



Universidade Federal do Pará
Laboratório de Tecnologias Sociais

Análise da evolução da pandemia de COVID-19 no Brasil – O Estado do Pará

Elaborada por:

Prof. Dr. Carlos Renato Lisboa Francês¹ (rfrances@ufpa.br)

CV Lattes: <http://lattes.cnpq.br/7458287841862567>

Prof. Dr. Marcelino Silva da Silva¹ (marcelino@ufpa.br)

CV Lattes: <http://lattes.cnpq.br/7080513172499497>

Prof. Dr. André Carlos Ponce de Leon Ferreira de Carvalho² (andre@icmc.usp.br)

CV Lattes: <http://lattes.cnpq.br/9674541381385819>

Prof. Dr. Solon Venâncio Carvalho³ (solon@lac.inpe.br)

CV Lattes: <http://lattes.cnpq.br/3368137994024629>

Prof. Dr. Nandamudi Lankalapalli Vijaykumar⁴ (vijay.nl@inpe.br)

CV Lattes: <http://lattes.cnpq.br/9922863822347014>

Profª. Ma. e doutoranda Evelin Helena Silva Cardoso¹ (evelinhelena@ufpa.br)

CV Lattes: <http://lattes.cnpq.br/5388902706205997>

Profª. Ma. e doutoranda Maria da Penha de Andrade Abi Harb¹ (mpenha@ufpa.br)

Profª. Ma. e doutoranda Lena Veiga e Silva¹ (lenaveiga@ufpa.br)

CV Lattes: <http://lattes.cnpq.br/0072033667848347>

Doutoranda Aurea Milene Teixeira Barbosa dos Santo¹ (aurea.mile@gmail.com)

CV Lattes: <http://lattes.cnpq.br/5313442765630737>

Mestrando Carlos André de Mattos Teixeira¹ (carlos.mattos@itec.ufpa.br)

CV Lattes: <http://lattes.cnpq.br/5642339206700236>

Mestrando Vitor Hugo Macedo Gomes¹ (hugom4cedo@gmail.com)

CV Lattes: <http://lattes.cnpq.br/3621131132892879>

1 - Universidade Federal do Pará (UFPA)

2 – Universidade de São Paulo (USP)

3 – Instituto Nacional de Pesquisas Espaciais (INPE)

4 – Universidade Federal de São Paulo (UNIFESP)

1. Introdução

No final do ano de 2019, uma pneumonia de causa desconhecida foi detectada na província de Wuhan (China) e relatada pela primeira vez à Organização Mundial de Saúde (OMS) no dia 31 de dezembro de 2019. O que começou como uma doença misteriosa, foi referida primeiramente como 2019-nCoV, doença causada pelo novo coronavírus (Sars-Cov-2) e se tornou mundialmente conhecida como COVID-19. Apenas um mês depois (30 de janeiro de 2020), a OMS declarou que o surto da doença constituía uma Emergência de Saúde Pública de Importância Internacional – o mais alto nível de alerta da Organização e, em 11 de março de 2020, a COVID-19 foi caracterizada oficialmente como uma pandemia [1].

Desde então, o mundo enfrenta uma emergência de saúde pública, com poder devastador ainda não experimentado em um passado recente. O novo coronavírus é uma doença respiratória aguda e, por vezes, grave, podendo levar o infectado a óbito. A transmissão interpessoal ocorre pelo contato com secreções contaminadas, principalmente pelo contato com grandes gotículas respiratórias, mas também pode ocorrer por meio do contato com uma superfície contaminada [2]. Seu alto poder de espalhamento requer uma atenção especial das autoridades internacionais, devido ao seu efeito nos sistemas de saúde, sobrecarregando os mesmos, podendo levá-los ao colapso. Assim, exige das autoridades públicas ações imediatas para minimizar os efeitos da doença e atenuar a curva de contágio, reduzindo a disseminação incontrolável da doença e o número de óbitos [3].

Embora a transmissão da doença fora da Ásia tenha sido inicialmente centrada na Europa ocidental e na América do Norte, uma grande expansão significativa é vista em outras partes do mundo, incluindo países da África e América Latina [4]. Hoje, um dos países que têm chamado a atenção do mundo inteiro é o Brasil. Até a presente data (01/06/2020), o país é o quarto maior em número absoluto de mortes em decorrência do novo coronavírus e ocupa o segundo lugar no ranking de casos confirmados. Segundo o portal Coronavírus Brasil, do Ministério da Saúde, são 514.819 casos confirmados e 29.314 óbitos.

A crise do novo coronavírus só reforça a desigualdade entre países desenvolvidos e subdesenvolvidos. O enfrentamento da doença é um processo muito custoso e tende a sobrecarregar o sistema de saúde, tornando mais evidentes suas fragilidades. A construção de hospitais, a produção/aquisição de equipamentos e insumos médicos e a manutenção dos serviços essenciais em meio à crise têm drenado o caixa dos países, com efeitos ainda mais graves naqueles com piores situações econômicas.

Na ausência de intervenções farmacológicas, como medicamentos amplamente aceitos ou o uso de vacinas, as chamadas Intervenções Não Farmacêuticas (NPIs, *non-pharmaceutical interventions*) são importantíssimas para influenciar a trajetória da epidemia nos países. Atualmente, a principal recomendação da OMS é o isolamento social [5]. Assim, os doentes são postos em quarentena hospitalar/domiciliar e a população como um todo é orientada a realizar quarentena voluntária domiciliar, quando possível, a fim de diminuir a escalada da propagação da doença, amenizando o impacto da pandemia no sistema de saúde. Além disso, o uso de máscaras e a

higienização frequente das mãos com água e sabão e/ou por meio do uso de álcool em gel têm sido apontados como grandes aliados no combate à COVID-19.

À medida que a doença se propaga os desafios do sistema de saúde aumentam, principalmente pelo fato de muitas pessoas infectadas não apresentarem sintomas da doença, também chamadas de assintomáticas. Estudos realizados na China apontam que até 62% das transmissões do COVID-19 ocorrem através de pessoas assintomáticas e pré-sintomáticas [6]. Dessa forma existe um risco crescente de que o número real de pessoas infectadas seja muito maior do que os notificados pelos órgãos de controle, e o real crescimento da doença seja identificado de forma incorreta, com um elevado número de subnotificações.

Portanto, é essencial estimar adequadamente o grau de subnotificação ou notificações erradas do COVID-19 para se ter a compreensão do cenário epidemiológico real e realizar tomadas de decisão mais efetivas. No Brasil, a subnotificação se deve especialmente à baixa quantidade de testes realizados por milhão de habitantes e na demora para obter os resultados [7][8]. Para ilustrar, nas primeiras semanas do surto de COVID-19, adotou-se no Brasil a testagem para todos os casos suspeitos e às pessoas que tiveram contatos com casos confirmados. Todavia, o baixo número de testes RT-PCR disponíveis fez com que o Ministério da Saúde (MS) recomendasse que apenas os casos graves fossem testados [9], além de alguns grupos de alto risco de contaminação, como os profissionais de saúde.

Segundo o portal World o Meters [10], que compila dados mundiais da COVID-19, o Brasil até a presente data realizou 930.013 testes, o que resulta num número de 4.378 por milhão de habitantes, bem abaixo de países como a Espanha, Portugal e Estados Unidos, que apresentam números de 86.921, 78.030 e 53.156 testes por milhão de habitantes. Essa subamostragem leva o país a um elevado grau de subnotificação de casos, o que também gera desvios na estimativa da taxa de letalidade real da doença [4]. Assim, conhecer o grau de subnotificação de casos é fundamental para definir as políticas de saúde pública e na tomada de decisão das autoridades acerca do enfrentamento da pandemia.

Mesmo considerando que a subnotificação é um problema grave no Brasil, o que dificulta a análise precisa da evolução de casos no país, os dados oficiais sugerem ainda um crescente aumento no número de casos. Sobre o controle da doença, os estudos sugerem que para a diminuir o número de casos, o número de reprodução (R) deve estar abaixo de 1 [11]. Porém, temos observado que, apesar de muitos estados brasileiros terem adotado medidas de isolamento e distanciamento social, inclusive com a adoção de medida de *lockdown*, as taxas de isolamento social reportadas ainda estão muito aquém das taxas desejadas, que seriam a partir de 70%, a fim de diminuir efetivamente o número de reprodução da doença.

