

UNIVERSIDADE DE SÃO PAULO
INSTITUTO DE MATEMÁTICA E ESTATÍSTICA
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

**Planejamento On-line Baseado em Redes
de Contato para Medidas de Contenção da
COVID-19**

Guilherme Yambanis Thomaz

MONOGRAFIA FINAL

MAC 499 — TRABALHO DE
FORMATURA SUPERVISIONADO

Orientador: Prof. Dr. Denis Deratani Mauá
Coorientadora: Prof^a. Dr^a. Leliane Nunes de Barros

São Paulo
Dezembro de 2020

**Planejamento On-line Baseado em Redes
de Contato para Medidas de Contenção da
COVID-19**

Guilherme Yambanis Thomaz

Esta é a versão original da monografia
elaborada pelo candidato Guilherme
Yambanis Thomaz, tal como
submetida à Comissão Julgadora.

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

*À minha família, pelo apoio e amor; e
àqueles que enfrentaram o COVID-19.*

Resumo

Guilherme Yambanis Thomaz. **Planejamento On-line Baseado em Redes de Contato para Medidas de Contenção da COVID-19**. Monografia (Bacharelado). Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, 2020.

Utilizamos dados da pesquisa Origem-Destino 2017 na construção de uma rede de contato representativa da cidade de São Paulo, na qual indivíduos são conectados por diferentes relações sociais (escola, trabalho, vizinhança e moradia). A rede é utilizada na construção de um modelo compartimental estocástico, com tempo e estados discretos, para simular a propagação da COVID-19. O modelo é usado para comparação de diferentes estratégias de políticas públicas de mitigação. Os resultados indicam que até mesmo planejadores simples baseados em técnicas de Monte Carlo são capazes de aumentar de forma significativa a performance, considerando-se os impactos econômicos e sociais de medidas de intervenção não-farmacêuticas, quando comparados a estratégias puramente reativas.

Palavras-chave: COVID-19, Redes Complexas, Planejamento

Abstract

Guilherme Yambanis Thomaz. **A Contact Network-Based Approach for Online Planning of Containment Measures for COVID-19**. Capstone Project Report (Bachelor). Institute of Mathematics and Statistics, University of São Paulo, São Paulo, 2020.

We use data from the 2017 Origin-Destination survey to build a representative contact network for the city of São Paulo, where individuals are connected by different social relations (school, work, neighborhood). The network is used to devise a stochastic discrete time and state compartmental model for the spread of the COVID-19. We employed the model to compare different mitigation strategies. The results show that even simple Monte Carlo planners greatly improve the performance over reactive strategies in terms of balancing the economical and health impacts of non-pharmaceutical interventions.

Keywords: COVID-19, Complex Networks, Planning

Lista de Figuras

3.1	Esquerda: Histograma 2D de relações por distrito de residência Direita: Número de indivíduos com residência em cada distrito	8
3.2	Ego networks das relações de três indivíduos amostrados no grafo final .	10
3.3	Histogramas das relações de contato com base nas idades para a rede . .	11
3.4	Simulação da evolução da doença COVID-19	11
3.5	Curva epidemiológica simulada do modelo irrestrito	14
3.6	Taxa de mobilidade para a cidade de SP no período	14
3.7	R_t simulado a partir das taxas de mobilidade	15
3.8	Número de internações observadas comparado às simuladas	15
3.9	Número de indivíduos infectados em cada distrito após 0, 4, 8, 12 e 18 semanas simuladas	16
3.10	Esquerda: Custo das intervenções e hospitalizações Direita: Estratégias de mitigação (reativas) basais	18
4.1	Curvas de hospitalizados para as estratégias de referência1	20
4.2	Curvas de hospitalizados para as estratégias de referência 2	20
4.3	Curva de hospitalizados do planejador para H=2	24
4.4	Curva de hospitalizados do planejador para H=3	24
4.5	Curva de hospitalizados do planejador para H=4	25
4.6	Ilustração da árvore de ações com horizonte igual a 3	25
4.7	Pseudo código para o planejador	26

Lista de Tabelas

3.1	Estatísticas do grafo resultante	9
3.2	Esquerda: Probabilidades de necessidade de hospitalização Direita: Parâmetros das distribuições normais truncadas (em dias)	13
4.1	Performance das estratégias de mitigação	23

Sumário

1	Introdução	1
2	Trabalhos Relacionados	3
3	Modelagem da COVID-19 Baseada em Redes de Contato para a Cidade de São Paulo	7
3.1	Uma Rede de Contato para a Cidade de São Paulo	7
3.2	Modelo de propagação da doença	9
3.3	Intervenções	16
3.4	Modelagem dos custos	17
4	Otimização das intervenções	19
5	Conclusões e trabalhos futuros	27
	Agradecimentos	29
	Referências Bibliográficas	31

Capítulo 1

Introdução

A atual pandemia da COVID-19 causada pelo vírus SARS-CoV-2 tem causado imensos custos sanitários, sociais e econômicos para sociedades ao redor do planeta. As respostas de governos locais e nacionais à pandemia têm variado consideravelmente, mas, de forma geral, consistem na aplicação de medidas de intervenção não-farmacêuticas, como restrição ao fluxo de pessoas e viagens, fechamento de escolas e locais de trabalho e até mesmo quarentenas e isolamentos forçados. A evolução e as consequências da doença também têm sido variadas: enquanto alguns países têm sido capazes de manter números relativamente baixos de infecções e mortes, outros observaram cenários catastróficos. O colapso de seus sistemas de saúde, incapazes de lidar com picos no número de infecções simultâneas, acaba por gerar um consequente número relativamente mais elevado de mortes. No cerne da discussão entre as diferentes estratégias adotadas, está o embate entre os custos econômicos e o impacto do ponto de vista da saúde, bem como as idiosincrasias de cada sociedade em relação a liberdades individuais, privacidade e confiança nas autoridades públicas. É possível, entretanto, apontar o consenso de que as políticas públicas devem priorizar a saúde pública e minimizar o impacto econômico. Esse é um objetivo extremamente complexo de se alcançar, uma vez que exige análise a longo prazo das consequências das ações a serem tomadas. Todavia, esse aspecto entra em choque com a urgência da própria tomada de decisões, caracterizada pela severa incerteza envolvida, devido, principalmente, ao ineditismo de uma pandemia nessa escala, nos tempos recentes.

O objetivo deste trabalho é estudar como técnicas automatizadas de planejamento podem contribuir para delimitar políticas públicas de contenção e mitigação do COVID-19 no nível municipal, levando em conta a interação entre os diferentes fatores da vida urbana e a doença, como, por exemplo, padrões de mobilidade e distribuição de idade na população. O problema de controle é então formulado como um processo de decisão markoviano com horizonte finito, com um modelo de evolução da doença baseado em uma rede [Newman 2002, Xue 2020]. A fim de tornar os resultados mais realistas, usamos os dados da pesquisa Origem-Destino mais recente da cidade de São Paulo, realizada em 2017, para extrair uma rede de contato que modela a possível propagação da doença através das relações de trabalho, escola, compras e trânsito. Além disso, também foram utilizados dados públicos sobre número de camas hospitalares disponíveis, características de transmissão da doença, entre outros. Diferentemente de abordagens baseadas em

planejamento probabilístico que consideram apenas medidas como isolamento e vacinação [Xue 2020, Kinathil et al. 2017], também consideramos políticas adotadas por autoridades públicas na atual pandemia, como conscientização da população sobre medidas profiláticas, fechamento de escolas e serviços, banimento de eventos de grande porte e imposição de restrições de trânsito. Nossos resultados mostram que estratégias otimizadas fornecem performance superior no balanço entre os custos de saúde e os impactos econômicos.

