das restrições de viagens na China (23 de janeiro de 2020) o índice de subnotificação era de 86% e a taxa de transmissão por caso não documentado foi de 55% e, além disto, o estudo reporta que estes casos não registrados correspondem a 79% dos casos ocorridos na China até aquele momento. Se dados fidedignos de subnotificação não forem levados em consideração na análise do cenário da pandemia em cada país, projeções de avanço do surto epidemiológico tendem a gerar resultados distantes da realidade e consequentemente medidas para o impedimento do avanço da doença não serão efetivas (Prado et al, 2020).

No Brasil, a doença avançou de forma rápida e agressiva, sendo o Brasil o segundo país com maior número de casos no mundo, até data de final de junho, com mais de 1.000.000 de casos confirmados da doença (UNIVERSIDADE JOHN HOPKINS, 2020). Em Junho de 2020, o Brasil é o 10º país que mais testa no mundo, de forma absoluta, com 2.409.830, e com 11.339 testes por milhão de habitantes. (WORLD OF METERS,2020) Ao considerar que o Brasil possui mais de 211.000.000 de habitantes (IBGE, 2020), o número de testes é consideravelmente inferior ao necessário para mensurar de forma eficiente o real número de casos confirmados da doença no país.

Especificamente no Rio de Janeiro, a situação alarmante não é diferente, sendo o segundo Estado com maior número de casos confirmados em 20 de junho, com 95.537 casos, perdendo apenas para o Estado de São Paulo, que possui 215.793 casos na mesma data (MINISTÉRIO DA SAÚDE, 2020). Segundo dados do Núcleo de Operações e Inteligência em Saúde (NOIS), o Estado do RJ possui uma estimativa de notificação da doença de 7,2%, sendo uma das mais baixas do país, sendo a média nacional de aproximadamente 8% (Prado et al, 2020). O elevado grau de subnotificação pode sugerir uma falsa ideia de controle epidêmico e, consequentemente, poderia levar a redução na implementação de ações de contenção, como por exemplo o isolamento horizontal e medidas de distanciamento social, por isso é fundamental que sejam implementadas medidas efetivas de testagem no Estado e em todo o país.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

3. Metodologia

Inicialmente realizou-se uma revisão de literatura completa sobre artigos com foco em problemas de Facility Location em desastres naturais e artigos sobre o novo coronavírus. Foi conduzida também uma coleta de dados para fornecer a distância entre os municípios do Estado do Rio de Janeiro utilizando a ferramenta API Matrix Distance, do Google. Para o tratamento dos dados, foi utilizado o software de otimização combinatória AIMMS, cujas funções utilizadas foram referentes à programação inteira, estruturando-se o algoritmo adequado ao problema e obtendo-se a solução através do solver comercial CPLEX. A partir dos dados iniciais e da revisão realizada foi desenvolvido um modelo matemático de otimização estocástica para localização de postos de testagem.

A determinação da demanda de testes em cada cidade pode ser determinada de diferentes formas, dentre as quais destacamos a previsão à partir de modelos preditivos do número de casos futuros de COVID-19 em cada cidade (através da utilização de taxas de crescimento ou séries temporais por exemplo); ou mesmo à partir da análise do histórico de casos em cada cidade, utilizando dados relativos (por 100.000 habitantes) ou utilizando os dados diretos divulgados. (Chowell et al, 2019)(Liu et al, 2019)(Roosa et al, 2020). No presente trabalho utilizamos os dados divulgados do histórico de número de casos por cidade para estimar a demanda por testes de COVID-19 e aplicar o modelo matemático proposto, como descrito nas seções subsequentes deste artigo.

4. Modelo Matemático Proposto

Foi desenvolvido um modelo estocástico de otimização que busca minimizar a distância entre as cidades com demanda de testes e as cidades onde os postos serão instalados. O Modelo minimiza também os custos de instalação e operação dos postos.