A situação do país se agrava pela severa condição de desigualdade social. No Brasil, uma significativa parcela da população vive em condições precárias de moradia (casas superpopuladas e de poucos cômodos), que não contribuem para o isolamento efetivo da população (infectados ou não); e saneamento básico e acesso à água tratada, que dificultam/inviabilizam o cumprimento de recomendações, tais como a higienização frequente das mãos, além de outros problemas em decorrência da pobreza e má distribuição de renda, agravando o espalhamento da doença e seus efeitos na sociedade.

Nesse sentido, na ausência de medidas de intervenções farmacêuticas contra a covid-19, tais como um protocolo de tratamento amplamente aceito pela comunidade científica e vacinas, e com o objetivo de avaliar as possíveis dimensões da pandemia em

termos de contaminados, hospitalizados graves e óbitos, bem como os efeitos das medidas de intervenções não farmacêuticas no controle da doença, pesquisadores e especialistas no tema fazem uso de modelos matemáticos que representam a dinâmica de epidemias ao longo do tempo, como por exemplo: modelos SIR (Suscetível, Infecioso, Recuperado) e SEIR (Suscetível, Exposto, Infecioso, Recuperado) [12].

Um dos estudos mais relevantes foi elaborado pelo grupo liderado por Patrick G. T. Walker, do Imperial College London na Inglaterra [13], que utilizou um modelo SEIR estruturado por idades. Em tal trabalho, os autores consideraram aspectos tanto da pirâmide populacional dos países, quanto dos contatos médios entre pessoas no mesmo grupo e em grupos de faixa etária distintos, para realizar previsões de número de infectados e os efeitos das medidas NPIs durante a pandemia de COVID-19.

Embora de extrema relevância, o trabalho mencionado não insere características típicas de países em desenvolvimento, os quais apresentam um elevado grau de desigualdade social (ex.: Brasil e Índia) que tendem a agravar os efeitos da pandemia. Além de melhor aderir às realidades de tais países, a elaboração de modelos que tratam os aspectos da desigualdade social, como condições precárias de moradia, falta de saneamento básico, baixo nível de acesso a serviços de saúde, permitem que os governos elaborem planos de ação diferenciados e mais efetivos.

Diante disto, propomos “Um novo modelo epidêmico mais realista para países em desenvolvimento”, baseado no tradicional modelo SEIR e em indicadores sociais para prever surtos e mortalidade da COVID-19. No caso brasileiro, para estimar a evolução da doença nas diversas regiões metropolitanas, utilizamos como base de dados aquelas providas pelos governos federal, estaduais e/ou municipais, tais como PNAD (Pesquisa Nacional de Amostra de Domicílios) do IBGE (Instituto Brasileiro de Geografia e Estatística), DATASUS do Ministério da Saúde e casos confirmados de COVID-19 relatados pelas Secretarias estaduais e municipais de Saúde.

Os resultados obtidos são utilizados para analisar o impacto que o surto da COVID-19 pode gerar no sistema de saúde da região sob análise. Além das estimativas, o estudo prevê a eficácia de diversas estratégias, com diferentes medidas de intervenção não farmacêuticas. Isto, sem dúvida, pode contribuir para a melhor atuação do poder público na gestão desta crise sem paralelo na história recente da humanidade. A seguir, o detalhamento do modelo.

2. Um novo modelo epidêmico para regiões e países em desenvolvimento

Dadas as dimensões de número de contaminados pelo COVID-19, o que na prática indica que o sistema de saúde não possui capacidade de fornecer isolamento para todos os contaminados, para os casos de pessoas contaminadas que não estão em estado grave, é recomendada a quarentena domiciliar. Porém, as pessoas em situação de moradia precária e elevado número de moradores por cômodo não conseguem efetivamente realizar o isolamento domiciliar.

Em geral estas pessoas moram em áreas em que os demais domicílios possuem condições semelhantes e que, desta forma, as medidas para a redução da taxa de contágio nesta população, mesmo para os indivíduos com confirmação da contaminação ou para momentos de suspensão das atividades laborais, não serão efetivas.

Além disso, tais pessoas, em geral, realizam atividades como de frentistas, motoristas e garçons, e, desta forma, podem contaminar e ser contaminadas por pessoas em condições saudáveis de moradia.

Com base nestas observações e em algumas outras, para a elaboração e a devida interpretação do modelo, os seguintes pressupostos são assumidos:

- Uma proporção da população não conseguirá reduzir sua taxa de contágio;
- Os trabalhadores combatendo a pandemia (médicos, policiais, bombeiros, etc) estão devidamente protegidos para não propagarem o contágio;
- Existe um tempo de incubação entre o indivíduo ser infectado e se tornar infeccioso.

2.1 O novo modelo SEIR

O tradicional modelo SEIR é um refinamento do modelo SIR (Suscetível, Infectado, Recuperado), que basicamente considera uma taxa de infecção (β) e uma taxa de recuperação (γ) [12]. O refinamento do modelo SIR se dá na introdução de um período latente ao modelo (σ). Durante este estágio, a abundância de patógenos é muito baixa para a transmissão ativa a indivíduos suscetíveis. Em outras palavras, o modelo considera que há um período após a infecção no qual o indivíduo infectado ainda não é infeccioso. Indivíduos neste estado são chamados de Expostos. O modelo SEIR clássico, sem considerar nascimento e morte dos indivíduos, busca resolver o sistema de equações diferenciais ordinárias a seguir:

$$\begin{aligned}\frac{dS(t)}{dt} &= \frac{-\beta S(t)I(t)}{N} \\ \frac{dE(t)}{dt} &= \frac{-\beta S(t)I(t)}{N} - \sigma E(t) \\ \frac{dI(t)}{dt} &= \sigma E(t) - \gamma I(t) \\ \frac{dR(t)}{dt} &= \gamma I(t)\end{aligned}$$

As equações denotam no tempo t o respectivo número de casos/indivíduos suscetíveis, expostos, infecciosos e recuperados, este último resume todos aqueles que foram removidos por se tornarem imunes após a recuperação ou que vieram a óbito em decorrência da doença. A constante $N = S + E + I + R$, denota a população total da região investigada.

Diferente do tradicional modelo SEIR, propomos uma abordagem que distingue o compartimento/estado Infeccioso em dois compartimentos, de acordo com a probabilidade do indivíduo infeccioso poder efetivamente reduzir ou não sua taxa de contágio.

Assim, o compartimento I do modelo tradicional foi substituído por dois novos compartimentos: I_a (indivíduos infecciosos que conseguem reduzir sua taxa de contaminação, β_a , de acordo com as restrições orientadas pelos agentes de saúde) e I_b (indivíduos infecciosos que não conseguem efetivamente reduzirem sua taxa de contaminação, β_b). O novo modelo SEIR para países em desenvolvimento busca resolver o sistema de equações diferenciais ordinárias a seguir:

$$\begin{aligned}
\frac{dS(t)}{dt} &= \frac{-S(t)\beta_a I_a(t) - S(t)\beta_b I_b(t)}{N} \\
\frac{dE(t)}{dt} &= \frac{S(t)\beta_a I_a(t) + S(t)\beta_b I_b(t)}{N} - \alpha E(t) \\
\frac{dI_a(t)}{dt} &= \delta \alpha E(t) - \gamma I_a(t) \\
\frac{dI_b(t)}{dt} &= (1 - \delta) \alpha E(t) - \gamma I_b(t) \\
\frac{dR(t)}{dt} &= \gamma I_a(t) + \gamma I_b(t)
\end{aligned}$$

Onde

- N é a população total;
- δ é a proporção de N que consegue efetivamente reduzir sua taxa de contágio de acordo com as orientações dos agentes de saúde;
- α é a taxa de mudança de Exposto (indivíduos infectados ainda não infecciosos) para Infecciosos;
- β_a é a taxa de contaminação para indivíduos do grupo a ;
- β_b é a taxa de contaminação para indivíduos do grupo b ;
- γ é a taxa de saída de indivíduos da condição de infecciosos, seja por recuperação ou por morte;
- $S(t)$ é o número de indivíduos suscetíveis ao contágio ao longo do tempo;
- $E(t)$ é o número de indivíduos expostos ao longo do tempo;
- $I_a(t)$ é o número de indivíduos infecciosos no grupo a ao longo do tempo;
- $I_b(t)$ é o número de indivíduos infecciosos no grupo b ao longo do tempo;
- $R(t)$ é o número de indivíduos que finalizaram o ciclo do COVID-19, por recuperação ou por morte, ao longo do tempo.