Os resultados deste trabalho foram publicados em um artigo e apresentados na edição 2020 do ENIAC (Encontro Nacional de Inteligência Artificial e Computacional) [Thomaz et al. 2020], de maneira remota, devido ao COVID-19.

Capítulo 2

Trabalhos Relacionados

O número de trabalhos modelando e reportando a atual pandemia de COVID-19 tem sido impressionante. Mesmo com todos os problemas presentes nos dados disponíveis (subnotificação, indivíduos assintomáticos etc.), em um período de tempo relativamente curto, pesquisadores foram capazes de identificar propriedades-chave sobre a doença, como taxa de infecção, taxa de mortalidade, fatores de risco e taxa básica de reprodução. Também houve grande esforço para proposição de modelagens (muitas advindas de indivíduos externos à área de epidemiologia, como no caso deste trabalho). A maioria dessas modelagens utiliza o conhecido modelo SIR [Kermack and McKendrick 1927], um sistema de equações diferenciais ordinárias que descrevem a propagação da doença em termos de “fluxos populacionais”, através de diferentes compartimentos/estados (suscetível, infectado e removido). Apesar de bem estabelecido, o modelo SIR é incapaz de prover uma descrição acurada, já que assume que os indivíduos interagem entre si de maneira aleatória (mistura homogênea da população) e sem levar em considerações fatores de risco [Keeling and Eames 2005].

Técnicas atuais diferem na forma de considerar essas heterogeneidades, incorporando, além da maneira como características incertas sobre a doença são levadas em conta, o impacto de mobilidade intra e entre cidades e as características dos indivíduos, como idade e condições socioeconômicas [Dureau et al. 2013, Kucharski et al. 2020].

Mellan et al. ajustaram um sofisticado modelo estocástico de transmissão, a partir de dados oficiais sobre o COVID-19 no Brasil e de dados do *Google mobility trends* [Mellan et al. 2020]. O modelo leva em conta tendências de mobilidade, bem como fatores de risco relacionados a idade e renda. Usando primariamente dados oficiais reportados sobre número de mortes¹, os quais acredita-se serem menos afetados por subnotificação, e o relatório de mobilidade do Google, estimaram a tendência epidemiológica para os 16 estados com maior número de mortes até a data do estudo, incluindo São Paulo. Estimaram que, no estado de São Paulo, a taxa básica de reprodução, que era aproximadamente 3 no início do surto, em 16 de fevereiro, diminuiu para cerca de 1.5 no dia 6 de maio, após a adoção de medidas de distanciamento social, pelas autoridades. Mesmo que significativo, o decréscimo não foi suficiente para frear o crescimento exponencial da doença, visto

¹<https://covid.saude.gov.br>

que o valor continuou acima de 1. Silva et al. utilizaram um modelo espacial SEIR, que contabiliza o deslocamento diário entre as principais cidades do estado de São Paulo, e assumiram, como fazemos aqui, que o número de reprodução de cada cidade pode ser controlado a cada passo [Silva et al. 2020]. O problema de controle é então proposto como uma otimização contínua e limitada. O principal objetivo é alternar as restrições entre as diferentes cidades, levando a propagação da doença a um nível aceitável e minimizando os impactos econômicos.

Uma abordagem interessante para construir modelos mais realistas de transmissão de doenças é usar redes de contato (também conhecidas como redes de difusão ou de mistura), que capturam os padrões de interação a nível individual [Newman 2002, Keeling and Eames 2005, Bai et al. 2007]. Entretanto, obter redes de contato realistas é desafiador, já que dados sobre interações a nível individual raramente estão disponíveis e, adicionalmente, as características do que se constitui um “contato” dependem da doença específica (por exemplo, uma rede de contato para AIDS requer uma estimativa de atividade e parceiros sexuais, enquanto uma rede para doenças transportadas pelo ar deve levar em conta proximidade, duração e local específico da ocorrência da interação). Halloran et al. usaram redes de contato para simular a propagação de doenças transmitidas pelo ar em uma pequena população [Halloran et al. 2002]. Construíram uma rede através da atribuição aleatória de indivíduos em grupos etários e domiciliares, de acordo com a distribuição da população dos EUA. Mais especificamente, as crianças foram designadas a uma escola ou creche, onde as interações ocorrem de forma intensa, criando a principal fonte de propagação da doença. Isso é apoiado por evidências anteriores de que as famílias e as escolas são as principais rotas de transmissão de várias doenças, tais como varíola e sarampo. De modo similar, Meyers et al. estimaram uma rede de contato de dados de censo e simularam o contágio de SARS [Meyers et al. 2005]. Bai et al. compararam o efeito de estratégias de imunização entre alvos aleatórios e específicos, em redes de contato “scale-free” [Bai et al. 2007]. Concluíram que, enquanto o efeito da imunização aleatória é pequeno, a imunização com alvos específicos tem potencial de reduzir de maneira significativa o contágio da doença.

Com relação ao COVID-19, Zhang et al. coletaram dados sobre padrões de contato auto relatados antes e depois do surto, de uma pesquisa com 636 habitantes da cidade de Wuhan (o epicentro inicial do surto) e com 557 habitantes de Xangai (uma das maiores e mais densamente povoadas cidades da China) [Zhang et al. 2020]. Os indivíduos entrevistados reportaram seus padrões de contato em um dia de semana usual antes do início do surto e no dia anterior à pesquisa, quando medidas restritivas de mitigação já haviam sido implantadas (o que ocorreu próximo ao pico epidêmico em Wuhan). Para Xangai, os pesquisadores utilizaram dados disponíveis de pesquisa similar, conduzida anteriormente. As diferenças nos padrões de contato pré e pós início do surto permitiram aos pesquisadores medir o efeito das intervenções não-farmacêuticas na diminuição da transmissão através do contato social. Em resumo, o estudo observou que o número médio de contatos diminuiu, de cerca de 14 (no período-base) para 2 no período do surto. Este último valor se aproxima do número médio de membros por domicílio na região, refletindo a intensidade das intervenções (que incluíram isolamento individual e rastreamento de contatos). No Reino Unido, um decréscimo similar do número de contatos foi observado [Jarvis et al. 2020]. Utilizando os dados, estimaram os parâmetros de um modelo SIR estratificado [Kermack and McKendrick 1927], capaz de

modelar heterogeneidades entre diferentes classes (por exemplo, entre faixas etárias e tipos de contatos), utilizando o modelo para analisar a efetividade de intervenções não farmacêuticas.

Como mencionado na introdução, houve estudos do uso de técnicas de planejamento para a elaboração de políticas de controle. Kinathil et al. utilizaram programação dinâmica simbólica [Sanner et al. 2011] para otimizar uma política off-line de um modelo SIR de tempo discreto com estado e ações contínuas [Kinathil et al. 2017]. O trabalho que mais se assemelha à nossa abordagem é por Xue, que utilizou um modelo de transmissão compartimental, baseado em rede de contato para prescrever intervenções ao nível dos nós da rede (por exemplo, vacinação e isolamento) de forma “on-line” [Xue 2020]. O problema de planejamento foi reformulado como uma programação inteira linear mista, que pode ser resolvido por softwares comerciais disponíveis.