A seguir é apresentada a formulação matemática utilizada no modelo desenvolvido, com a descrição das funções, de suas variáveis e restrições. As Tabelas Tabela 1 e Tabela 2 apresentam, respectivamente, os conjuntos e os parâmetros utilizados no modelo, e a Tabela 3 apresenta as variáveis utilizadas.

Conjunto	Índice	Nome	Descrição
I	i	Local de Origem	Local onde está a população que será testada
J	j	Local de Destino	Local onde os postos serão instalados
C	c	Capacidade do Posto	Tipo de posto que será instalado.
T	t, tt	Tempo	Tempo (em dias)
S	s	Cenário	Cenário estocástico

Tabela 1- Conjuntos do Modelo

Parâmetro	Nome	Descrição	Unidade
D_{ij}	Matriz de Distâncias	Distância entre todas as cidades do estado.	m
$DEMANDA_{its}$	Demanda a ser atendida	Número de pessoas do município i a serem testadas no tempo t no cenário s.	Pessoas

$COST_IN_{jc}$	Custo de Instalação do Posto	Custo de Instalação do Posto de capacidade "c" na cidade "j".	R$/Posto
COST_OPjc	Custo de Operação do Posto	Custo de Operação do Posto de capacidade "c" na cidade "j".	R$/Posto
U	Parâmetro de Custo	Parâmetro de custo por distância.	R$/m
$TOTAL_POSTOS_c$	Total de Postos	Número total de postos do tipo "c"	Postos
Θ_c	Oferta de Testes	Oferta de testes em postos de capacidade "c"	Testes/Posto
MIN	Demanda Mínima	Número mínimo de demanda que uma cidade precisa ter para que haja testagem.	Pessoas
$PROB_s$	Probabilidade	Probabilidade de um cenário "s" ocorrer	Adimensional

Tabela 2- Parâmetros do Modelo

Variável	Descrição	Unidade	Domínio
x_{ijts}	Número de pessoas em "i" testadas em "j", no tempo "t", no cenário "s".	Pessoas	Z +
y_{jct}	Quantidade de postos do tipo "c" instalados na cidade "j" no tempo "t".	Postos	Z +
z_{jcts}	Quantidade de postos do tipo "c" mantidos abertos na cidade "j", no tempo "t", no cenário "s".	Postos	Z +

Tabela 3- Variáveis do Modelo

O modelo estocástico construído possui dois estágios de decisão: No primeiro estágio de tempo, é realizada a decisão de instalar ou não um ou mais postos em uma cidade "j", representada pela variável inteira y_{jct}. No Segundo estágio, é tomada a decisão de manter as tendas instaladas na cidade "j" abertas ou fechadas, de acordo com a variação de demanda observada no cenário "s"; esta decisão é representada pela variável z_{jcts}. A variável x_{ijts} por sua vez aloca a quantidade de pessoas de cada origem "i" que será atendida em "j", de acordo com o cenário "s" de demanda.

Função Objetivo

$$MIN\ Z = \sum_{ijts} D_{ij} U x_{ijts} PROB_s + \sum_{jct} COST_IN_{jc} y_{jct} + \sum_{jcts} COST_OP_{jc} z_{jcts} PROB_s \quad (1)$$

Sujeito a:

$$\sum_{jt} y_{jct} \leq TOTAL_POSTOS_C \quad \forall c \ (2)$$

$$\sum_{j} x_{ijts} = DEMANDA_{its} \quad \forall i,t,s \ (3)$$

$$z_{jcts} \leq \sum_{tt \leq t} y_{jc(tt)} \quad \forall j,c,t,s \ (4)$$

$$\sum_{i} x_{ijts} \leq \sum_{c} \theta_c z_{jcts} \quad \forall j,t,s \ (5)$$

$$x_{ijts} \in \mathbb{Z} \mid x_{ijts} \geq 0 \ e \ DEMANDA_{its} \geq MIN \quad \forall i,j,t,s \ (6)$$