O número de mortes ao longo do tempo é calculado com uma fração de $R(t)$, de acordo com os relatórios de taxa de letalidade adotados. O número de leitos de UTI necessário é calculado como uma fração do valor de pico do número total de Infecciosos Ativos ao longo do tempo, $I(t) = I_a(t) + I_b(t)$, de acordo com as taxas já obtidas para outros países em estágio mais avançado da pandemia, assumindo que essa necessidade se comportaria de maneira semelhante.

2.2 Estudo de Caso – Aplicação para a Região Metropolitana de Belém, Brasil

Método para cidades brasileiras

A estimativa do tamanho da população dos municípios do país é obtida de acordo com os dados mais recentes divulgados pelo Instituto Brasileiro de Geografia e Estatísticas (IBGE). Demais dados demográficos são obtidos a partir de informações da Pesquisa Nacional por Amostra de Domicílios (PNAD), também realizada pelo IBGE. A PNAD traz informações tais como *educação, acesso às tecnologias de informação e comunicação (TIC), características gerais dos domicílios e dos moradores, ocupação,*

rendimento médio mensal, entre outros [14]. Sobre as características gerais dos domicílios e dos moradores, a PNAD realiza o levantamento de informações tais como: *tipo e condição da moradia; material predominante nas paredes, piso e telhado; serviços essenciais de saneamento básico*, que abarcam *o abastecimento de água, a presença de banheiro e esgotamento sanitário, o destino do lixo, e a disponibilidade de energia elétrica*; bem como a *posse de bens e serviços*, contemplando, por exemplo, a *posse de geladeira, máquina de lavar roupa, carro e motocicleta*. Quanto às características gerais dos moradores, os comentários se referem à distribuição da população residente por sexo, grupos de idade, além de cor ou raça.

Informações específicas da doença e de estimativas acerca de hospitalização foram extraídas a partir da análise de dados anteriormente obtidos para a COVID-19, em trabalhos como [1][5][11][13][15][16][17][18].

Os números de casos confirmados, recuperados e mortos são obtidos por meio dos dados divulgados diariamente pelo Ministério da Saúde do Governo Federal [19] e das Secretarias de Saúde dos estados e municípios. Assumimos também que indivíduos que residem em habitações com mais de 3 pessoas por cômodo não são capazes de se isolar efetivamente, no entanto têm sua probabilidade de contato diminuída, denotada pelo parâmetro η , que é a taxa de infecção de indivíduos infecciosos não isolados. Para estimar a demanda por serviços de saúde, usamos taxas de hospitalização (internação e cuidados críticos) obtidas de nossa análise anterior de dados da COVID-19 em outros países, assumindo que níveis semelhantes de necessidade de assistência médica são esperados. Informações sobre leitos hospitalares e leitos de UTI foram extraídas do Cadastro Nacional de Estabelecimentos de Saúde [20], do DATASUS, que disponibiliza informações a fim de subsidiar análises objetivas da situação sanitária, tomadas de decisão baseadas em evidências e elaboração de programas de ações de saúde.

Cenário

Os resultados apresentados a seguir foram obtidos para a Região Metropolitana de Belém (RMB). A RMB é formada por 7 cidades do estado do Pará (Ananindeua, Belém, Benevides, Castanhal, Marituba, Santa Bárbara do Pará e Santa Isabel do Pará), que juntas reúnem uma população em torno de 2.459.321 habitantes, segundo dados do IBGE de 2019. De acordo com o CNES/DATASUS atual (2020), a RMB conta com um total de 4.383 leitos hospitalares, entre leitos clínicos, cirúrgicos e complementares (incluindo UTIs). Portanto, a RMB conta em média com 1,78 leitos para cada mil habitantes, número abaixo da média nacional, que é de 1,95 leitos para mil habitantes, segundo a Federação Brasileira de Hospitais (FBH) e Confederação Nacional de Saúde (CNS) [21], enquanto a média do planeta é de 3,2 leitos para mil habitantes [22]. Dados da PNAD mais recente (2018) foram usados para compor as demais informações demográficas. Os números de casos confirmados, recuperados e mortos associados à RMB foram obtidos por meio dos dados divulgados pelo Ministério da Saúde do Governo Federal [19] e das Secretarias de Saúde Pública do Estado do Pará (SESPA) [23].

Para fins de exemplificação da desigualdade social que atinge a cidade de Belém, principal cidade da RMB, a Figura 1 apresenta o mapa do município de Belém, com a respectiva descrição da proporção de domicílios com chefes de família recebendo até $\frac{1}{2}$ salário mínimo.

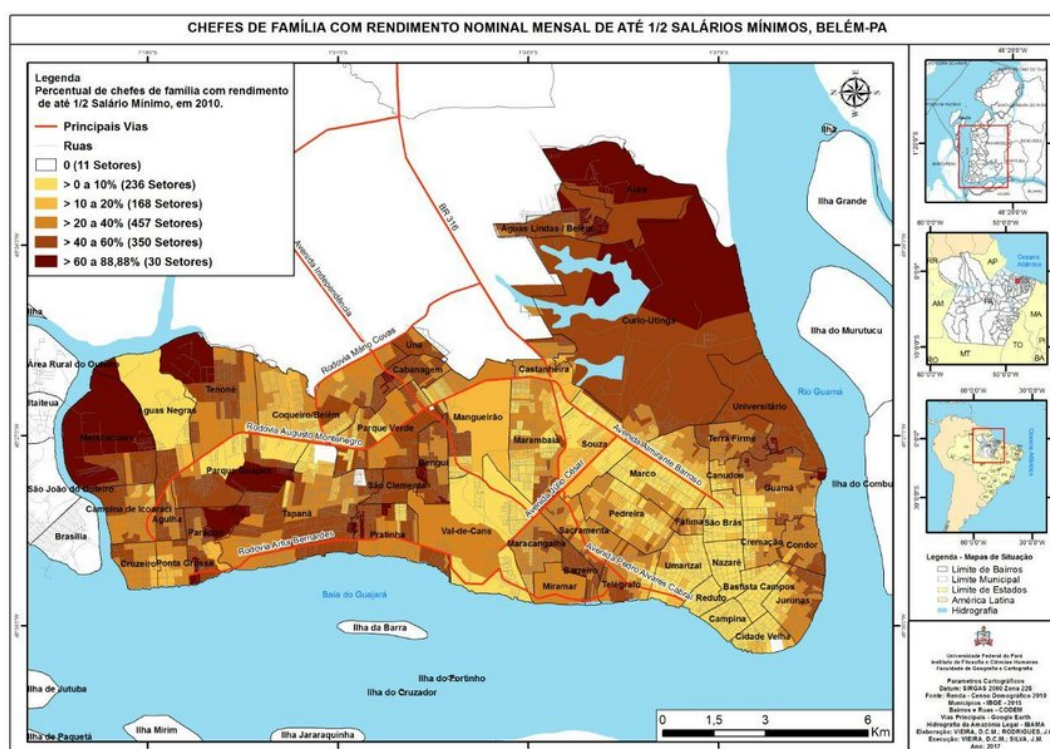


Fig. 1. Chefes de família com rendimento nominal de até ½ salário mínimo. Fonte: D. C. de M. Vieira, J. C. Rodrigues, J. C. Rodrigues, “Mapeamento e Análise de Desigualdades Socioespaciais: Abordagem Interpretativa a Partir da Cidade de Belém, Pará”, Revista Geosaberes, 2018.

Os parâmetros de taxas utilizadas no modelo foram obtidos a partir de levantamento bibliográfico acerca da pandemia e os parâmetros de população e proporção de pessoas pertencentes ao grupo *b*, aquelas que não conseguem efetivamente reduzir sua taxa de contaminação, foram obtidos da PNAD Contínua 2018, dados de divulgação anual. Os estudos sobre a PNAD mostraram que 14,54% da população da RMB não consegue realizar efetivamente o isolamento, mesmo estando em quarentena domiciliar. Portanto, consideramos que apenas 85,46% da população pode ter sua taxa de contaminação reduzida. A Tabela 1 apresenta os valores utilizados.

Tabela 1. Parâmetros utilizados.

Parâmetro	Valor
N	2.292.758
δ	85,46%
α	$1/2 \text{ dia}^{-1}$
β_a	$6,5 \times 0,05 \times \text{Taxa de Redução de Contágio}$
β_b	$6,5 \times 0,05$
γ	$1/14 \text{ dia}^{-1}$
Tx UTI	5% dos casos requerem UTI

Resultados e Discussão

O número de infectados, demanda de leitos de UTI e mortes ao longo do tempo devido à COVID-19 foram estimados usando o novo modelo SEIR para países em desenvolvimento, a partir da análise de cenários que incluem ou não medidas de NPI por parte do governo. Essas medidas incluem uma política de distanciamento social na população em geral, a fim de diminuir a transmissão de humano para humano, incluindo a redução de infecções secundárias entre contatos próximos e influenciam nas taxas de contaminação/infecção da população. Dentro do nosso modelo, essa taxa pode ser entendida como um coeficiente que ajusta o β . Todas as estimativas a seguir foram realizadas utilizando os registros reportados pela SESPA na data de 02 de maio de 2020 e não incluem os novos registros atualizados até a data presente e os efeitos do *lockdown*.

Até a data da simulação (02 de maio), na RMB, o primeiro caso havia sido registrado em 18 de março de 2020 e até 1º de maio de 2020, 2436 casos tinham sido confirmados. Em 18 de março, as atividades foram suspensas, visando reduzir o contágio. Na época, os resultados demoravam cerca de 10 dias para confirmar a infecção e por esta razão consideramos que apenas 10 dias após o primeiro caso, a suspensão das atividades foi eficaz na redução do contágio. A Tabela 1 mostra que a taxa de contágio inicial foi estimada em 0,325 e 10 dias após, houve uma redução de 20% dessa taxa foi incluída no grupo a. Segundo a SESPA, até o 35º dia, o distanciamento social era de cerca de 20% e aumentado para cerca de 50%. A Figura 2 apresenta os casos reais versus estimados até 1º de maio, com base nos parâmetros do modelo.




Fig. 2. Estimativas do COVID-19 para a Região Metropolitana de Belém. Casos reportados e simulados.

Após calibrar a taxa de contaminação para obter os resultados da Figura H, consideramos cenários em que a redução da taxa de contaminação, a partir do 30º dia,

era de 20% a 85% para os infecciosos no grupo *a*. Para aqueles do grupo *b*, a taxa de contaminação foi mantida em seu valor inicial.

As Figuras 3 e 4 mostram casos ativos de infectados ao longo do tempo, reduzindo a taxa de contaminação aplicada a partir do 30º dia. As figuras ressaltam o efeito da desigualdade social no impacto da epidemia de COVID-19. A Figura 2H considera um cenário com desigualdade social, na qual 14,54% da população não consegue reduzir sua taxa de contaminação, pois vive em famílias superpovoadas e com ou sem acesso a saneamento básico ou água tratada. Enquanto a Figura 3 considera um cenário no qual a população inteira consegue reduzir sua taxa de contaminação.

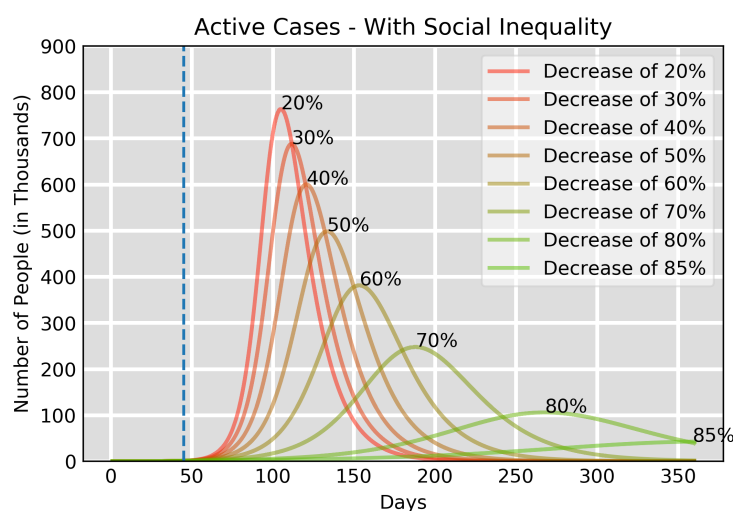


Fig. 3. Casos ativos de infecção ao longo do tempo, considerando desigualdade social.




Fig. 4. Casos ativos de infecção ao longo do tempo, desconsiderando desigualdade social.

A Figura 5 mostra o número total de casos confirmados estimados com foco nos próximos 20 dias a partir do 70º dia. No caso da curva de 30%, são apresentados dados semelhantes ao do estudo da UFPEL[29]




Figura 5. Acumulado de casos confirmados, com foco nos próximos 20 dias a partir do 70º dia.

Observa-se que a desigualdade social tem um forte efeito nos resultados. Embora reduza a taxa de contaminação em 80% em um cenário real (com desigualdade), ainda existe um pico de mais de 100 mil infectados ativos por volta do 275º dia. No caso do cenário sem desigualdade (geralmente considerado nos estudos disponíveis na literatura especializada), a mesma redução praticamente leva a zero a curva de infecção ativa, atingindo o valor máximo nas próximas duas semanas.

É imprescindível ressaltar que há um significativo atraso na divulgação dos registros de casos confirmados e de óbitos, além de uma diferença entre os dados reportados pela SESPA e as secretarias municipais. Observando de modo geral o Estado do Pará, comparou-se os resultados de casos confirmados e óbitos no período de tempo de 01.03.2020 a 28.05.2020, publicados em dois dias distintos. A primeira publicação para o referido período de tempo observada foi a realizada no final do dia 28.05.2020 e a segunda publicação observada foi realizada no final do dia 31.05.202. Isto é, observou-se o quanto os registros de casos confirmados e óbitos até o dia 28.05.2020 foi alterado devido a inserção de registros atrasados na base de dados.

Primeiramente, nota-se que, neste intervalo de 3 dias, o número de registros atrasados até o dia 28.05.2020 fez com que a contagem de casos confirmados totais para este dia aumentasse de 35.132 para 38.005, enquanto que a contagem de óbitos totais até este dia aumentasse de 2.785 para 2.915.

Desta forma, tem-se que, em 3 dias, o atraso nos registros e publicações fez com que a contagem de casos confirmados e óbitos aumentasse, respectivamente, em 2.873 e 130 casos.

As Figuras 6 e 7 apresentam os gráficos de quantidades de registros atrasados e dias de atraso referentes a 28.05.2020, considerando as publicações ocorridas entre 28.05.2020 e 31.05.2020, para casos confirmados e óbitos.



Figura 6. Atraso nos registros de casos confirmados observando o mesmo período de tempo em publicações com 3 dias de diferença.




Figura 7. Atraso nos registros de óbitos observando o mesmo período de tempo em publicações com 3 dias de diferença.

Tais resultados demonstram que a dinâmica envolvida em todo o processo que vai do registro do primeiro atendimento do paciente, passa pela confirmação da doença, até

a publicação dos registros no painel da SESPA, exige um tempo que faz com que os registros dos últimos dias sejam inferiores ao que realmente está ocorrendo no serviço de saúde.

As figuras 8 e 9 apresentam os resultados de casos confirmados e óbitos por dia para o período em questão (01.03.2020 a 28.05.2020), observados nas publicações de 28.05.2020 e 31.05.2020.



Figura 8. Casos confirmados por dia observando o mesmo período de tempo em publicações com 3 dias de diferença.



Figura 9. Óbitos por dia observando o mesmo período de tempo em publicações com 3 dias de diferença.

As figuras revelam que a queda visualizada nos gráficos é alterada ao longo do tempo, à medida que registros de dias anteriores são inseridos na base de dados. Por exemplo, para os casos confirmados, a queda evidente a partir do dia 11.05.2020 (quando observada no dia 28.05.2020), não se concretiza quando novos registros são inseridos na base, pois, observando a publicação do dia 30.05.2020, só nota-se evidente queda no número de casos confirmados a partir do dia 16.05.2020. Efeito semelhante é observado no número de óbitos.

Para melhor exemplificar, observa-se pelos gráficos que no dia 28.05.2020 foi notificado somente 1 óbito neste mesmo dia, porém, no dia 31.05.2020, este valor foi corrigido para 25, isto é, outros 24 óbitos ocorridos no dia 28.05.2020 somente foram contabilizados 3 dias depois.

Para se contabilizar e analisar as estatísticas descritivas básicas do atraso dos registros, considerou-se o boletim informativo da SESP do dia 29.05.2020, realizada no período da noite. Neste boletim, foram informados 789 casos confirmados de dias anteriores. Observando a distribuição destes registros em relação aos dias de atraso, tem-se que a média é de 20,33 dias de atraso, a mediana é 18 dias de atraso e o percentil-75 é 27 dias de atraso. A Figura 10 apresenta o histograma da quantidade de registros atrasados pelo número de dias de atraso.




Figura 10. Atraso na divulgação dos registros de casos confirmados, de acordo com o observado no boletim divulgado pela SESP no dia 29.05.2020, no período da noite.

Em relação a óbitos, o mesmo boletim informa 32 registros de dias anteriores, com média de 12,81 dias de atraso, mediana de 10 dias de atraso e percentil-75 de 17,75 dias de atraso. A Figura 11 apresenta o histograma da quantidade de registros atrasados de óbitos pelo número de dias de atraso.




Figura 11. Atraso na divulgação dos registros de óbitos, de acordo com o observado no boletim divulgado pela SESPÁ no dia 29.05.2020, no período da noite.

Estes resultados indicam então que, para os dados sendo publicados no painel da SESPÁ, devem-se observar as curvas somente até o dia 04.05.2020, para os registros de casos confirmados e somente até o dia 14.05.2020 para os registros de óbitos, pois os dias após estas datas possuem elevada chance de serem corrigidos durante os próximos dias para valores maiores dos que estão sendo publicados atualmente, desfazendo, assim, a queda que está sendo observada nos gráficos. As figuras 12 e 13 repetem os dados utilizados nas figuras X3 e X4, porém com o corte nas datas supracitadas.



Figura 12. Casos confirmados por dia no período de 01.03.2020 a 04.05.2020.



Figura 13. Óbitos por dia no período de 01.03.2020 a 14.05.2020.

Especificamente para a RMB, o boletim do dia 29.05.2020 no período noturno, informa 189 casos confirmados de dias anteriores, com média de 29,37 dias de atraso, mediana de 30 dias e percentil-75 de 40 dias de atraso. Em relação a óbitos, foram 12 registros de dias anteriores, com média de 16,75 dias de atraso, mediana de 12,5 dias de atraso e percentil-75 de 21,75 dias de atraso.

As Figuras 14 e 15 apresentam os gráficos para a RMB, destacando o período com menor chance de alteração dos resultados




Figura 14. Casos confirmados por dia destacando o período com elevada chance de alteração posterior dos dados.




Figura 15. Óbitos por dia destacando o período com elevada chance de alteração posterior dos dados.

3. Modelo de previsão baseado na subnotificação de mortalidade por COVID-19 no Brasil

Diante do problema da subnotificação já discutido anteriormente, assume-se a hipótese de que se há subnotificação no número de casos confirmados e que, por conseguinte, também é possível haver subnotificação no número de óbitos apresentados nos números oficiais. Para avaliar tal hipótese, utilizou-se os dados da série histórica de óbitos por doenças no sistema respiratório para estimar o possível número de notificações realizadas erroneamente no período de coexistência com pandemia de COVID-19.

Os dados da série histórica dos anos de 2010 a 2018 foram coletados no portal DATASUS do Ministério da Saúde. Os dados dos anos de 2019 e 2020 foram obtidos no portal da transparência do Registro Civil. Os dados adquiridos no DATASUS foram utilizados no treinamento de modelos de séries temporais (regressões modulares) para prever o comportamento esperado para os óbitos no ano de 2020. Tal predição revelou uma discrepância entre os valores reais e preditos, caracterizando inequivocamente a existência de *outliers* na série. Diante do dimensionamento preciso dos *outliers* é possível quantificar o número de óbitos que foram, com grau de probabilidade bastante consistente, notificados de maneira equivocada - ou seja: grande probabilidade de ser classificado como COVID-19, mas que foram classificados como, por exemplo, SRAG ou Insuficiência Respiratória.

3.1 Metodologia

A metodologia utilizada nesta pesquisa é composta por três etapas (Figura 16), iniciando-se pela extração dos dados. Foram selecionados dados de bases diferentes disponibilizados por entes públicos nacionais. Em seguida, é realizado o processamento dos dados para obter informações de séries temporais que serão avaliadas e analisadas na etapa consecutiva.

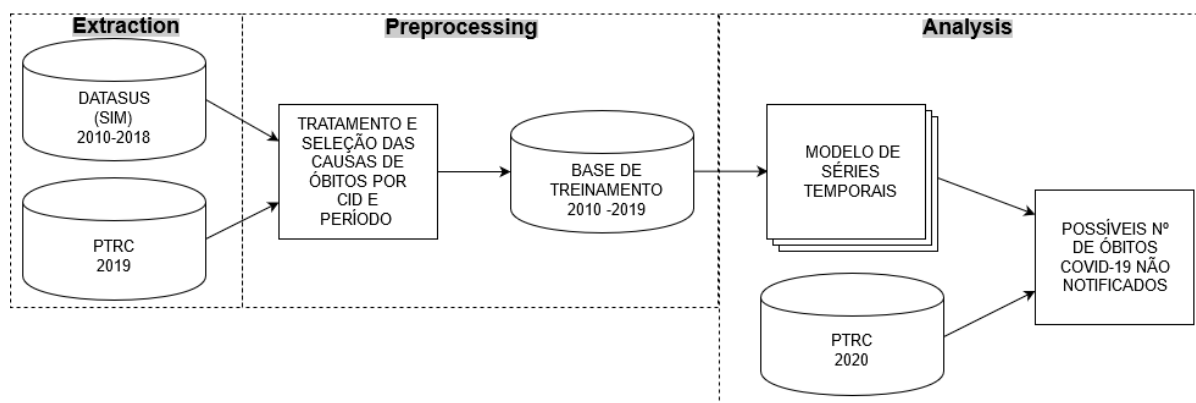


Figura 16: Workflow da Metodologia utilizada na pesquisa

3.2 Extração de dados

Os dados utilizados na pesquisa foram extraídos do Sistema de Informação de Mortalidade (SIM) do DATASUS [24], que representa o sistemas para a obtenção regular de dados sobre mortalidade no Brasil, para subsidiar as diversas esferas de gestão na saúde pública [24] . Foram extraídas informações dos anos de 2010 a 2018, de todos as capitais dos estados brasileiros. É importante registrar que os dados do SIM não são atualizados constantemente, de tal forma que o ano de 2019 ainda não está disponibilizado.

Outra base de dados foi o portal da transparência do Registro Civil – PTRC [25], portal que apresenta o registro de óbitos da COVID-19 (confirmado ou suspeito), além de doenças respiratórias, tais como, SRAG (síndrome respiratória aguda grave), Pneumonia e Insuficiência Respiratória. Os números apresentados pelo PTRC se baseiam nas Declarações de Óbito (DO) registradas nos cartórios do país ocorridos em diversos locais, tais como: hospitais, domicílios e vias públicas. O período considerado compreende de janeiro a maio de 2020 e o respectivo período também no ano de 2019. O PTRC, para os anos de 2019 e 2020, apresenta também uma outra categoria, denominada “demais óbitos” (quando não foi caracterizado como COVID-19 ou

doenças respiratórias relacionadas). Tal categoria também foi observada, para o mesmo período, no âmbito desta pesquisa.

Os dados apresentados pelo PTRC, lavrados pelos cartórios de registro civil, obedece a uma sequência de prazos legais impostos pela Constituição Brasileira, de forma que a família tem até 24h após o falecimento para registrar o óbito em cartório que, por sua vez, tem até cinco dias para efetuar o registro de óbito e, por fim, os cartórios possuem até oito dias para enviar o ato feito à Central Nacional de Informações do Registro Civil (CRC Nacional), que finalmente atualizará o PTRC. Assim, os dados apresentados no PTRC podem conter entre 14 a 15 dias úteis de atraso em relação à real data de óbito dos indivíduos.

3.3 Processamento de Dados

Para realizar processamento dos dados do DATASUS, foram utilizadas condições similares às utilizadas no PTRC e, dentre os campos para realização da seleção, o campo data de óbito e CID [26] do óbito foram considerados de maneira compulsória.

Os dados foram filtrados de acordo com as seguintes condições definidas pelo PTRC:

- Condição 1: se houver alguma menção à COVID-19 na certidão de óbito, suspeita ou confirmada, ela foi considerada como COVID-19;
- Condição 2: se houver alguma menção à Síndrome Respiratória Aguda Grave (SRAG), esta foi considerada a causa;
- Condição 3: se houver alguma menção à pneumonia, esta foi considerada a causa;
- Condição 4: se a insuficiência respiratória estiver listada como a única causa, ela foi considerada como tal.
- Condição 5: Se o óbito não foi classificado em nenhuma das condições anteriores, considerou-se outra causa (demais óbitos).

Desta forma, para obter-se a série temporal de casos por ano, em cada estado, e de acordo com as condições apresentadas anteriormente, foi necessário identificar as CIDs [26] referentes a cada causa de óbito. A Tabela 2 apresenta a relação das doenças e das CIDs correspondentes.

Tabela 2: Classificação de doenças do sistema respiratório de acordo com a CID-10 [26].

Disease	ICD-10 Classification
SARS	I260, U04, J22, J100, J110
Pneumonia	J12, J13, J14, J15, J16, J180, J181, J182, J188, J189, B953, B960, B961
Insuficiência Respiratória	J96

3.4 Análise dos dados

Para a análise, obtivemos os dados de todos os casos de óbitos relacionados ao COVID-19 até o dia 21 de Maio de 2020, de seis (6) capitais brasileiras com maior número de óbitos, registrados a partir dos dados publicados no PTRC: São Paulo (capital de São Paulo), Rio de Janeiro (capital do Rio de Janeiro), Manaus (capital do Amazonas), Recife (capital de Pernambuco) e Belém (capital do Pará).

Após o fluxo de trabalho de processamento e limpeza de dados acima descrito, pode-se aferir um sistema de predição no comportamento das ocorrências das doenças respiratórias, e prever o comportamento das doenças para 2020. Tem-se o número de óbitos por ano de cada doença para os estados objeto de estudo podendo assim calcular qual a projeção ou (estimativa) dessas doenças sem a ocorrência da pandemia. Foi encontrado a diferença dos números de casos que seriam o normal sem a pandemia e os que foram notificados, que foram bem mais altos. Depois somou-se essa diferença com os casos registrados como COVID-19, para se ter um valor possível do total de óbitos por COVID-19.

Com essa análise pode-se ter uma estimativa real do aumento dos casos em relação a essas doenças respiratórias e demais óbitos, podendo assim observar as possíveis subnotificações erradas nos casos de óbitos de COVID-19.

Considerando a série histórica das DO nos anos de 2010 a 2018, (retirados do SIM [24] e dos anos de 2019 e 2020 (retirados do PTRC [25]), podemos observar o acréscimo de até 856% no números de registros de óbitos envolvendo as doenças do sistema respiratório (insuficiência respiratória e SRAG) na cidade de Manaus, no período de abril a maio, uma das capitais mais afetadas no Brasil.

As demais capitais estudadas (figura 17) também tiveram um aumento significativo da porcentagem do números de óbitos em 2020: Recife com acréscimo de 286%, seguido de Belém com 161%, Fortaleza apresentando 79%, Rio de Janeiro com 161% e em último São Paulo com o índice de 79%.




Figura 17: Porcentagem do acréscimo do Número de óbitos por doenças do sistema respiratório

Além das doenças respiratórias, identificamos aumento expressivos nos números apresentados em demais óbitos. Os valores de média e desvio padrão da série histórica de cada doença é apresentado na Tabela 3 seguidos da taxa de variação observada nos períodos de pico de óbitos em 2020.

Tabela 3: Valores de média e desvio padrão da série histórica

Capital	Insuficiência Respiratória	Pneumonia	SRAG	Demais Óbitos
	Média Desvio Variância	Média Desvio Variância	Média Desvio Variância	Média Desvio Variância
Manaus	27,4 4,17 533%	109,1 21,87 382%	4,1 1,28 5926%	504,7 62,3 199%
Recife	104 18,26 68,26	155,9 23,25 51,3%	4,6 3,34 5543%	982,2 154,67 73%
Belém	73,2 15,75 177%	180 42,2 137%	3,6 2,54 1972%	490 73,4 99%
Fortaleza	88,8 19,31 127%	270,6 95,24 96%	11 7,3 563%	880,8, 103,78 85%
Rio de Janeiro	264,2 50,27 127%	642,3 73 124%	9,4 4,47 1659%	2644,6 212,39 93%
São Paulo	317,9 31,73 225%	1152,5 97,53 74%	27,9 12,64 415%	3197,9 229,45 103%

3.4.1 Modelo e Previsão de Séries Temporais

Os modelos de previsão de séries temporais foram ajustados para prever o número esperado de mortes diárias para o ano de 2020 baseado na série histórica dos anos de 2010 à 2018 para as seis capitais selecionadas para esta pesquisa. Para conduzir este experimento, foi utilizada a estrutura de treinamento do modelo de regressão modular *FbProphet* [27]. O modelo de série temporal decomposto resultante é representado pela Equação 1.

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \quad (1)$$

Onde, de acordo com o modelo de série temporal apresentado por [28], $g(t)$ representa a função de tendência utilizada pra captar mudanças não periódicas na série histórica, $s(t)$ representa as sazonalidades periódicas, representando os comportamentos

recorrentes anuais, mensais e semanais, $h(t)$ representa os efeitos de feriados na tendência geral dos dados. O componente ϵ é utilizado para representar alterações peculiares que não estão incluídas no modelo.

3.5 Resultados

Nesta seção é apresentado o resultado do modelo de previsão de séries temporais comparado com os dados reais de óbitos obtidos no PTRC, separando a análise para as doenças respiratórias e os demais óbitos, no período de março a maio de 2020.

Na figura 18 é apresentado o quantitativo de notificações de óbitos registrados (reais) no PTRC, barras verdes, incluindo os registros de óbitos de COVID-19 (confirmados e suspeitos), barras rosas, e o quantitativo predito de óbitos definido pelo nosso modelo, barras azuis, por semanas epidemiológicas, considerando os dados a partir da 9ª semana até a 19ª semana de 2020. O primeiro óbito de COVID-19 confirmado pelas autoridades brasileiras, ocorreu na 11ª semana na cidade de São Paulo, que sofreu um aumento de 24,96% fora da série esperada. A cidade de Manaus apresentou um percentual de 142,8% de diferença de notificações de óbitos do predito para o real, com pico na 14ª semana epidemiológica. A cidade de Recife registrou uma crescente de 150,29% de diferença no pico correspondendo a 18ª semana epidemiológica. Em Belém o percentual de aumento em óbitos real-predito corresponde a 95,9%, tendo o pico na 16ª semana epidemiológica. As cidades de Fortaleza e do Rio de Janeiro, demonstraram um aumento de 40,20% e 39,9% respectivamente, com picos na 17ª e 13ª semana epidemiológica.




Figura 18- Modelo de previsão vs Número reais de mortes por semana epidemiológica considerando as doenças respiratórias.

Os percentuais citados referem-se ao aumento de registros de outras causas de mortes sem menção da COVID-19. Assim, nota-se um acréscimo significativo nos números de óbitos no período da epidemia sendo atribuído a outras causas de morte que fogem do padrão esperado. É apresentando (Figura 18) padrões diferentes para cada cidade, o que demonstra que o período de contaminação da doença ocorreu em momentos diferentes, assim como as notificações de outros óbitos.

Na figura 19 é apresentado as estimativas de erros de notificações de mortes por cidade desagregada por tipo de doenças, representando a diferença em valores absolutos do real notificado para o predito na série. Os números apresentados no final de cada barra é a estimativa de mortes totais considerando o somatório das causas em seus respectivos picos de contágios.




Figura 19- Estimativa de óbitos desagregada por doenças no sistema respiratório notificados fora da série histórica.

São apresentadas (Figura 19) estimativas de subnotificações de COVID-19, com números expressivos. Conforme a especificidade de cada cidade as notificações vinculadas a determinadas doenças são bastante divergentes. Acredita-se que os quantitativos apresentados correspondem a possíveis casos de óbitos relacionados a COVID-19 em cada cidade e que foram registrados erroneamente como causa outras doenças.

Na tabela 4 é apresentado a diferença (Δ) entre o real número de casos notificados e o número de casos predito no nosso modelo, de forma quantitativa e em percentual, para as respectivas doenças, pneumonia, insuficiência respiratória, SARS e demais óbitos (todas as outras causas). Na última coluna é apresentado a diferença total dos números de óbitos que extrapolam a série histórica.

Existe uma discrepância em percentual nas notificações das doenças, destacando-se a SRAG que foi notificada com um acréscimo em torno de 5770% em Manaus e de 1552% em Belém, estimando-se um total de 457 casos de notificações equivocadas na cidade de Belém.

Tabela 4. Tabela com os percentuais de valores correspondentes às diferenças do real-predito, com a estimativa de número de notificações erradas.

Cidades / (Per. pico em sem. epid.)	Δ Óbitos Ins. Resp., n (%)	Δ Óbitos Pneum., n (%)	Δ Óbitos SRAG, n (%)	Δ Óbitos demais causas, n (%)	Δ Óbitos totais, n (%)
Manaus (13º a 19ª)	215,35 (+587,59%)	472,52 (+194,07%)	463,96 (+5770,65%)	667,92 (+67,73%)	1819,75 (+142,81%)
Belém (15º a 17ª)	87,47 (+125,8%)	84,87 (+60,14%)	161,59 (+1552,26%)	123,33 (+48,24%)	457,26 (+95,91%)
Recife (10ª a 19ª)	17,26 (+27,51%)	10,27 (+32,37%)	661,68 (+2837,39%)	37,95 (+10,37%)	727,16 (+150,29%)
Fortaleza (14º a 18ª)	66,36 (+50,41%)	52,10 (+24,82%)	154,66 (+799,69%)	222,28 (+25,59%)	495,40 (+40,29%)
São Paulo (10º a 17ª)	842,16 (+90,18%)	296,02 (+23,89%)	271,33 (+487,39%)	315,33 (+6,73%)	1724,84 (+24,96%)
Rio de Janeiro (13º a 19ª)	317,96 (+95,76%)	479,49 (+42,19%)	390,85 (+2279%)	194,12 (+9,81%)	1382,42 (+39,90%)

3.6 Estudo EPICOV19-BR

Um estudo de relevância a ser comparado com nossos dados é o estudo realizado pela Universidade federal de Pelotas UFPEL, chamado de EPICOV19-BR, onde os

pesquisadores entrevistavam e testavam para o COVID-19 um conjunto da população, selecionadas aleatoriamente, com objetivo de estimar a quantidade da população contaminada em cada cidade [29]. No estudo a primeira etapa foi realizada em 133 cidades de todos os estados Brasileiros, entre os dias 14 e 21 de maio. Das 10 capitais com percentuais mais altos da população com anticorpos (testados positivo), 5 são da Região Norte, 3 são da Região Nordeste e 2 da Região Sudeste.

Entre as cidades estudadas destacam-se quatro cidades do estado do Pará com os percentuais mais altos de infectados: Breves, castanhal, Belém e Marabá. Na cidade de Breves (PA), a proporção da população que tem ou já teve coronavírus foi estimada em 24,8%, ou seja, cerca de 25 mil dos 103 mil habitantes da cidade estão ou já estiveram infectados. As figuras abaixo apresentam os dados específicos das cidades do estado do Pará.



Figura 20- Dados do estudo EPICOVID19 na cidade de Belém [29]




Figura 21- Dados do estudo EPICOV19 na cidade de Breves[29]




Figura 22- Dados do estudo EPICoVID19 na cidade de Marabá[29]




Figura 23- Dados do estudo EPICOID19 na cidade de Castanhal [29]

3.7 Taxa de Letalidade

Considerando os dados oficiais de óbitos de COVID-19 até a data deste estudo e os dados de óbitos estimados no modelo, assim como os dados do estudo apresentados pela UFPEL, pode-se inferir a real taxa de letalidade e possíveis número de óbitos na epidemia.

Na tabela 5 é mostrado uma estimativa de taxa de letalidade na última coluna considerando o total de óbitos de óbitos oficiais somados com a extrapolação do nosso modelo. Destaca-se a taxa da cidade de Belém que é a menor em relação a outras cidades em torno de 0,79%.

Tabela 5. Taxa de letalidade considerando o estudo da UFPEL

Capitais	Extrapolação de número de óbitos preditos para 2020	Nº óbitos oficiais [9]	Total óbitos preditos	Nº contaminados oficiais [9]	População (PNAD)	Percentual de contaminados - UFPEL -	Estimativa de contaminados - UFPEL -	Estimativa da Taxa de letalidade
São Paulo	1.725	4280	6.005	60131	12.252.023	3,10%	379.812,71	1,58%
Rio de Janeiro	1.382	3578	4.960	29157	6.718.903	2,20%	147.815,87	3,36%
Manaus	1.818	1366	3.184	18293	2.182.763	12,50%	272.845,38	1,17%

Recife	726	1081	1.807	15474	1.645.727	3,20%	52.663,26	3,43%
Fortaleza	495	1967	2.462	23613	2.669.342	8,70%	232.232,75	1,06%
Belém	456	1320	1.776	11591	1.492.745	15,10%	225.404,50	0,79%

4. Conclusões

Diante dos atuais achados de pesquisas relevantes, notadamente a realizada pela UFPel, que se baseia em amostragem e testagem e que estimado com um importante grau de confiança estatística, é razoável supor-se que a população de infectados das cidades experimentadas, incluindo Belém, de fato se aproximem dos números estimados. Sendo assim, esse parâmetro, com uma probabilidade bastante razoável, estaria subestimado para a média brasileira em até 7 (sete) vezes e para Belém em até 10 (dez) vezes. Portanto, não é razoável admitir-se que as políticas públicas tomem como base exclusivamente os dados oficiais (notoriamente subnotificados), sob pena de planejar o sistema já em níveis de colapso.

No mesmo diapasão, não é razoável, sob o ponto de vista estatístico, assumir eventuais decréscimos das curvas de infectados e de óbitos, tendo-se uma defasagem de ordem de dezenas de dias. Basta extrapolar tal princípio para o futuro, para inferir-se que é impossível estimar que não haverá casos, nos próximos 30 ou 40 dias, que sejam referentes à data atual. O que significa afirmar que os valores aferidos hoje terão que ser acrescidos de valores ocorridos no tempo futuro, numa espécie de estoque de casos de infectados e óbitos, com um alto grau de aleatoriedade associado.

Eventualmente, as secretarias municipais poderiam abreviar esses tempos envolvidos entre a notificação primária e a consolidação dos dados pela SESPA e pelo Ministério da Saúde. Há relatos de secretarias, como a de Belém, de que isso é possível. Entretanto, mesmo sendo possível, não é o que é efetivado atualmente por nenhum dos municípios do Pará.

Entende-se, em adição, que pela falta de testagem e pela dinâmica imposta pelos protocolos de mortes potencialmente associadas à COVID-19, há pouquíssimo tempo (questão de poucas horas) para realização de teste de confirmação, o que em larga escala se torna inviável, a menos que se tenha testado ainda em vida. Como tal fato não é o padrão constatado, é muito provável que se conviverá com a subnotificação como uma realidade factual.

Com relação aos parâmetros da própria doença, é ponto pacífico que se conhece muito pouco acerca dela é que assumir valores voláteis como definitivos é um raciocínio anticientífico, que pode condenar grande parte da população a contrair a doença e em proporções indefiníveis. Assim, fatores como o R_0 , ciclo da doença, imunidade, período de incubação, número de assintomáticos, não estão claramente definidos internacionalmente, o que leva à constatação de que qualquer suposição acerca do comportamento da doença tomado como uniforme seja mera especulação e

não deva ser considerado, de maneira segura e responsável, por gestores públicos em suas tomadas de decisão.

À luz do exposto, entende-se que, a partir dos dados oficiais, tomando-se como referências os mais relevantes estudos realizados no Brasil e internacionalmente, não há como afirmar inequivocamente que o Pará ou a Região Metropolitana de Belém esteja já na curva decendente da pandemia. Assim, com base na prudência, em não havendo vacina ou medicamentos comprovadamente eficazes, a única estratégia para desacelerar a pandemia continua sendo o isolamento social.

Referências

- [1] Guo, Yan-Rong, et al. "The origin, transmission and clinical therapies on coronavirus ;disease 2019 (COVID-19) outbreak—an update on the status." *Military Medical Research* 7.1 (2020): 1-10.
- [2] A. L. Phelan, R. Katz, L. O. Gostin, The Novel Coronavirus Originating in Wuhan, China: Challenges for Global Health Governance, *JAMA* 2020, DOI:10.1001/jama.2020.1097
- [3] Lin L, McCloud RF, Bigman CA, Viswanath K. Tuning in and catching on? Examining the relationship between pandemic communication and awareness and knowledge of MERS in the USA. *J Public Health (Oxf)*. 2017;39(2):282–289. doi:10.1093/pubmed/fdw028
- [4] Thomas A Mellan, Henrique H Hoeltgebaum, et al. Report 21: Estimating COVID-19 cases and reproduction number in Brazil. 2020 <https://www.imperial.ac.uk/media/imperial-college/medicine/mrc-gida/2020-05-08-COVID19-Report-21.pdf>
- [5] Hellewell, Joel, et al. "Feasibility of controlling COVID-19 outbreaks by isolation of cases and contacts." *The Lancet Global Health* (2020).
- [6] Ruiyun Li, Sen Pei, Bin Chen, Yimeng Song, Tao Zhang, Wan Yang, Jeffrey Shaman. Substantial undocumented infection facilitates the rapid dissemination of novel coronavirus (SARS-CoV-2). *Science* 01 May 2020: Vol. 368, Issue 6490, pp. 489-493 DOI: 10.1126/science.abb3221. <https://science.sciencemag.org/content/368/6490/489>
- [7] COVID-19 Brasil. Análise Subnotificação. Disponível em: <<https://ciis.fmrp.usp.br/covid19/analise-subnotificacao/>>, Acesso em 15 de abril de 2020.
- [8] Núcleo de Operações e Inteligência em Saúde (NOIS). Nota Técnica 7 – Análise de subnotificação do número de casos confirmados da COVID-19 no Brasil. Disponível em: <<https://sites.google.com/view/nois-pucrio/publica%C3%A7%C3%B5es>>, Acesso em 15 de abril de 2020.
- [9] Ministério da Saúde. Coronavírus COVID-19. Disponível em: <<https://coronavirus.saude.gov.br/>>, Acesso em 23 de maio de 2020.
- [10] Meters World Disponível em: <<https://www.worldometers.info/coronavirus/>>, Acesso em 25 de maio de 2020.
- [11] Kucharski, Adam J., et al. "Early dynamics of transmission and control of COVID-19: a mathematical modelling study." *The Lancet Infectious Diseases* (2020).

- [12] Keeling, Matt J., and Pejman Rohani. Modeling infectious diseases in humans and animals. Princeton University Press, 2011.
- [13] Walker, Patrick GT, et al. "The global impact of covid-19 and strategies for mitigation and suppression." On behalf of the imperial college covid-19 response team, Imperial College of London (2020).
- [14] Instituto Brasileiro de Geografia e Estatística, Pesquisa Nacional por Amostra de Domicílios Contínua - PNAD Contínua. Disponível em: <<https://www.ibge.gov.br/estatisticas/sociais/educacao/17270-pnad-continua.html?edicao=24437&t=o-que-e>>, Acesso em 08 de abril de 2020.
- [15] Peng, Liangrong, et al. "Epidemic analysis of COVID-19 in China by dynamical modeling." arXiv preprint arXiv:2002.06563 (2020).
- [16] Ferguson, Neil, et al. "Report 9: Impact of non-pharmaceutical interventions (NPIs) to reduce COVID19 mortality and healthcare demand." (2020).
- [17] Tang, Zhou, Xianbin Li, and Houqiang Li. "Prediction of New Coronavirus Infection Based on a Modified SEIR Model." medRxiv (2020).
- [18] Hellewell, Joel, et al. "Feasibility of controlling COVID-19 outbreaks by isolation of cases and contacts." The Lancet Global Health (2020).
- [19] Ministério da Saúde. Coronavírus Brasil. Disponível em: <<https://covid.saude.gov.br/>>, Acesso em 08 de abril de 2020.
- [20] CNES. Cadastro Nacional de Estabelecimento de Saúde. Disponível em: <<http://cnes.datasus.gov.br/>>, Acesso em 08 de abril de 2020.
- [21] Federação Brasileira de Hospitais (FBH) e Confederação Nacional de Saúde (CNS). Relatório Cenário dos Hospitais no Brasil - 2019. Disponível em: < http://cnsaude.org.br/wp-content/uploads/2019/05/CenarioDosHospitaisNoBrasil2019CNSaudeFBH.pdf?fbclid=IwAR0DUw0Z1t8CBeA17uYV4TH4gRzJ62ZTWwOIRPxWInkTJlvw6Wm-1Rah_Sc>, Acesso em 08 de abril de 2019.
- [22] Organização para a Cooperação e Desenvolvimento Econômico (OCDE). Hospital Beds. Disponível em: <<https://data.oecd.org/healthqt/hospital-beds.htm>>, Acesso em 08 de abril de 2020.
- [23] Secretaria de Saúde Pública do Estado do Pará. Coronavírus no Pará. Disponível em: < <http://www.saude.pa.gov.br/coronavirus/>>, Acesso em 08 de abril de 2020.
- [24] DATASUS - Ministério da Saúde. Disponível em: < <https://datasus.saude.gov.br/>>, Acesso em 05 de maio de 2020.
- [25] Portal da Transparência do Registro civil. Disponível em: <<https://transparencia.registrocivil.org.br/inicio>>, Acesso em 23 de maio de 2020.
- [26] WHO - World Health Organization et al., "Icd-10: international statistical classification of diseases and related health problems: tenth revision," 2004.
- [27] S. J. Taylor and B. Letham, "Business Time Series Forecasting at Scale," PeerJ Preprints 5:e3190v2, vol. 35, no. 8, pp. 48–90, 2017.
- [28] A. C. Harvey and S. Peters, "Estimation procedures for structural time series models," Journal of Forecasting, 1990.
- [29] EPICOV19BR.- Universidade Federal de Pelotas. Disponível em: <<https://wp.ufpel.edu.br/covid19/files/2020/05/EPICOV19BR-release-fase-1-Portugues.pdf>>, Acesso em 01 de maio de 2020.