Capítulo 3

Modelagem da COVID-19 Baseada em Redes de Contato para a Cidade de São Paulo

Descreveremos agora os principais elementos que compõem nossa abordagem de planejamento: um modelo de transmissão de doenças baseado em rede de contato, as ações/intervenções e o modelo de custo.

3.1 Uma Rede de Contato para a Cidade de São Paulo

Utilizamos dados da pesquisa Origem-Destino da região metropolitana de São Paulo, conduzida em 2017, a fim de extrair uma rede de contato [Newman 2002, Keeling and Eames 2005] para a cidade. Essa pesquisa tem sido realizada a cada dez anos desde 1967, para apoiar a implementação de políticas públicas na área metropolitana.¹ A edição de 2017 coletou dados relacionados às tendências de mobilidade, incluindo local de residência, trabalho e escola/universidade, assim como tipo de ocupação, idade e renda de quase 87 mil indivíduos, em 32 mil domicílios. Isso nos fornece um quadro muito representativo dos padrões de interação dos habitantes da cidade, combinando informações espaciais, demográficas e regionais. O gráfico à direita na Figura 3.1 mostra a distribuição da localização dos domicílios dos indivíduos pesquisados em cada distrito da cidade.

Vale notar que, das 342 zonas da cidade, 13 não apresentaram dados associados (pintadas de cinza no mapa de calor). Apesar de não termos encontrado razão óbvia para esse fenômeno, os dados ainda são suficientes para modelar, de maneira adequada, a dinâmica das relações intra e inter zonas da cidade.

Usamos os dados para obter um *multigrafo* $G = (V, E)$, onde V denota o conjunto de indivíduos pesquisados v_1, v_2, \dots, v_N e E contém triplas (r, v_i, v_j) representando relações do

¹Os dados brutos e um resumo dos resultados da pesquisa OD 2017 foram obtidos através do site <https://bit.ly/38viIse>.




Figura 3.1: Esquerda: Histograma 2D de relações por distrito de residência
Direita: Número de indivíduos com residência em cada distrito

tipo r entre indivíduos v_i e v_j .² Cada nó está associado a informações pessoais disponíveis, tais como idade e tipo de trabalho, embora este último seja atualmente ignorado por nosso modelo. Consideramos quatro tipos de relações entre indivíduos (disponíveis a partir dos dados da pesquisa): escola, trabalho, vizinhança e casa, indicando, respectivamente, interações que ocorrem quando dois indivíduos frequentam a mesma escola/universidade, local de trabalho, lojas locais e compartilham uma mesma residência. Obtivemos as arestas em E de duas formas distintas. As relações domésticas foram obtidas conectando indivíduos com o mesmo identificador de domicílio no conjunto de dados. Para os outros tipos de relação, usamos um algoritmo de agrupamento k-means para agrupar indivíduos pela proximidade geográfica da relação correspondente (por exemplo, agrupando indivíduos que estudam em um local próximo); depois, conectamos os pares de indivíduos que foram agrupados em um mesmo cluster. Definimos os parâmetros do algoritmo de agrupamento de forma diferente para cada relação, procurando obter grupos realistas. Os grupos de colegas de classe (ou seja, do tipo de relação escolar) foram ainda subdivididos usando o nível de educação relatado individualmente, a fim de evitar grupos desproporcionalmente grandes em instituições educacionais com estudantes de vários níveis. Inicializamos os centros de agrupamento de acordo com os limites das zonas (que são aproximadamente subdivisões dos distritos mostrados na Figura 3.1) e definimos o valor de k do algoritmo, de modo que o tamanho médio μ dos agrupamentos resultantes satisfizesse: $\mu_{\text{casa}} < \mu_{\text{vizinhança}} < \mu_{\text{trabalho}} < \mu_{\text{escola}}$.

O grafo resultante é composto por 55 492 nós/indivíduos, dos quais 27 001 têm empregos e 12 605 são estudantes. Há 962 038 arestas e sua densidade é igual a 6×10^{-4} . A relação doméstica tem 61 634 arestas; a de vizinhança tem 348 835 arestas; a de trabalho tem 342 525 arestas e a escolar tem 209 044 arestas. Um resumo dessas informações está na Tabela 3.1. Nela, temos a relação de nós (indivíduos) e o número de arestas e seu grau médio (contatos) para cada uma das relações. Vale notar que 100% dos indivíduos possuem um domicílio associado; porém, nem todos têm arestas de relacionamento do tipo “Casa”, já que

²Alternativamente, pode-se pensar em G como uma coleção de grafos $G_r = (V, E_r)$, um para cada relação r .

estes, no caso, moram sozinhos. No caso das demais relações, os nós que não participam não são estudantes e/ou não possuem emprego. Porém, caso estudem ou trabalhem e não tenham aresta nas respectivas relações, estão geograficamente distantes dos demais indivíduos e, dessa forma, foram atribuídos a um cluster no qual são o único elemento pelo algoritmo. Este último comentário também se aplica àqueles que não possuem arestas de tipo vizinhança. Exemplos de ego networks resultantes podem ser observados na Figura 3.2. Essas redes foram amostradas de maneira aleatória, para fins de exemplificação. São compostas de um nó focal, ou ego, e outros nós diretamente conectados ao ego (chamados de “alters”). Também são apresentadas conexões existentes entre os “alters”. Cada nó foi pintado de acordo com o tipo de relação que possui com o ego. Vale notar que alguns nós podem partilhar mais de um tipo de relacionamento, porém, por questões práticas para a visualização, foram pintados de uma única cor. Por exemplo, na segunda figura, podemos inferir, pelas demais relações da ego network, que, apesar de pintado de vermelho, há um residente que também trabalha com o ego daquela rede. Ou seja, esse “alter” classificado na figura como residente poderia ter sido pintado de azul.

Relação	Nós (% da pop.)	Arestas (grau médio)
Casa	50 696 (91.35%)	61 634 (2.4)
Vizinhança	55 469 (99.95%)	348 835 (12.5)
Trabalho	26 998 (48.65%)	342 525 (25.3)
Escola	12 517 (22.55%)	209 044 (33.4)
Total	55 492 (100%)	962 038 (34.6)

Tabela 3.1: Estatísticas do grafo resultante

O histograma 2D à esquerda na Figura 3.1 mostra o número de relações de contato (isto é, número de arestas) entre os residentes pesquisados, em pares de distritos da cidade. Vemos que os contatos são mais frequentes entre indivíduos de um mesmo distrito, havendo vários distritos com forte conexão entre si. A distribuição das relações de contato, segmentadas por idade e tipo de relações, são apresentadas na Figura 3.3. Notavelmente, esses histogramas são muito semelhantes aos observados por Zhang et al. [Zhang et al. 2020] no que diz respeito à distribuição dos contatos por idade e ao efeito do fechamento dos locais de trabalho e das escolas. A alta simetria indica a importância de considerar a idade no controle da propagação.

3.2 Modelo de propagação da doença

Utilizamos um modelo epidemiológico estocástico compartimental, em que cada indivíduo v_i está associado a uma variável s_i^t que assume os valores SUSCETÍVEL, EXPOSTO (ou seja, infectado mas ainda não contagioso), INFECCIOSO (infectado e contagioso), HOSPITALIZADO e REMOVIDO (morto, ou recuperado e imune à doença), correspondendo a um estágio da doença no momento t , como ilustrado no diagrama da Figura 3.4 (auto-loops são omitidos para maior clareza).