$$y_{jct} \in \mathbb{Z} \mid y_{jct} \geq 0 \quad \forall j,c,t \ (7)$$

$$z_{jcts} \in \mathbb{Z} \mid z_{jcts} \geq 0 \quad \forall j,c,t,s \ (8)$$

O objetivo do modelo apresentado na equação (1) é minimizar o custo da distância percorrida pelas pessoas da origem "i" que serão testadas em determinado posto no destino "j", minimizar o custo de instalação de tais postos e também os custos operacionais, fornecendo a opção de manter o posto aberto ou fechado. A demanda de testes é o parâmetro que varia de acordo com o cenário de melhora ou piora da pandemia, ajustado pelo parâmetro de probabilidade. A restrição (2) garante que a quantidade total de postos não pode ultrapassar a disponibilidade total. A restrição (3) garante que a quantidade de pessoas, de cada origem, que serão testadas em determinado posto, seja igual a demanda deste local no tempo "t". Em (4), a restrição explicita que a decisão de manter uma tenda aberta ou fechada na cidade "j" só deve ser tomada se a decisão de instalar postos tiver sido tomada em um período de tempo anterior. Na restrição (5) a quantidade de pessoas testadas deve ser menor ou igual a oferta de testes enquanto as restrições (6), (7) e (8) garantem que as variáveis sejam inteiras e positivas.

5. Aplicação do Modelo e Análise de Resultados

5.1) Descrição do Problema

Conforme a descrição nas seções 1 e 2 do presente trabalho, a subnotificação de casos de COVID-19 é um dos principais desafios para controle da pandemia; no contexto do estado do Rio de Janeiro, a aplicação do modelo proposto se justifica pelo objetivo de instalar postos de testagem em massa em regiões estratégicas do estado, de modo a atender uma demanda proporcional ao numero de casos que cada cidade apresenta. A Tabela 4 apresenta os dados de número de casos confirmados de COVID-19 em cada uma das 92 cidades do estado do Rio de Janeiro (atualizado

em 08/06/2020). A demanda diária inicial, no tempo t=0, foi definido como 5% do número total de casos em cada cidade; como a demanda é um parâmetro afetado pela incerteza de o número de casos aumentar ou diminuir nos dias subsequentes, foram criados 3 cenários para avaliação do comportamento do modelo: a) O Cenário Pessimista, no qual no dia seguinte (t=1) a demanda aumenta em 100%; b) O Cenário Mediano, no qual no dia seguinte a demanda se mantém a mesma do tempo (t=0); c) O Cenário Otimista, no qual a demanda do dia seguinte é reduzida pela metade. Os cenários foram considerados equiprováveis na aplicação do modelo. Como as variáveis X e Z são dependentes do cenário, elas são calculadas sempre no segundo estágio (t=1), enquanto a decisão de instalar ou não um posto em determinada cidade é tomada pela variável Y no primeiro estágio (t=0).

Os custos de instalação e operação de um posto foram estimados apenas para efeito de aplicação do modelo, não correspondendo 100% aos custos reais, de modo que os custos realmente impactem na função objetivo (um custo muito baixo para um posto significa que o modelo sempre irá instalar o número total de postos disponíveis, de modo a minimizar a distância entre as cidades, o que não garantiria o funcionamento do modelo proposto). Os valores estabelecidos para cada parâmetro são apresentados na Tabela 5.

O Parâmetro "MIN" garante que cidades com demanda muito baixa ou sem demanda não precisem ser atendidas pelos postos de testagem em massa, pois algumas das cidades do interior do estado do Rio de Janeiro praticamente não possuem um número considerável de casos de COVID-19 identificados. O Parâmetro "U" age apenas como um transformador de unidade de distância para unidade monetária, e foi estimado com o valor de preço por quilometragem de aplicativos de transporte.