O estado inicial de cada indivíduo s_i^0 é amostrado aleatoriamente, de tal forma que, em certos distritos (Morumbi, Vila Mariana e Jardins), 10 indivíduos, também aleatoriamente, começam no estado EXPOSTO, e os indivíduos restantes (nesses distritos e em todos os




Figura 3.2: Ego networks das relações de três indivíduos amostrados no grafo final




Figura 3.3: Histogramas das relações de contato com base nas idades para a rede




Figura 3.4: Simulação da evolução da doença COVID-19

demais) começam como SUSCETÍVEL. Seleccionamos os três distritos citados para início do surto, com base em dados oficiais.³ A variável $\rho_r^t \in [0, 1]$ denota a importância de uma relação r no passo t ; se $\rho_r^t = 0$, então a relação não está mais ativa (ou seja, não influencia a propagação da doença) e $\rho_r^t = r = 1$ denota que qualquer contato entre um indivíduo INFECCIOSO e um indivíduo SUSCETÍVEL resulta em este último se tornar um EXPOSTO.

Como discutiremos posteriormente, as ações de controle modificam os valores de infecciosidade das relações, de acordo com um conjunto predefinido de configurações possíveis. Assumimos que a infecciosidade na relação doméstica não pode ser modificada e permanece constante em $\rho_{\text{casa}} = 0.06$. Esse valor foi escolhido de acordo com estimativas recentes [Wang et al. 2020, Li et al. 2020]. A infecciosidade das relações restantes foi especificada de tal forma que o número básico de reprodução em nossas simulações se aproxima das estimativas da literatura [Mellan et al. 2020]. Isso implica ter $\rho_{\text{trabalho}} = 0.1\rho_{\text{casa}}$, $\rho_{\text{escola}} = 0.15\rho_{\text{casa}}$, $\rho_{\text{vizinhança}} = 0.1\rho_{\text{casa}}$. Na figura 3.6, à direita, temos o R_t , ou taxa de reprodução efetiva, estimado em 100 simulações do modelo, utilizando nível de mobilidade extraídos do relatório Google Mobility Trends. Para estimar o R_t (quantidade média de casos secundários gerado por um caso, em um dado dia t), criamos um contador, tanto para o dia de infecção de cada indivíduo, como para o número de contatos infectados com sucesso. Então, calculamos, retroativamente, a média de contatos infectados para cada grupo cujo início do período infeccioso se deu em cada valor de t .

Há também uma “probabilidade de infecção por vazamento”, $\lambda = 5e^{-5}$, que modela aproximadamente 2 indivíduos suscetíveis por dia serem infectados “espontaneamente”, ou seja, independentemente do estado de seus vizinhos. Isso contabiliza as fontes externas de infecção, como indivíduos infectados que se deslocam para a cidade de São Paulo. Assim, um indivíduo SUSCETÍVEL v_i é infectado de acordo com uma distribuição Noisy-Or onde cada vizinho INFECCIOSO, de maneira independente, “falha” em espalhar a doença para aquele indivíduo com probabilidade de $1 - \rho_r^t$:

$$\Pr(s_i^{t+1} = \text{EXPOSTO} \mid s_i^t = \text{SUSCETÍVEL}, \mathbf{s}^t, \rho^t) = 1 - (1 - \lambda) \prod_{\substack{(r, \{v_i, v_j\}) \in E, \\ s_j = \text{INFECCIOSO}}} (1 - \rho_r^t),$$

onde ρ^t é o vetor das relações infecciosas, e o produto percorre as arestas de incidência de v_i , cujo vizinho $v_j = \text{INFECCIOSO}$. Quando um indivíduo v_i é infectado (ou seja, muda de SUSCETÍVEL para EXPOSTO), um período de incubação β_i^t é amostrado a partir de uma distribuição normal truncada e arredondado para baixo (assumimos que a variável assume algum valor negativo arbitrário, antes que o indivíduo seja EXPOSTO). A variável é decrementada nas etapas subsequentes (desde que seja positiva). Se $\beta_i^t = 0$, o indivíduo v_i passa para o estado INFECCIOSO, e um período infeccioso γ_i^t é então amostrado de outra distribuição normal truncada (e arredondado para baixo). A variável γ_i^t também é decrementada a cada passo, e, quando chega a zero, o indivíduo INFECCIOSO torna-se HOSPITALIZADO, com a probabilidade dependente da idade, dada na Tabela 3.2 (esquerda), extraída de estimativas do relatório [Ferguson et al. 2020]. Se o indivíduo se torna HOSPITALIZADO, um valor η_i^t é amostrado a partir de uma distribuição normal truncada, que determina o tempo de

³Esses eram os 3 distritos com maior incidência de casos no primeiro relatório oficial: <https://bit.ly/3e0tvvH>.

internação hospitalar. Se o indivíduo não se torna HOSPITALIZADO, definimos $\eta_i^t = 0$. Em ambos os casos, quando $\eta_i^t = 0$, o indivíduo se torna REMOVIDO. As médias e desvios padrão das distribuições normais para os valores iniciais de β_i^t , γ_i^t e η_i^t foram selecionados de modo a refletir as estimativas em [Linton and et al. 2020], e são dados na Tabela 3.2 (direita). As variáveis aleatórias correspondentes são truncadas abaixo de dois dias e acima do valor do percentil 99, de acordo com a distribuição normal, a fim de evitar cenários não realistas. O procedimento é descrito pelo pseudo-código na Figura 3.4. Note que o pseudo-código descreve uma etapa (um dia) da evolução da doença.

Idade (anos)	Probabilidade de hospitalização
0 to 9	0.1%
10 to 19	0.3%
20 to 29	1.2%
30 to 39	3.2%
40 to 49	4.9%
50 to 59	10.2%
60 to 69	16.6%
70 to 79	24.3%
80+	27.3%

Parâmetros	Média	Desvio Padrão	Suporte
Período de incubação (β)	5.6	2.8	[2, 15]
Período infeccioso (γ)	6.2	4.3	[2, 22]
Duração da hospitalização (η)	8.6	6.7	[2, 33]

Tabela 3.2: Esquerda: Probabilidades de necessidade de hospitalização
Direita: Parâmetros das distribuições normais truncadas (em dias)

A figura 3.5 (esquerda) mostra a curva epidemiológica média de nosso modelo para 10 simulações (observar as diferentes escalas para proporções de expostos e hospitalizados). É possível notar o delay entre a curva de indivíduos expostos e a de hospitalizados, o que também é observado em dados reais. Esse comportamento torna desafiador o planejamento de medidas de intervenção, já que o número atual de hospitalizados, na realidade, é reflexo do número de expostos em um período anterior. A Figura 3.9 mostra o número de indivíduos expostos e/ou infectados em cada distrito em diferentes fases da epidemia, em uma simulação amostrada. A epidemia progride a partir dos distritos mais centrais (aqueles que tiveram os pacientes iniciais e suas adjacências), em direção à periferia.