Cidades	CASOS	Cidades	CASOS	Cidades	CASOS
Angra dos Reis	1195	Itaocara	56	Resende	247
Aperibé	19	Itaperuna	241	Rio Bonito	174
Araruama	219	Itatiaia	8	Rio Claro	82
Areal	51	Japeri	147	Rio das Flores	4
Armação dos Búzios	114	Laje do Muriaé	53	Rio das Ostras	424
Arraial do Cabo	48	Macaé	1234	Rio de Janeiro	36893
Barra do Piraí	200	Macuco	4	Santa Maria Madalena	7
Barra Mansa	214	Magé	961	Santo Antônio de Pádua	156
Belford Roxo	940	Mangaratiba	152	São Fidélis	148
Bom Jardim	28	Maricá	708	S. Francisco de Itabapoana	68
Bom Jesus do Itabapoana	71	Mendes	35	São Gonçalo	2616
Cabo Frio	478	Mesquita	648	São João da Barra	127
Cachoeiras de Macacu	163	Miguel Pereira	22	São João de Meriti	1095
Cambuci	38	Miracema	44	São José de Ubá	65
Campos dos Goytacazes	963	Natividade	39	São José do Vale do Rio Preto	92
Cantagalo	6	Nilópolis	410	São Pedro da Aldeia	218
Carapebus	49	Niterói	4186	São Sebastião do Alto	10
Cardoso Moreira	25	Nova Friburgo	405	Sapucaia	105
Carmo	28	Nova Iguaçu	2181	Saquarema	140

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

Casimiro de Abreu	181	Paracambi	252	Seropédica	266
Comendador Levy Gasparian	17	Paraíba do Sul	162	Silva Jardim	79
Conceição de Macabu	93	Paraty	121	Sumidouro	17
Cordeiro	41	Paty do Alferes	28	Tanguá	171
Duas Barras	5	Petrópolis	529	Teresópolis	712
Duque de Caxias	1829	Pinheiral	68	Trajano de Moraes	7
Engenheiro Paulo de Frontin	21	Piraí	134	Três Rios	342
Guapimirim	377	Porciúncula	42	Valença	116
Iguaba Grande	96	Porto Real	17	Varre-Sai	13
Itaboraí	1589	Quatis	12	Vassouras	140
Itaguaí	624	Queimados	1251	Volta Redonda	918
Italva	93	Quissamã	82		

Tabela 4 - Casos de COVID-19 nas cidades do Estado do Rio de Janeiro [Governo do Estado do Rio de Janeiro, 2020]

Parâmetro	*Valor (unidade)*
COST_IN Posto A	R$10.000,00 / Posto
COST_IN Posto B	R$30.000,00 / Posto
COST_OP Posto A	R$5.000,00 / Posto
COST_OP Posto B	R$10.000,00 / Posto
U	R$0,0014 / m
Θ Posto A	1000 testes diários
Θ Posto B	2000 testes diários
TOTAL_POSTOS A	5 postos
TOTAL_POSTOS B	5 postos
MIN	5 casos de demanda

Tabela 5 - Valor dos Parâmetros Utilizados

5.2) Resultados Obtidos

O Solver comercial CPLEX foi utilizado na aplicação e solução do modelo para o problema proposto.

Cidade	Qtd Postos (Tipo)
Campos dos Goytacazes	1 (A)
Nova Iguaçu	1 (A)
Rio das Ostras	1 (A)
Rio de Janeiro	2 (B)
São Gonçalo	1 (A)
Volta Redonda	1 (A)

Tabela 6 - Cidades selecionadas para instalação dos postos

Cidade	CENÁRIO Pessimista	Mediano	Otimista
Campos dos Goytacazes	1 (A)	1 (A)	1 (A)
Nova Iguaçu	1 (A)	1 (A)	1 (A)
Rio das Ostras	1 (A)	1 (A)	1 (A)
Rio de Janeiro	2 (B)	1 (B)	1 (B)
São Gonçalo	1 (A)	1 (A)	1 (A)
Volta Redonda	1 (A)	1 (A)	1 (A)

Tabela 7 – Postos mantidos em funcionamento por cenário

A Tabela 6 mostra as decisões tomadas pelo modelo de localização dos postos. Pode-se observar que o modelo aloca 2 tendas grandes para a cidade do Rio de Janeiro, que é a cidade mais populosa do estado e também a cidade com maior número de casos confirmados de COVID-19. O Modelo decide localizar também tendas de 1000 testes diários nas cidades de Campos dos Goytacazes, Nova Iguaçu, Rio das Ostras, São Gonçalo e Volta Redonda, de forma a distribuir geograficamente as tendas em diferentes regiões do estado, localizando-as em pontos estratégicos centrais de acordo com a demanda de cada cidade, conforme pode ser observado na Tabela 8.