O número de leitos disponíveis na cidade é de cerca de 0.25 por 100 habitantes, de acordo com dados oficiais.⁴ Em condições normais (sem a presença da COVID-19), grande parte desses leitos encontra-se ocupada. Por outro lado, medidas de distanciamento social, muitas vezes, levam à diminuição de outros eventos causadores de hospitalização (por exemplo, acidentes de carro), além de ser esperado que novos leitos hospitalares sejam criados em tempos de epidemia.⁵ Neste trabalho, consideramos o número de leitos hospitalares disponíveis para os pacientes da COVID-19 como sendo 60% da capacidade total citada anteriormente (cerca de 0.15 por 100 habitantes). Esse valor é indicado pela linha tracejada na Figura 3.5 (e nos próximos gráficos semelhantes). Pode-se observar que o número de internações supera amplamente a capacidade hospitalar quando nenhuma medida de contenção é imposta.

A fim de verificar a validade do modelo proposto, simulamos a doença usando índices

⁴Isso foi anterior ao início do surto, de acordo com os dados em <https://bit.ly/2AAx0vc>.

⁵De acordo com dados oficiais, o número de leitos de UTI para pacientes da COVID-19 na cidade de São Paulo dobrou desde o início do surto (veja <https://bit.ly/2NYMqMQ>), enquanto o número de acidentes de trânsito diminuiu 30%, de acordo com as notícias locais (por exemplo, <https://glo.bo/3f2J2MO>).




Figura 3.5: Curva epidemiológica simulada do modelo irrestrito




Figura 3.6: Taxa de mobilidade para a cidade de SP no período




Figura 3.7: R_t simulado a partir das taxas de mobilidade




Figura 3.8: Número de internações observadas comparado às simuladas




Figura 3.9: Número de indivíduos infectados em cada distrito após 0, 4, 8, 12 e 18 semanas simuladas

reais de isolamento, extraídos de dados de telefones celulares, conforme a Figura 3.6. A cada dia, dimensionamos o valor de infecciosidade de cada relação pela respectiva redução de mobilidade, conforme relatado pelo Relatório de Tendências de Mobilidade do Google (<https://bit.ly/2NX40kj>). Ou seja, se o índice de mobilidade para uma dada relação caiu em uma certa porcentagem em um dado dia, a sua infecciosidade foi reduzida na mesma proporção. Para as relações escolares, que não são mapeadas pelo relatório do Google, usamos os valores de base durante os dias úteis (com atividade escolar) e reduzimos esses valores durante os fins de semana anteriores a 23 de março, quando as aulas foram suspensas (<https://glo.bo/2VQ0lJg>). Consequentemente, após essa data, a infecciosidade da relação vai a zero. Já para as relações de vizinhança, foi utilizada a média entre as relações de comércio/serviços; recreação; supermercados/farmácias e parques. Nas relações de trabalho, que são diretamente mapeadas no relatório, utilizamos seus valores brutos. Finalmente, apesar de, no período, as relações residenciais terem aumentado em intensidade, seu valor basal foi mantido constante para as simulações. Os valores obtidos da variação de mobilidade para cada relação em comparação ao nível basal podem ser observados na Figura 3.6.

A Figura 3.8 compara o número observado de internações devido à SRAG (Síndrome Respiratória Aguda Grave) ao número médio e desvio padrão de indivíduos internados em 10 simulações do nosso modelo, utilizando as restrições estimadas através do relatório do Google.⁶ É possível notar que as curvas se mantêm próximas durante todo o período, mostrando que o modelo é um bom preditor do número de hospitalizados, de acordo com a fase da epidemia e a taxa de mobilidade.

3.3 Intervenções

Assumimos que o responsável pela tomada de decisões age de modo a modificar a infecciosidade das relações ρ_t^i , utilizando intervenções a nível populacional como: incentivo ao distanciamento social, conscientização pública, fechamento de escolas, universidades ou locais de trabalho, restrição do tráfego urbano, proibição de reuniões públicas ou imposição de bloqueio em toda a cidade. Essas ações acontecem de imediato e duram um número fixo de dias (uma semana, em nossos experimentos). Assumimos que são aplicadas a todos os indivíduos, indiferentemente, e não modificam a infecciosidade da relação doméstica. Para

⁶Usamos as estimativas históricas do Observatório COVID-19 (<https://bit.ly/2O0CrX6>) reportadas no dia 24 de julho de 2020 como valores observados.

as demais relações, consideramos as seguintes cinco intervenções/ações, selecionadas para simular as possíveis medidas de mitigação anunciadas pelas autoridades da cidade:

- **Contato Irrestrito:** A infecciosidade de todas as relações é mantida nos seus valores basais.
- **Distanciamento Social:** Reduzimos em 20% a infecciosidade no trabalho, na escola e na vizinhança, em relação aos seus valores basais. Isso simula a sensibilização da população e a proibição de grandes reuniões públicas, deixando as escolas e o comércio/serviços abertos.
- **Quarentena Leve:** Reduzimos em 40% a infecciosidade no trabalho e na vizinhança e atribuímos valor zero à infecciosidade nas relações escolares. Isso simula o fechamento de escolas, universidades e parte do comércio/serviços, proibindo grandes reuniões públicas e aumentando a conscientização do público.
- **Quarentena Severa:** Reduzimos em 70% a infecciosidade no trabalho e na vizinhança e atribuímos valor zero à infecciosidade nas relações escolares. Essa é uma versão mais rigorosa da intervenção anterior, na qual apenas os trabalhadores de serviços essenciais se deslocam e a mobilidade na cidade é limitada.
- **Lockdown:** Reduzimos em 90% a infecciosidade no trabalho e na vizinhança e atribuímos valor zero à infecciosidade nas relações escolares. Isso modela uma situação em que apenas trabalhadores de serviços extremamente essenciais são autorizados a transitar.

Vale notar que a redução da infecciosidade, como relatada nos diferentes níveis de restrição acima, não significa, necessariamente, uma mudança na forma intrínseca como se dão as relações, mas pode também denotar a interrupção momentânea de parte dessas mesmas relações. Ou seja, uma redução da infecciosidade das relações de trabalho pode indicar tanto a utilização de máscaras e outras medidas profiláticas, como também relações de trabalho presenciais que deixaram de existir em dado período, por exemplo, devido a mudança para regime de home-office.

3.4 Modelagem dos custos

A construção de um modelo de custos para a pandemia é tarefa árdua, pois deve favorecer a minimização das infecções, sem impor uma carga excessiva à economia. Dessa forma, criamos dois modelos em conjunto: o dos custos sanitários e o dos econômicos. Aqui damos especial atenção à prevenção do colapso do sistema de saúde, medido pela proporção de leitos hospitalares disponíveis. Lembramos que assumimos a disponibilidade de 0.15 camas hospitalares por 100 indivíduos (para pacientes com COVID-19). Assim, especificamos o custo de uma porcentagem h da população no estado HOSPITALIZADO em um determinado dia, pela curva sigmóide $1/(1 + \exp(-44h + 6))$, mostrada na Figura 3.10 (esquerda).

Assumimos que, *ceteris paribus*, é preferível uma medida de contenção mais branda a uma mais severa, de maneira a resguardar a economia. Adotamos uma abordagem pragmática/utilitária, na qual o custo de uma intervenção reflete o número de hospitalizações que estamos dispostos a tolerar por esse nível de restrições econômicas. Dessa forma, o




Figura 3.10: Esquerda: Custo das intervenções e hospitalizações
Direita: Estratégias de mitigação (reativas) basais

custo das intervenções é proporcional à sua capacidade de reduzir a infecciosidade. O intuito não é, necessariamente, capturar uma estimativa realista do impacto econômico de hospitalizações e intervenções, mas regular o contágio da doença dentro de níveis aceitáveis de hospitalizados, gerando o menor impacto possível à vida urbana.

Definimos os custos das intervenções de Distanciamento Social, Quarentena Leve, Quarentena Severa e Lockdown, respectivamente, de modo a igualar os custos de 0,05%, 0,1%, 0,125% e 0,15% da população hospitalizada (como dado pela função sigmóide). Por exemplo, o custo do Lockdown é equivalente ao custo de 100% de ocupação dos leitos, segundo nossa estimativa, disponíveis ao tratamento da COVID-19. O custo da ação de Contato Irrestrito é zero. Finalmente, especificamos o custo total em um determinado passo da simulação como o máximo entre o custo da intervenção e o custo do número de indivíduos hospitalizados. Também experimentamos adicionar estes dois custos, mas observamos melhores resultados com o máximo.

Capítulo 4

Otimização das intervenções

Agora estamos prontos para comparar diferentes estratégias capazes de mitigar o surto, de acordo com nosso modelo. Assumimos que uma etapa de decisão leva sete dias de simulação, o que significa que um plano de intervenção, uma vez selecionado, permanece em vigor por uma semana.

Primeiro consideramos duas políticas reativas de referência, que adotam regras manuais da forma “Se a porcentagem de indivíduos hospitalizados estiver em um determinado intervalo, então adote a seguinte medida de intervenção”, como mostrado na Figura 3.10 (direita). Os intervalos correspondentes foram definidos com base na função de custo e em algumas tentativas e erros, para manter o número de hospitalizados com limites razoáveis.

As Figuras 4.1 e 4.2 apresentam as curvas da proporção de hospitalizados por dia, de 10 simulações das estratégias de referência, ao longo de 52 semanas (1 ano). A curva preta denota a simulação com o custo mediano. Para essas simulações, pintamos o fundo de cada semana, a fim de indicar a ação correspondente (indicada pelo código de cores usado na Figura 3.10). Ambas as estratégias de referência conduzem a um comportamento oscilatório da curva de hospitalizados, com vários picos e vales no número de internações. Elas também conduzem a um número de hospitalizações acima da capacidade por curto período de tempo para algumas simulações, com a estratégia de referência 1, proposta para manter o caso mediano sempre abaixo da capacidade, e a estratégia de referência 2, proposta para exceder essa capacidade para a curva mediana. Os resultados mostram que o plano da estratégia de referência 1 é uma medida de controle mais agressiva, com Lockdowns e Quarentenas Severas sendo usados mesmo após passado um longo período do início do surto (quando o número de suscetíveis se reduz consideravelmente, ocasionando uma diminuição natural no número de hospitalizados); paradoxalmente há mais períodos com Contato Irrestrito. O plano da estratégia de referência 2, por outro lado, consegue reduzir o número de picos, ao mesmo tempo que utiliza medidas de contingência menos rigorosas. Em ambos os casos, porém, em diversas simulações, há um pico de hospitalizados entre a 6^a e a 10^a semanas, que ultrapassa a capacidade hospitalar. Esse fato é mais acentuado na estratégia de referência 2.

Em seguida, consideramos estratégias otimizadas, utilizando uma versão simplificada




Figura 4.1: *Curvas de hospitalizados para as estratégias de referência 1*




Figura 4.2: *Curvas de hospitalizados para as estratégias de referência 2*

do algoritmo de Sparse Sampling com modelo generativo (simulador), de maneira similar à proposta por Kearns et al. [M. KEARNS and NG 2002], sem heurística. Esse tipo de técnica foi adotada já que, mesmo com o conjunto de ações limitado a apenas 5, temos um ambiente estocástico, com um espaço de estados de dimensão muito grande, o que torna inaplicáveis algoritmos tradicionais de planejamento e reinforcement learning.

Em cada etapa de decisão (ou seja, início de uma semana), consideramos todos os possíveis planos futuros com horizonte H , isto é, todas as sequências de intervenções de tamanho igual a H semanas, nas quais cada intervenção subsequente aumenta, mantém ou reduz o nível de restrição da intervenção anterior. Por exemplo, uma semana cuja ação é de Quarentena Severa pode ter, na semana seguinte, as ações de Lockdown, manutenção da Quarentena Severa ou Quarentena Leve.

O planejador recebe uma matriz M de dimensão $N \times 5$, sendo N o número de indivíduos na rede, contendo as seguintes informações a respeito de cada um: identificador único; estado atual (SUSCETÍVEL, EXPOSTO, INFECCIOSO, HOSPITALIZADO OU REMOVIDO); valor do período correspondente ao seu estado atual (-1 se SUSCETÍVEL ou REMOVIDO, ou os valores amostrados para os períodos de incubação, infecciosidade e hospitalização β, γ, η); dia em que ocorreu a infecção (-1 caso não tenha sido infectado); idade. Esses dados poderiam ter sido guardados como atributos dos nós do grafo; porém, foi escolhido o formato matricial, já que permite que as operações sobre ele sejam mais performáticas. A informação sobre dia de infecção foi apenas utilizada para análises descritivas das simulações e para cálculo do R_t . As demais descrevem as características essenciais de cada indivíduo e, em conjunto com as arestas do grafo, que codificam os relacionamentos, são utilizadas para executar as simulações.

Esses dados são armazenados no nó raiz n_0 e são sempre utilizados como ponto de partida para as simulações. O caminho do nó raiz até qualquer outro nó na árvore de ações codifica um plano, ou seja, uma sequência de ações. O nó raiz representa o estado atual antes de qualquer nova ação ser tomada; portanto, representa um plano vazio.

O gráfico à esquerda na Figura 4.6 ilustra a construção da grafo direcionado acíclico, representando os possíveis planos, descrito pelo pseudo-código à direita. Escolhemos um horizonte H , que define quantas semanas ou ações serão avaliadas. Isso é equivalente a determinar quantos níveis da árvore, a partir do nó raiz, serão explorados. Cada iteração consiste em executar a função “ExpandirÁrvore” H vezes. Em seguida, para cada novo nó folha resultante, são executadas as funções “Simular”, para cada ação do plano da raiz até o nó folha, e o custo é acumulado. Então, o nó de nível 1 que possui o nó folha de menor custo é selecionado.

A função “ExpandirÁrvore” cria os nós filhos para todos os atuais nós folha da árvore, e repete este processo de maneira iterativa, até que a altura da árvore seja igual ao horizonte predefinido. Caso a árvore contenha apenas o nó raiz, são criados 5 nós filhos, um para cada uma das ações possíveis (Contato Irrestrito, Distanciamento Social, Quarentena Leve, Quarentena Severa e Lockdown). Para os demais nós, serão criados 3 nós filhos, sendo que cada um aumenta, mantém ou reduz o nível de restrição do nó sendo expandido. Isso é equivalente a dizer que, em cada iteração desta função, um novo nível da árvore é criado de maneira exaustiva, levando em conta a restrição de, após o primeiro nível, cada nó possuir 3 filhos. O Algoritmo foi construído dessa forma para manter certo nível de

verossimilhança nos planos gerados, além de limitar o crescimento exponencial do número de nós. Vale notar que, na árvore apresentada na Figura 4.6, filhos de nível 2 e 3 foram omitidos para maior clareza da figura.

Então, com a árvore de altura igual a H , para cada nó filho, executamos S simulações com o plano correspondente. Isso equivale a dizer que, partindo do nó raiz em direção ao nó folha sendo simulado, executamos, em sequência, a simulação de cada uma das H semanas, aplicando a ação de cada nó do caminho e atualizando uma cópia da matriz da população. Assim, para uma árvore de altura H , teremos 5×3^H nós folhas, cada um codificando um plano de H semanas, contendo H ações a partir do estado inicial do nó raiz.

Cada nó folha é simulado S vezes por H semanas. O custo de cada simulação é então avaliado, como $\sum_{k=0}^h 0.8^k \cdot \text{custo}_k$, onde custo_k denota o custo de 7 dias para a k -ésima semana de simulação. Essa função custo aplica um *fator de desconto* de 0.8 a cada semana futura, de maneira a priorizar os custos das semanas mais próximas à semana atual. Finalmente, a cada uma das S simulações, o custo simulado é atribuído ao nó folha sendo simulado. Após todos os nós folha terem sido simulados, o de menor custo médio é selecionado e a ação correspondente de seu antepassado do nível 1 é executada.

Observe-se que o custo de um plano é a soma dos custos dos dias no período (já que cada etapa de decisão se estende por uma semana), que por sua vez é o valor máximo entre o custo da ação e o custo de hospitalizados, conforme descrito anteriormente. Em resumo, realizamos uma busca em largura on-line de planos de H passos, que são avaliados de acordo com as estimativas de custo de Monte Carlo (sobre S simulações).¹

Em nossos experimentos, usamos $S = 48$ simulações com $H = 2, 3, 4$ semanas. Aumentar ainda mais H foi computacionalmente muito caro. Com $S = 48$ e $H = 4$, uma simulação completa de 52 semanas (com planejamento on-line) levou em média 5 horas para ser concluída em uma máquina de ponta com CPU AMD Threadripper 3960x 24-core.

As figuras 4.3, 4.4 e 4.5 apresentam as curvas de hospitalizados por dia para 10 simulações das estratégias otimizadas (em azul), com $S = 48$ e horizontes de planejamento $H = 2$, $H = 3$ e $H = 4$. Como antes, a linha preta mostra a simulação com o custo mediano, e o fundo é pintado de acordo com as ações usadas naquela simulação. O primeiro fato relevante é que um maior horizonte H leva a um desempenho superior, como esperado.

A estratégia com $H = 4$ é capaz de manter as hospitalizados abaixo da capacidade para quase todas as simulações em todos os dias (note o pequeno excesso em uma única curva por um único dia), sem recorrer à medida de Lockdown e aplicando a Quarentena Severa apenas uma vez.

O aumento do valor de H gerou planos que tomam medidas restritivas mais cedo. As estratégias otimizadas com $H = 2$, $H = 3$ e $H = 4$ levaram, em média, 5, 4.2 e 3.3 semanas, respectivamente, para impor a primeira medida de restrição. Um horizonte mais longo também levou a medidas de restrição mais duradouras. A primeira medida de restrição permaneceu ativa, em média, por 12.3, 16.1 e 22.2 semanas por $H = 2$, $H = 3$ e $H = 4$,

¹O código fonte utilizado pode ser encontrado em <https://github.com/yambanis/CovidMDP>

respectivamente.

Para se ter uma comparação mais objetiva entre as diferentes estratégias, calculamos a utilização média do sistema de saúde, dada pela diferença absoluta entre o número e a capacidade de internações, bem como a sobrecarga hospitalar, dada pela área da curva acima do limite da capacidade. Essas medidas, que não são diretamente otimizadas pelos planejadores de Monte Carlo, medem o equilíbrio entre o rigor das medidas de intervenção e o impacto no número de leitos disponíveis. Na Tabela 4.1, mostramos os resultados e o custo total das ações executadas. Mais uma vez salientamos que os custos totais são a somatória dos custos de cada dia, sendo estes o máximo entre o custo de hospitalizados e da ação vigente.

Em relação às estratégias de referência, vemos que as estratégias otimizadas obtêm um equilíbrio muito melhor entre os custos econômicos e o número de internações. O planejador com $H = 4$, em particular, obteve diminuição na utilização média e redução acentuada na sobrecarga hospitalar, chegando próximo a zero. Observe-se que os pequenos desvios padrão sugerem que esses resultados são robustos em diferentes simulações. Finalmente, a estratégia otimizada com $H = 4$ minimizou o custo (como esperado).

Estratégia	Utilização	Sobrecarga Hospitalar	Custo
Irrestrito	1.85±0.027	293.8±9.0	81.2±1.9
Referência 1	1.07±0.012	0.586±1.04	95.2±3.7
Referência 2	1.01±0.02	1.775±1.882	69.5±4.0
H=2, S=48	0.73±0.102	14.7±18.2	68.8±5.3
H=3, S=48	0.71± 0.023	1.3± 2.5	53.9±3.0
H=4, S=48	0.74±0.029	0.003± 0.01	49.2±2.2

Tabela 4.1: Performance das estratégias de mitigação




Figura 4.3: Curva de hospitalizados do planejador para $H=2$




Figura 4.4: Curva de hospitalizados do planejador para $H=3$




Figura 4.5: Curva de hospitalizados do planejador para H=4




Figura 4.6: Ilustração da árvore de ações com horizonte igual a 3

```
A, n0 ← CriarÁrvore(M)
Para h = 1, 2..., H
  ExpandirÁrvore(A)
FimPara
Para cada n' em nósFolha(A)
  custo(n') ← 0
  Para s = 1, 2..., S
    e ← Estado(n0)
    Para cada ação em Plano(n0, n')
      e, c ← Simular(e, ação)
      custo(n') ← custo(n') + c
    FimPara
  FimPara
FimPara
Retornar FilhoMenorCusto(n0)
```

Figura 4.7: Pseudo código para o planejador

Capítulo 5

Conclusões e trabalhos futuros

Neste trabalho, utilizamos dados da pesquisa Origem-Destino da região metropolitana de São Paulo, conduzida em 2017, para construir uma rede de contato de uma amostra dos indivíduos da cidade de São Paulo, segmentada por diferentes tipos de relações (escola, trabalho, vizinhança, casa). A rede de contato foi, então, utilizada para desenvolver um modelo epidemiológico da COVID-19 a nível individual.

Os parâmetros do modelo foram selecionados de acordo com dados reportados recentemente e validados em relação a dados do mundo real, proporcionando realismo às simulações. Comparamos estratégias de mitigação baseadas em regras (reativas) com planos on-line, otimizados por uma abordagem de Monte Carlo. Nossos resultados mostraram que as políticas otimizadas conseguem controlar a propagação da doença dentro da capacidade do sistema de saúde, minimizando, ao mesmo tempo, os impactos econômicos das políticas de distanciamento social. Até onde sabemos, este é o primeiro trabalho a aplicar o planejamento automatizado para o controle da COVID-19 dentro da cidade de São Paulo.

Vale notar que, apesar de muito esforço ter sido direcionado para a construção de um grafo realista das relações e indivíduos de São Paulo, poderíamos substituí-lo por outras redes, com eventual ajuste dos demais parâmetros, para aplicar nossa abordagem em outras cidades ou contextos, com a reutilização de grande parte do código criado. Seria ainda possível alterar os valores da capacidade hospitalar, caso fosse desejável a criação de um planejador mais ou menos cauteloso ou nos baseássemos em outras fontes de dados.

Definimos aqui cinco ações possíveis de intervenção, de modo a aumentar a explicabilidade do modelo, relacionando porcentagens de restrição em cada uma das relações a um nome facilmente interpretável. Porém, uma opção viável seria a otimização em relação a valores contínuos de cada uma das variáveis, aumentando o espaço de busca e, conseqüentemente, a complexidade computacional. Caso nossa abordagem fosse utilizada em um contexto real, a maior complexidade poderia ser solucionada utilizando mais recursos, como computação paralela em nuvem.

Uma ressalva a nossa abordagem é a suposição de que são observáveis o estado de cada indivíduo da população (suscetíveis, expostos, infecciosos, hospitalizados e removidos). Embora tal informação não esteja disponível, ela pode ser estimada de forma confiável

testando regularmente uma amostra da população e, depois, atribuindo aleatoriamente os indivíduos em nossa rede, de acordo com a estimativa amostral (seguindo a distribuição de idade, características geográficas etc.).

Há várias melhorias viáveis para tornar nosso modelo ainda mais realista. Por exemplo, distinguir o comportamento epidemiológico entre indivíduos sintomáticos e assintomáticos; condicionar a infecciosidade de um contato à idade; incorporar informações de renda dos indivíduos e seus efeitos na disponibilidade de leitos. Seria também possível aperfeiçoar nosso modelo de custos, incorporando recursos limitantes não explorados inicialmente (número de testes disponíveis, leitos de UTI, EPIs, etc.). Outra abordagem relevante para maior verossimilhança seria distinguir as relações de trabalho por setores (essencial/não essencial, comércio, indústria etc.). Finalmente, considerando o planejador, seria interessante explorar técnicas mais sofisticadas de planejamento on-line; extrair políticas off-line e usar valores de horizonte de simulação maiores.

Agradecimentos

À Universidade de São Paulo e ao Instituto de Matemática e Estatística pela oportunidade de cursar o Bacharelado em Ciência da Computação.

Aos meus orientadores Prof. Dr. Denis e Profa. Dr^a. Leliane, pela orientação, paciência e parceria durante todo o processo.

À minha mãe, Prof^a. Cristina Yambanis, pelo auxílio na revisão do texto.

Este trabalho teve o apoio parcial das Bolsas #304012/2019-0 e #307979/2018-0 da CNPq e o financiamento CAPES código 001.

Referências Bibliográficas

- [Bai et al. 2007] Bai, W., Zhou, T., and Wang, B. (2007). Immunization of susceptible–infected model on scale-free networks. *Physica A: Statistical Mech. and Its Applications*, 384:656–662.
- [Dureau et al. 2013] Dureau, J., Kalogeropoulos, K., and Baguelin, M. (2013). Capturing the time-varying drivers of an epidemic using stochastic dynamical systems. *Biostatistics*, 14:541–55.
- [Ferguson et al. 2020] Ferguson, N. M., Laydon, D., and et al. (2020). Report 9: Impact of non-pharmaceutical interventions to reduce COVID-19 mortality and healthcare demand. Technical report, Imperial College London.
- [Halloran et al. 2002] Halloran, M., Longini, I., Nizam, A., and Yang, Y. (2002). Containing bioterrorist smallpox. *Science*, 298:1428–1432.
- [Jarvis et al. 2020] Jarvis, C. I., Van Zandvoort, K., Gimma, A., Prem, K., Klepac, P., Rubin, G., and Edmunds, W. (2020). Quantifying the impact of physical distance measures on the transmission of COVID-19 in the UK. Technical report, CMMID COVID-19 working group. medRxiv 2020.03.31.20049023.
- [Keeling and Eames 2005] Keeling, M. and Eames, K. (2005). Networks and epidemic models. *Journal of the Royal Societcity Interface*, 2:295–307.
- [Kermack and McKendrick 1927] Kermack, W. O. and McKendrick, A. G. (1927). A contribution to the mathematical theory of epidemics. *Proceedings of the Royal Society A*, 115(772):700–721.
- [Kinathil et al. 2017] Kinathil, S., Soh, H., and Sanner, S. (2017). Nonlinear optimization and symbolic dynamic programming for parameterized hybrid markov decision processes. In *AAAI-17 Workshop on Symbolic Inference and Optimization*.
- [Kucharski et al. 2020] Kucharski, A. J., Russell, T. W., and et al. (2020). Early dynamics of transmission and control of COVID-19: a mathematical modelling study. *The Lancet Infectious Diseases*, 20(5):553–558.
- [Li et al. 2020] Li, W., Zhang, B., Lu, J., Liu, S., Chang, Z., Cao, P., Liu, X., Zhang, P., Ling, Y., Tao, K., and Chen, J. (2020). The characteristics of household transmission of COVID-19. *Clinical infectious diseases*.
- [Linton and et al. 2020] Linton, N. M. and et al. (2020). Incubation period and other epidemiological characteristics of 2019 novel coronavirus infections with right truncation:

- A statistical analysis of publicly available case data. *MDPI, Multidisciplinary Digital Publishing Institute*.
- [M. KEARNS and NG 2002] M. KEARNS, Y. M. and NG, A. (2002). A sparse sampling algorithm for near-optimal planning in large markov decision processes. *Machine Learning, Kluwer Academic Publishers*, 49:193–208.
- [Mellan et al. 2020] Mellan, T. A., Hoeltgebaum, H. H., Mishra, S., and et al. (2020). Estimating COVID-19 cases and reproduction number in Brazil. Technical report, Imperial College London.
- [Meyers et al. 2005] Meyers, L., Pourbohloul, B., Newman, M., Skowronski, D., and Brunham, R. (2005). Network theory and SARS: predicting outbreak diversity. *Journal of Theoretical Biology*, 232:71–81.
- [Newman 2002] Newman, M. (2002). Spread of epidemic disease on networks. *Physical Review E*, 66.
- [Sanner et al. 2011] Sanner, S., Delgado, K., , and Nunes de Barros, L. (2011). Symbolic dynamic programming for discrete and continuous state MDPs. In *Proceedings of the Conference on Uncertainty in Artificial Intelligence*, pages 1–10.
- [Silva et al. 2020] Silva, P. J. S. S., Pereira, T., and Nonato, L. G. (2020). Robot dance: a city-wise automatic control of COVID-19 mitigation levels. Technical report, Unicamp. medRxiv 2020.05.11.20098541.
- [Thomaz et al. 2020] Thomaz, G., Mauá, D., and Barros, L. (2020). A contact network-based approach for online planning of containment measures for covid-19. In *Anais do XVII Encontro Nacional de Inteligência Artificial e Computacional*, pages 234–245, Porto Alegre, RS, Brasil. SBC.
- [Wang et al. 2020] Wang, Z., Ma, W., Zheng, X., Wu, G., and Zhang, R. (2020). Household transmission of SARS-CoV-2. *The Journal of infection*, 81(1):179–182.
- [Xue 2020] Xue, S. (2020). *Scheduling and Online Planning in Stochastic Diffusion Networks*. PhD thesis, Oregon State University.
- [Zhang et al. 2020] Zhang, J., Litvinova, M., Liang, Y., Wang, Y., Wang, W., Zhao, S., Wu, Q., Merler, S., Viboud, C., Vespignani, A., Ajelli, M., and Yu, H. (2020). Changes in contact patterns shape the dynamics of the COVID-19 outbreak in China. *Science*, 368(6498):1481–1486.