A Tabela 7 mostra os resultados estocásticos de segundo estágio de decisão, na qual o modelo decide manter aberta ou fechar uma tenda anteriormente instalada, de acordo com cada cenário de previsão de demanda. Percebe-se que mesmo nos cenários mediano e otimista, o modelo decide manter abertas a maioria das tendas, mostrando que a decisão de localização desses postos é mais fortemente influenciada pela centralidade dessas cidades em regiões com maior demanda. Já na cidade do Rio de Janeiro, observa-se que manter apenas uma das tendas instaladas anteriormente abertas é a melhor decisão para a demanda do cenário mediano ou otimista, o que demonstra o funcionamento correto do modelo em dois estágios, visto que a decisão de primeiro estágio tomada é a de instalar duas tendas, devido a possibilidade de 33,33% de haver um cenário pessimista, no qual uma tenda apenas não seria suficiente para atender a demanda, e no caso de não ocorrer este cenário, o modelo desativa uma das tendas para cortar o custo de operação.

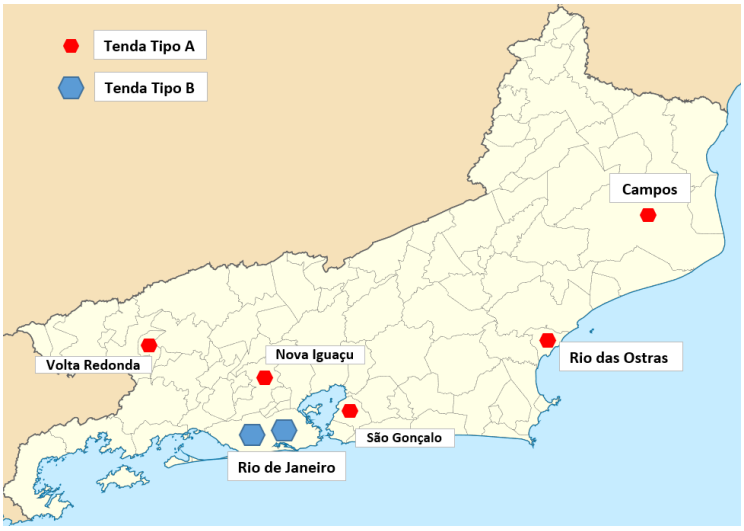


Figura 1 - Mapa do Estado do Rio de Janeiro com a localização das tendas/postos

A Figura 1 mostra o mapa do estado do Rio de Janeiro, com as fronteiras de suas 92 cidades, e a localização geográfica das cidades selecionadas pelo modelo para a instalação dos postos de testagem em massa. Pode-se observar que a maioria das tendas é localizada na região metropolitana do estado (Rio de Janeiro, Nova Iguaçu e São Gonçalo pertencem à esta região). Este fato se deve pela natureza de transmissibilidade do vírus; a região metropolitana possuí uma população maior, e a proximidade com a cidade do Rio de Janeiro, a mais afetada, justifica também o maior número de casos nessa região e, portanto, a decisão de instalar uma quantidade maior de tendas.

A Tabela 8 apresenta a alocação de atendimento, ou seja, quais cidades do estado estão sendo atendidas por qual posto. Percebe-se que algumas das 92 cidades do estado, apresentadas na Tabela 4, não são atendidas por nenhum dos postos. Isso ocorre pois essas cidades não possuem demanda de testes na estimativa realizada, ou apresentam uma demanda menor que o mínimo estabelecido na Tabela 5 (5 casos). Toda a demanda das demais cidades é obrigatoriamente atendida por ao menos um posto, o que é garantido pela equação 3 de restrição do modelo.

POSTO	CIDADES ATENDIDAS
Campos dos Goytacazes	Bom Jesus do Itabapoana
	Campos dos Goytacazes
	Conceição de Macabu
	Italva
	Itaocara
	Itaperuna
	Quissamã
	Santo Antônio de Pádua
	São Fidélis
	São Francisco de Itabapoana
	São João da Barra
	São José de Ubá
Nova Iguaçu	Belford Roxo
	Duque de Caxias
	Itaguaí
	Japeri
	Mesquita
	Nilópolis
	Nova Iguaçu
	Paracambi
	Queimados
	São João de Meriti
	Seropédica
Rio das Ostras	Araruama
	Armação dos Búzios
	Cabo Frio
	Casimiro de Abreu
	Iguaba Grande
	Macaé
	Nova Friburgo
	Rio das Ostras
	São Pedro da Aldeia
	Saquarema
	Silva Jardim

POSTO	CIDADES ATENDIDAS
Rio de Janeiro	Niterói
	Petrópolis
	Rio de Janeiro
	São José do Vale do Rio Preto
São Gonçalo	Cachoeiras de Macacu
	Guapimirim
	Itaboraí
	Magé
	Maricá
	Niterói
	Rio Bonito
	São Gonçalo
	Saquarema
	Tanguá
	Teresópolis
Volta Redonda	Angra dos Reis
	Barra do Piraí
	Barra Mansa
	Mangaratiba
	Paraíba do Sul
	Paraty
	Pinheiral
	Piraí
	Resende
	Rio Claro
	Sapucaia
	Três Rios
	Valença
	Vassouras
	Volta Redonda

Tabela 8 - Alocação de Cidades atendidas por posto

6. Conclusão

O Modelo de Otimização Estocástica proposto é capaz de tomar decisões em dois estágios, com a consideração das incertezas de demanda, para a localização de tendas de testagem para o COVID-19, conforme o objetivo do presente trabalho. A Aplicação do modelo no exemplo, com dados de cidades do Estado do Rio de Janeiro, resultou na decisão de instalação de uma tenda de 1000 testes diários nas cidades de Campos dos Goytacazes, Nova Iguaçu, Rio das Ostras, São Gonçalo e Volta Redonda; e instalação de duas tendas de 2000 testes diários cada na cidade do Rio de Janeiro.

Este trabalho fornece um modelo aplicável a diferentes estados e/ou cidades para a decisão de Facility Location, no contexto na pandemia de COVID-19, com a possibilidade de entrada de dados diferentes, ou mesmo outros cenários de demanda.

É possível observar que o exemplo aplicado contou com a estimação de alguns parâmetros; a utilização de valores reais de custo, modelos preditivos diferentes para o número de casos ou mesmo um modelo estatístico para criação dos cenários de demanda, garantindo a variação aleatória da demanda de cada uma das cidades em diferentes cenários estocásticos, fugiram do escopo do presente trabalho, porém, ficam como sugestões para trabalhos futuros.

Referências

Caunhye A.M., Nie X., Pokharel S., (2012). Optimization models in emergency logistics: a literature review. Socio-Economic Planning Sciences. 46(1):4-13. https://doi.org/10.1016/j.seps.2011.04.004.

Cavdur F., Sebatli-Saglam A., Kose-Kucuk M. (2020). A spreadsheet-based decision support tool for temporary-disaster-response facilities allocation. Safety Science. 124 https://doi.org/10.1016/j.ssci.2019.104581.

Chowell G., Tariq A., Hyman JM., (2019). A novel sub-epidemic modeling framework for short-term forecasting epidemic waves. BMC Medicine. 17:164. https://doi.org/10.1186/s12916-019-1406-6.

Eberhardt J. N, Breuckmann N. P., Eberhardt C. S., (2020) Multi-Stage Group Testing Improves Efficiency of Large-Scale COVID-19 Screening. Journal of Clinical Virology. 128. https://doi.org/10.1016/j.jcv.2020.104382.

Governo Do Estado Do Rio De Janeiro, 2020. Painel coronavirus. Disponível em: https://coronavirus.rj.gov.br/. Acessado em 06/2020.

Gumbrecht J, Howard J. WHO declares novel coronavirus outbreak a pandemic. CNN: 2020 Mar 11. Disponível em: https://edition.cnn.com/2020/03/11/health/coronavirus-pandemic-world-health-organization/index.html. Acessado em 07/04/2020.

IBGE, 2020. População brasileira em 2020. Disponível em: https://www.ibge.gov.br/apps/populacao/projecao/box_popclock.php. Acessado em 06/2020.

Kovacs G., Spens, K.M., (2007). Humanitarian logistics in disaster relief operations. Int. J. Phys. Distribut. Logist. Manag. 37(2):99-114. https://doi.org/10.1108/ 096000307107

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

Li R., S. Pei, Chen B., Song Y., Zhang T., Yang W., Shaman J., (2020). Substantial undocumented infection facilitates the rapid dissemination of novel coronavirus (SARS-CoV2). Science. 368(6490):489-493. DOI: 10.1126/science.abb3221.

Liu Q, Li Z, Ji Y, Martinez L, Zia U, Javaid A, Lu W, Wang J, (2019). Forecasting the seasonality and trend of pulmonary tuberculosis in Jiangsu Province of Chine using advanced statistical time-series analyses. Infection and Drug Resistance. 12, 2311-2322.

Ministério Da Saúde, 2020. Painel Coronavírus. Disponível em https://covid.saude.gov.br/. Acessado em 06/2020.

Muggy L, Stamm J, 2017, Dynamic, robust models to quantify the impact of decentralization in post-disaster health care facility location decisions. Operations Research for Health Care. 12: 43-59. http://dx.doi.org/10.1016/j.orhc.2017.01.002

Natarajarathinam M., Capar I., Narayanan A., (2009). Managing supply chains in times of crisis: a review of literature and insights. Int. J. Phys. Distribut. Logist. Manag. 39(7): 535-573. https://doi.org/10.1108/096000309109

Nogueira A., Nogueira C., Zibetti A., Roqueiro N., Bruna-Romero O., Carciofi B.A.M., (2020). Estimativa da subnotificação de casos da COVID-19 no Estado de Santa Cantarina.

Prado M., Bastos L., Batista A., Antunes B., Baião F., Maçaira P., Hamacher S., Bozza F., (2020). Análise de subnotificação do número de casos confirmados da COVID-19 no
Brasil. Núcleo de Operações e Inteligência em Saúde (NOIS). Nota Técnica 7 – 11/04/2020.

Roosa K, Lee Y, Luo R, Kirpich A, Rothenberg R, Hyman JM, Yan P, Chowell G, (2020). Real-Time forecasts of the COVID-19 epidemic in China from February 5th to February 24th, 2020. Infectious Disease Modelling. 5; 256-263.

Sheu, J.B., (2007). Challenges of emergency logistics management. Transport. Res. Part E: Logist. Transport. Rev. 43. https://doi.org/10.1016/j.tre.2007.01.001

Universidade John Hopkins, 2020. COVID-19 Dashboard by the Center for Systems Science and Engineering (CSSE) at Johns Hopkins University. Disponível em: https://coronavirus.jhu.edu/map.html. Acessado em 06/2020.

Wang B., Li M., Hu Y., Huang L., Lin S., (2018). Optimizing Locations and Scales of Emergency Warehouses Based on Damage Scenarios. https://doi.org/10.1007/s40305-018-0215-5

World Health Organization, 2020. Coronavirus disease (Covid-19), Situation Report. Disponível em: https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200620-covid-19-sitrep-152.pdf?sfvrsn=83aff8ee_2. Acessado em 04/2020.

World of Meters, 2020. COVID-19 Coronavirus Pandemic. Disponível em: https://www.worldometers.info/coronavirus/. Acessado em 06/2020.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings