

Ensaio Econômico

EPGE

Escola

Brasileira de

Economia e

Finanças

Nº 818

ISSN 0104-8910

COVID-19: ANÁLISE COM UM MODELO ESTATÍSTICO PARA DADOS EM PAINEL

Eduardo Lima Campos, Rubens Penha Cysne, Alexandre Madureira

Julho de 2020

COVID-19: ANÁLISE COM UM MODELO
ESTATÍSTICO PARA DADOS EM PAINEL/ Eduardo Lima Campos,
Rubens Penha Cysne, Alexandre Madureira - Rio de Janeiro:
FGV EPGE, 2020

14p. - (Ensaaios Econômicos; 818)

Inclui bibliografia.

CDD-330

COVID-19: ANÁLISE COM UM MODELO ESTATÍSTICO PARA DADOS EM PAINEL

Eduardo Lima Campos¹

Rubens Penha Cysne²

Alexandre Madureira³

Resumo

Esse trabalho tem por objetivo oferecer resultados relativos ao impacto de algumas variáveis mencionadas na literatura, sobre a taxa de variação diária de casos (por milhão de habitantes) registrados da COVID-19. Utilizam-se dados diários para 165 países, entre 22 de janeiro e 30 de abril de 2020 e um modelo estatístico para dados em painel. Fica clara, na análise, a importância do isolamento social no controle da pandemia. Adicionalmente, método adotado e os dados utilizados não permitem excluir a hipótese de que a evolução dos casos da doença possa estar associada a baixas temperaturas e à ausência da cobertura para BCG (Bacilo Calmette-Guérin).

Key words: COVID-19, Pandemia, Taxa de Crescimento, Temperatura, Isolamento Social, Vacinação contra BCG.

JEL classification codes: C13; C33; I18

1. Introdução e Objetivo⁴

Os governos de vários países afetados pela pandemia COVID-19 vêm introduzindo políticas de distanciamento social em diferentes gradações. Tendo em vista os impactos econômicos negativos decorrentes destas políticas, é importante mensurar como o quão importante é o nível de isolamento social na determinação dos casos de COVID-19.

Adicionalmente, alguns trabalhos empíricos apontam que a incidência das viroses H3N2, H1N1 e outras variantes da *influenza* seria maior em regiões e/ou períodos de menor temperatura e umidade. Cabe também, em função deste fato, investigar se um padrão similar seria observado nos dados coletados.

Outra hipótese levantada na literatura é de que a vacina BCG poderia oferecer alguma proteção contra a COVID-19. Neste caso, países sem programa de vacinação BCG tenderiam a apresentar mais casos da doença. Este ponto é também investigado no presente trabalho.

Fica clara no trabalho a importância do distanciamento social na mitigação ou supressão da pandemia. Os resultados sugerem, adicionalmente, que temperaturas mais baixas e/ou uma baixa cobertura de vacinação contra a BCG podem estar relacionadas ao aumento da taxa de variação diária de casos por milhão registrados. Tais resultados, evidentemente, foram obtidos utilizando-se controle para várias outras possíveis variáveis que, a princípio, de acordo com a literatura sobre o assunto, poderiam alterar o curso da pandemia.

¹ FGV EPGE Escola Brasileira de Economia e Finanças e Escola Nacional de Ciências Estatísticas (ENCE/IBGE), Rio de Janeiro, Brasil.

² FGV EPGE Escola Brasileira de Economia e Finanças, Rio de Janeiro, Brasil.

³ FGV EPGE Escola Brasileira de Economia e Finanças e Laboratório Nacional de Computação Científica (LNCC), Rio de Janeiro, Brasil.

⁴ Os autores agradecem a Carlos Henrique Dias pela assistência de pesquisa.

Por último, cabe observar que, dada a ausência de modelos epidemiológicos subjacentes à nossa análise, os resultados aqui obtidos não devem ser usados para delimitação de políticas sem a complementação por estudos de outras áreas.

2. Revisão Bibliográfica

2.1 - Efeitos do Isolamento Social

São vários os estudos que investigam o efeito do distanciamento social sobre a evolução da pandemia. Dentre esses destacam-se Cano et al. (2020), Maloney e Taskin (2020), Price e Holm (2020), Ferguson et al. (2020), Siedner et al. (2020), Ding et al. (2020) e Baumgartner et. al (2020).

No presente trabalho, propõe-se inicialmente uma forma de quantificar o isolamento social, mediante uma estimativa do percentual de pessoas circulando nas ruas (obtida via dados de mapeamento de GPS), em relação ao período anterior à pandemia. Em seguida, definem-se categorias de isolamento e chega-se a uma variável adequada para representar seu efeito sobre a evolução da COVID-19, considerando uma defasagem de tempo referente à incubação e ao registro.

2.2 - Efeitos da Temperatura sobre a Evolução da COVID-19

Vários estudos averiguam a possibilidade de influência da temperatura e da umidade sobre a evolução da pandemia. São exemplos nesse sentido Fredericks (2020), Wang et al. (2020), Chen et al (2020), Shi et al (2020), Carleton e Meng (2020). Esse último trabalho, por exemplo, associa a um aumento de 1°C na temperatura uma redução de 13% na taxa de variação de casos por milhão da COVID-19. Evidentemente, se válido, não se deveria esperar linearidade nesse resultado.

2.3 - Efeitos da Cobertura Universal para Vacina BCG (Bacille Calmette-Guerin)

Dentre os estudos que tentam averiguar a relação entre a COVID-19 e a vacinação por BCG destacam-se Sala e Miyakawa (2020), Shet et al. (2020), Hamiel et al (2020), Fukui et al (2020), Curtis et al. (2020) e Miller et al (2020). Vale observar que (WHO, 2020 (2)), trabalho conduzido pela Organização Mundial de Saúde (OMS), não corrobora a relação entre essas variáveis.

Neste trabalho desenvolveu-se uma metodologia para estimar o percentual de cobertura pela vacina BCG em cada país a partir do percentual histórico registrado no último ano em que vigorou um programa de vacinação e de projeções demográficas. Em seguida, aplicou-se uma metodologia que incorporou os possíveis fatores de confusão, como o número de dias contados a partir do primeiro caso, a proporção de idosos na população e a capacidade do sistema de saúde (proxy para renda).

3. Dados Utilizados

Foram utilizados dados de 165 países ao longo de 100 dias, com frequência diária, contemplando-se o período de 22 de janeiro a 30 de abril de 2020. A seguir são apresentadas as variáveis consideradas, a caracterização dos dados correspondentes e suas respectivas fontes.

3.1 - Casos (por Milhão) de COVID-19

Casos diários de COVID-19 (por milhão de pessoas⁵) foram obtidos no site da OMS (Organização Mundial da Saúde) para 165 dos 202 países que haviam registrado casos até 30 de abril de 2020.

3.2 - Variáveis Climáticas

As variáveis consideradas foram: temperatura (°C), precipitação (em mm) e umidade (em 10³ hPA kg/kg). A temperatura média diária foi calculada a partir dos dados fornecidos pelas 100 maiores estações meteorológicas de cada país, a partir do site do *National Oceanic and Atmospheric Administration* (NOAA) do Governo dos Estados Unidos⁶. Os dados de precipitação total e de umidade média diárias foram obtidos a partir do sistema *Copernicus*, da União Europeia⁷.

3.3 - Isolamento Social

Definiu-se, inicialmente, uma variável denominada “Índice de Circulação”, que foi adotada como medida inversa do isolamento social (pois, quanto maior o isolamento, menor a circulação).

Para a construção desta variável, inicialmente foram coletados dados de variação dos níveis de circulação das pessoas em diversas categorias de locais públicos, obtidos a partir do histórico de localização, via GPS de aparelhos celulares, para as contas de usuários do Google que mantêm esta função ativa⁸.

Após uma análise crítica dos dados disponíveis, foi considerada apenas a variação percentual diária da quantidade de pessoas circulando em estações de transporte público (os dados são disponibilizados pelo Google desta forma). Isto porque, colocando-se a evolução desta variável em perspectiva com os dias em que foram anunciadas as medidas de distanciamento social em cada país, observou-se que se tratava da proxy mais adequada para o efeito pretendido.

Adicionalmente, utilizou-se no modelo a variável defasada em 20 dias, período identificado como mais adequado para refletir o impacto das medidas de isolamento sobre os registros de contágio⁹. Foram tomados como referência (base 100%) os níveis de circulação médios antes da Pandemia e, em seguida, foram aplicadas as taxas de variação coletadas para chegar aos percentuais de circulação a cada dia, em relação aos observados antes da pandemia.

Após uma sequência de testes, observou-se que os efeitos mais claros são observados quando se divide a variável em duas categorias: circulação menor que 40% e maior/igual que 40%, em relação aos níveis pré-pandemia.

A partir dessas duas categorias do Índice de Circulação definiu-se a variável “Isolamento Social estrito” assumindo o valor zero quando o Índice de Circulação assumia valores maiores ou iguais a 40% em relação aos níveis anteriores à pandemia; e, valor um, para valores do Índice de Circulação menores do que 40% dos valores observados antes da pandemia.

Cabe ressaltar, de forma geral, que países que experimentaram este nível de distanciamento social - seja pelo rigor das medidas adotadas ou pelo efetivo sucesso de sua implementação - apresentaram, após um certo período de tempo (em torno de vinte dias) uma tendência de queda não apenas da taxa de crescimento da pandemia, mas também do número de novos casos por

⁵ É importante considerar apenas os casos para cada milhão de pessoas, uma vez que um país X com a mesma taxa de crescimento que outro país Y, porém uma população maior, tenderá a apresentar mais casos.

⁶ <https://www.ncdc.noaa.gov/cdo-web/datatools/selectlocation>.

⁷ <https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-single-levels?tab=form>.

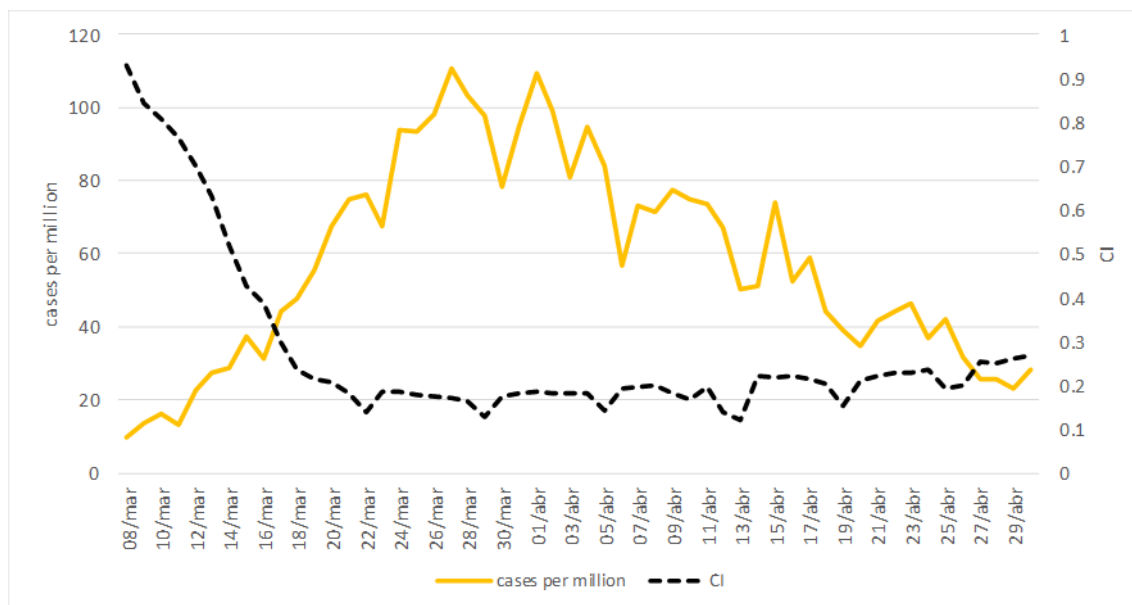
⁸ <https://www.google.com/covid19/mobility> (Google COVID-19 Community Mobility Reports).

⁹ Há que se considerar o período de incubação do vírus e o tempo até que saiam os resultados dos testes. Conclui-se aqui que o período de 21 dias é o necessário para começar a detectar o impacto do isolamento.

milhão (ou seja, a taxa de crescimento passou a apresentar valores negativos – observando-se que a população de cada país é considerada constante).

O Gráfico 3.1 ilustra este fato, mostrando a evolução dos casos por milhão em perspectiva com o índice de circulação (proporção de pessoas em circulação em relação ao nível anterior à pandemia) em três países que atingiram o nível estrito de distanciamento social da forma como aqui definido (ou seja, com Índice de Circulação tendo caído a valores inferiores a 40% dos valores observados antes da pandemia): Itália, Espanha e França.

Gráfico 3.1 - COVID-19 (casos por milhão) x Índice de Circulação (CI) - Itália, Espanha e França



Nota-se a associação entre o maior isolamento social (CI caindo abaixo de 40% - aproximadamente, no dia 17 de março) e a queda, com alguma defasagem, do número de casos da COVID-19 (final de março e início de abril).

O aumento da circulação no fim do período de estudo refere-se ao início do relaxamento das medidas de isolamento em alguns países.

3.4 - Cobertura para Vacina BCG

Considerou-se aqui uma estimativa da proporção de pessoas protegidas pela vacina BCG em cada país, em relação à população total.

Observe-se que não é suficiente verificar se um país possui ou não um programa vigente de vacinação BCG. Isto porque determinado país pode ter interrompido seu programa de vacinação há pouco tempo, e, neste caso, uma grande parcela da população que já havia se vacinado estará devidamente imunizada, sendo esta a variável relevante para o modelo. Desta forma, a variável “cobertura para BCG” representa a proporção da população imunizada.

Para a construção desta variável, atribuiu-se, inicialmente, valor zero para países que nunca tiveram cobertura para BCG¹⁰. Em seguida, para países que possuem programa de vacinação ativa (exemplos: Brasil e China), considerou-se o percentual de cobertura histórica¹¹.

¹⁰ <http://www.bcgatlas.org3>.

¹¹ <https://www.who.int/data/gho/indicator-metadata-registry/imr-details/2442>.

Finalmente, restaram os países nos quais já vigorou um programa de vacinação BCG, mas que, em algum momento, interromperam esse programa (exemplos: Austrália e grande parte dos países europeus). Nesses casos, o percentual de pessoas atualmente imunizadas foi estimado a partir da cobertura histórica registrada até o ano da interrupção e de fatores demográficos (levando-se em consideração os falecimentos ocorridos desde então) e aplicou-se a taxa de crescimento populacional àqueles não vacinados¹².

Por exemplo, o Reino Unido interrompeu a campanha de vacinação em 2004, sendo que, nesse ano, a cobertura histórica média da vacina BCG era de 75%. A população do Reino Unido em 2004 era de 60 milhões de pessoas, ou seja, aproximadamente 45 milhões de pessoas receberam a vacina. Aplicando, a cada ano, a taxa de mortalidade ao total de população imune, obtivemos 38.8 milhões de pessoas que permanecem imunes. No mesmo período, a população total do país elevou-se para algo em torno de 66.7 milhões de pessoas¹³. Desta forma, estima-se que a parcela de pessoas imunes tenha se reduzido de 75%, no ano de interrupção, para 58,3%, em 2020.

3.5 - Proporção da População Idosa (> 65 Anos)

Diversas referências indicam o maior efeito da doença em idosos, resultando em um maior registro de casos em populações com maior percentual de idosos (ver, por exemplo, Singhal (2020)). Utilizou-se, desta forma, como variável de controle, a proporção de idosos (pessoas acima de 65 anos em relação ao total) registrada em cada país, de acordo com o Banco Mundial¹⁴.

3.6 - Dias Transcorridos a Partir do Primeiro Caso

Esta variável refere-se ao número de dias contados a partir do primeiro dia de registro de caso de COVID-19 de cada país até o último dia da amostra (30/04/2020)¹⁵.

O objetivo de incorporar esta variável ao modelo é controlar o efeito do avanço natural da doença ao longo do tempo, independente da variação nos valores das demais variáveis explicativas. Por exemplo, a redução da temperatura média em um país, acompanhada de um aumento na taxa de crescimento da COVID-19, poderia induzir a uma associação espúria entre a transmissão e a temperatura. Isto porque uma elevação natural da taxa de crescimento é esperada nos estágios iniciais da doença, a partir do primeiro caso registrado, independente de variações na temperatura.

Cowling e Leung (2020), por exemplo, estabelecem que a infecção pela COVID-19, na fase inicial, apresenta uma evolução bastante rápida, uma vez que a pandemia apresenta padrões de transmissão parecidos com os da influenza, em que a fase de contágio ocorre logo em seguida aos primeiros sintomas manifestados.

3.7 - Capacidade do Sistema de Saúde

Considerou-se aqui o número de leitos hospitalares¹⁶, obtidos a partir do site do Banco Mundial¹⁷. Para viabilizar a comparação entre países com populações distintas, foi usada uma métrica que considera a quantidade de leitos para cada mil habitantes. Conjectura-se que, quanto mais preparado o sistema de saúde do país, maior a facilidade em tratar as pessoas e reduzir o contágio.

¹² Não foram considerados os fluxos migratórios.

¹³ [https://countrymeters.info/pt/United_Kingdom_\(UK\)](https://countrymeters.info/pt/United_Kingdom_(UK))

¹⁴ <https://data.worldbank.org/indicator/SP.POP.65UP.TO.ZS>.

¹⁵ <https://ourworldindata.org/grapher/daily-cases-covid-19?tab=map&year=2020-05-11>.

¹⁶ Leitos de internação em hospitais e centros de reabilitação públicos, privados, gerais e especializados.

¹⁷ <https://data.worldbank.org/indicator/SH.MED.BEDS.ZS>

3.8 - Outras Variáveis

Demais variáveis consideradas neste trabalho foram: capacidade de testagem, renda, nível de poluição, alcance do sistema de transporte e ter passado ou não por uma epidemia recente (variável binária). Porém, nenhuma destas variáveis, assim como a precipitação pluviométrica (já descrita na Seção 3.2) resultou estatisticamente significativa, aos níveis usuais, no modelo final.

4. Metodologia

Estimou-se um modelo para dados em painel. Foram utilizados dados de 165 países ao longo de 100 dias, com frequência diária, contemplando-se o período de 22 de janeiro a 30 de abril de 2020 (os dados de maio foram usados para validação).

A variável dependente considerada é a taxa logarítmica de variação do número de novos casos, por milhão de habitantes, entre os dias $t-1$ e t , registrada no país i , isto é: $Y_{it} = \ln(C_{it}/C_{i,t-1})$, em que C_{it} é o número de casos por milhão de COVID-19 registrados no país i no dia t ¹⁸. Siedner et al. (2020), Ding et al. (2020), Baumgartner (2020), Sevi (2020) e Dropkin (2020) são exemplos de trabalhos que se detêm sobre algum tipo de construção dessa variável.

A equação do modelo é apresentada a seguir:

$$Y_{it} = \gamma_i + \varphi_t + \underline{\theta}'\underline{X} + \varepsilon_{it} \quad (4.1)$$

em que i é o índice do país ($i = 1$ a 165); t é o índice que representa o dia ($t = 1$ a 100 , sendo que $t = 1$ corresponde a 22 de janeiro de 2020, $t = 100$ corresponde a 30 de abril de 2020); γ_i e φ_t representam os efeitos fixos entre países e no tempo, respectivamente; \underline{X} é um vetor que inclui todas as variáveis descritas na seção 3 - sendo os respectivos coeficientes armazenados em $\underline{\theta}$.

Os efeitos fixos γ_i , invariantes no tempo, permitem capturar diferenças específicas entre os países que não tenham sido explicitamente incorporadas à modelagem (por exemplo, por serem não observáveis ou de difícil medição). Exemplos são os hábitos de higiene e de convívio social. Os efeitos fixos φ_t , que não variam de um país para outro, permitem capturar mudanças globais ao longo do tempo, como o volume de informações sobre a doença e condições meteorológicas¹⁹.

Inicialmente, foi implementado um procedimento de seleção de variáveis via testes F , utilizando a metodologia *backwise* (geral para específico) e considerando o nível de significância 0,05 como referência. Em todas as etapas deste procedimento, a estimação foi efetuada com correção para heterocedasticidade e autocorrelação serial.

As seguintes variáveis resultaram estatisticamente significantes, ao nível considerado (0,05): $Temp_{it}$ = temperatura média no país i e no dia t (ponderada pela densidade populacional); BCG_i = cobertura para BCG (percentual estimado da população vacinada do país i em 2020); FC_{it} = número de dias decorridos a partir do primeiro caso de COVID-19 registado no país; SI_{it} = variável binária que indica se há ou não isolamento social estrito, conforme anteriormente

¹⁸ A opção pela taxa logarítmica se deve ao fato de que a variação relativa exata, definida por: $Y_{it} = (C_{it} - C_{i,t-1})/C_{i,t-1}$ apresenta forte oscilação, o que conduz à violação de pressupostos básicos do modelo.

¹⁹ Estimativas dos efeitos fixos também poderiam ser obtidas por meio de variáveis binárias - como fazem Carleton e Meng (2020), por exemplo - considerando-se um conjunto de variáveis dummy para cada i e outro para cada t . Todavia, esta especificação pode comprometer a validade dos resultados por três razões, conforme alerta Wooldridge (2010, p. 454): 1) sobreparametrização, reduzindo graus de liberdade e a precisão das estimativas; 2) possível multicolinearidade, inflando as estimativas de erro padrão e 3) dificuldade de avaliar o ajuste do modelo (as métricas usuais tendem a apresentar valores artificialmente elevados, na presença de muitas variáveis explicativas).

descrito²⁰; EP_i = percentual de idosos (residentes com 65 anos ou mais) no país i ; HM_{it} = umidade média (10^3 hPa Kg/Kg); HB_i = número de leitos de UTI para cada mil pessoas e alguns efeitos de interação e não lineares.

5. Modelo Estimado

O modelo final estimado encontra-se a seguir²¹:

$$Y_{it} = 0,4128 - 0,00152Temp_{it} + 0,00001Temp_{it}^2 - 0,00847BCG_i + 0,00029Temp_{it}BCG_i + 0,00015FC_{it} - 0,04652SI_{it} + 0,0002SI_{it}Temp_{it} - 0,00009FC_{it}SI_{it} + 0,07184EP_i + 0,00969EP_i^2 - 0,01387EP_iSI_{it} - 0,00015EP_iTemp_{it} - 0,09121EP_{it}BCG_i - 0,00032HM_{it} - 0,00029HB_i \quad (5.1)$$

em que $Y_{it} = \ln(C_{it}/C_{i,t-1})$, sendo C_{it} o número de casos por milhão no país i e no dia t , ou seja, a taxa de crescimento logarítmica do número de casos por milhão no país i , entre os dias $t-1$ e t . Observe-se que os sinais de cada variável primária estão de acordo com o esperado.

Um primeiro ponto que deve ser observado é a importância de se especificar um modelo com as variáveis de controle adequadas. Por exemplo, modelos estimados na ausência de variáveis como $Temp_{it}$ e SI_{it} , conduziram a resultados bastante discrepantes em relação ao modelo em (5.1)²².

O coeficiente negativo da variável $Temp_{it}$ na equação (5.1) permite identificar o efeito esperado da temperatura sobre a taxa de crescimento da COVID-19, indicando que, temperaturas mais baixas favorecem a evolução da epidemia. A magnitude deste efeito, no entanto, não é de cálculo direto, uma vez que depende de valores de outras variáveis do modelo: BCG_i , SI_{it} e EP_i - o que é evidenciado pela significância dos respectivos efeitos de interação - e do valor da própria temperatura - como pode ser observado a partir da significância de $Temp_{it}^2$.

O coeficiente de SI_{it} indica um efeito redutor de um isolamento social estrito sobre a taxa de variação dos casos por milhão da COVID-19. Cabe observar que outras categorizações, considerando versões menos rigorosas de isolamento (como, por exemplo, 50% dos níveis pré-pandemia) não resultaram estatisticamente significantes. Além disto, o termo de interação $SI_{it}Temp_{it}$ com coeficiente positivo indica que o isolamento social (valor de SI igual a um e não igual a zero) não somente reduz a taxa de crescimento da doença, como também atenua o impacto da temperatura sobre essas taxas.

Os resultados mostram ainda que o efeito do isolamento depende também do número de dias a partir do primeiro caso e do percentual de idosos no país. Estes pontos serão discutidos na seção 6.

O coeficiente negativo da variável BCG_i indica o efeito esperado da cobertura para vacinação BCG sobre a taxa de crescimento da COVID-19, ou seja, tudo o mais constante, os dados aqui utilizados (cabe averiguar esse fato para amostras posteriores a 30/04) não permitem negar a hipótese de que populações com maior percentual de cobertura experimentam uma evolução menos incisiva da doença. Todavia, assim como ocorre com a temperatura, o cálculo do impacto não é direto, dependendo, neste caso, de $Temp_{it}$ e EP_i .

²⁰ $SI_{it} = 1$, se no país i e no instante t a população circulando nas ruas em relação ao nível anterior à pandemia (ou seja, o valor de CI_{it}) é inferior a 40%, e $SI_{it} = 0$, caso contrário.

²¹ Foram reportados apenas os efeitos significantes ao nível 0,05.

²² Rigorosamente, a omissão de variáveis de controle relevantes pode tornar o estimador do efeito da temperatura inconsistente, o que significa que a estimativa correspondente não possui significado prático.

O coeficiente positivo de FC_{it} (dias contados a partir do primeiro caso) indica que a taxa de variação da doença, no período de tempo analisado, e já de forma controlada por todas as demais variáveis, se mostrou função crescente do tempo. O controle deste efeito é essencial para a estimação correta dos coeficientes das demais variáveis, uma vez que diferentes países se encontram, a cada dia, em fases distintas da pandemia. O coeficiente negativo de $FC_{it}SI_{it}$ indica que esta aceleração se reduz com o isolamento estrito.

O coeficiente da variável EP_i indica que, quanto maior a população idosa, maior a taxa de crescimento da COVID-19. Além disso, a presença de EP_i^2 com coeficiente positivo indica que esse efeito aumenta com o percentual de idosos na população. Não obstante o fato de que a maior incidência da COVID-19 em populações mais envelhecidas é esperada, a presença desta variável no modelo é essencial para isolar a estimação dos demais impactos. Cabe ainda ressaltar que os efeitos da temperatura, BCG e isolamento social foram distintos para países com menor população idosa, como indica a significância estatística encontrada para os respectivos termos de interação.

As duas variáveis de controle restantes que resultaram significantes foram a umidade e o número de leitos de UTI (para cada mil pessoas). A primeira indica que a evolução da doença é mais severa em climas mais secos. Este resultado está de acordo com Wang et al (2020) (ver também Fredericks (2020)). Por outro lado, Carleton e Meng (2020) e Shi et al (2020), não encontram evidências de que o nível de umidade do ar teria efeitos sobre a taxa de crescimento da COVID-19.

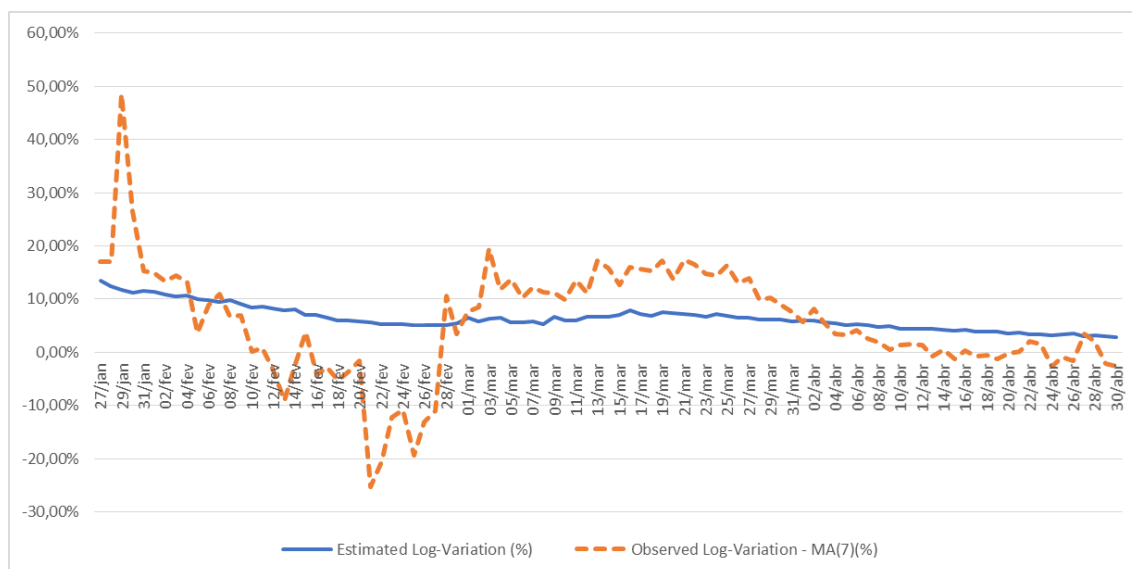
A significância do número de leitos por UTI indica que, como esperado, quanto maior a capacidade do sistema de saúde, maior o preparo do país para isolar e tratar pessoas contaminadas, reduzindo assim a probabilidade de transmissão.

As demais variáveis testadas, listadas na seção 3.8 porém não incluídas no modelo final estimado apresentado anteriormente (equação 5.1), resultaram não significantes. Em particular, a explicação para a não significância da variável binária que indica “existência de epidemia prévia recente” pode estar no reflexo desta experiência sobre a capacidade do sistema de saúde e a adoção precoce de medidas de isolamento, ambas já incorporadas ao modelo. A capacidade do sistema de saúde é uma proxy da renda (com melhor resultado), o que pode explicar a exclusão desta variável do modelo final²³.

O gráfico 5.1 apresenta as taxas de variação estimadas e observadas (média móvel de 7 dias).

²³ Outra explicação é que os efeitos fixos do modelo (invariantes no tempo) capturem o efeito da renda.

Gráfico 5.1 - Evolução das Taxas de Crescimento Estimadas x Observadas (Média Móvel)



A maior estabilidade observada no final da amostra pode ser explicada pela redução do número de novos países que vai sendo incorporado ao estudo com a passagem do tempo. Desta forma, os valores médios das variáveis explicativas (e da taxa de variação) tendem a apresentar menor flutuação. A título de informação, o valor médio apresentado pelas taxas logarítmicas de crescimento da pandemia ao longo de todo o período considerado foi de 5,0%. Observe-se que este período já inclui alguns países com introdução de isolamento social.

As estimativas conseguem acompanhar a variação média da taxa de crescimento da doença, e a tendência levemente decrescente no final do período de estudo. Porém, deve ser levado em consideração que se trata de uma análise para dentro da amostra (*in sample*), ou seja, considerando os valores que foram efetivamente observados para as variáveis explicativas no período de estudo.

Cabe ainda observar que a tendência de queda no final da amostra não implica em redução do número de casos diários, que segue aumentando, mas apenas em uma taxa de variação diária decrescente.

6. Efeitos do Nível de Distanciamento Social sobre a Evolução da COVID-19

Com respeito aos efeitos das políticas de isolamento social, como já foi visto, o impacto causal esperado se confirma, porém apenas quando se categoriza a variável circulação em dois níveis: redução maior que 60% e redução menor/igual a 60% (em relação ao valor anterior à pandemia). Importante ressaltar que este nível de isolamento mais rigoroso não foi obtido por grande parte dos países atingidos pela pandemia, salvo exceções como as apresentadas na seção 3, gráfico 3.1.

Nas tabelas 6.1 a 6.2, a coluna mais à esquerda, para cada linha, considera valores que contribuem (com base nos coeficientes estimados na equação 5.1) para uma maior taxa de variação dos novos casos de COVID-19. Por exemplo, quando se passa da esquerda para a direita em cada linha nessas tabelas, reduz-se a temperatura, aumenta-se o percentual de idosos, reduz-se a cobertura por BCG, aumenta-se o distanciamento em dias a partir do primeiro caso e diminui-se a umidade e reduz-se o número de leitos em hospitais.

As tabelas 6.1 e 6.2, a seguir comparam países com e sem isolamento social estrito, de acordo com a definição adotada. Exercício semelhante pode ser feito com as demais variáveis do modelo.

Tabela 6.1 - Taxas de Crescimento Estimadas – Países/Períodos Sem isolamento Social

	Cenários (Possíveis Valores para as Variáveis Explicativas)							
Temp _{it}	25	20	15	10	5	0	-5	-10
EP _i	0,02	0,06	0,1	0,14	0,18	0,22	0,26	0,3
BCG _i	1	0,8	0,7	0,6	0,5	0,4	0,2	0
FC _{it}	30	40	50	60	70	80	90	100
HM _{it}	8	7	6	5	4	3	2	1
HB _i	8	7	6	5	4	3	2	1
Taxas de Crescimento Logarítmicas (Casos Por Milhão) Estimadas:								
	1,05%	1,91%	2,77%	3,57%	4,34%	5,06%	5,40%	5,60%

Tabela 6.2 - Taxas de Crescimento Estimadas – Países/Períodos Com isolamento Estrito

	Cenários (Possíveis Valores para as Variáveis Explicativas)							
Temp _{it}	25	20	15	10	5	0	-5	-10
EP _i	0,02	0,06	0,1	0,14	0,18	0,22	0,26	0,3
BCG _i	1	0,8	0,7	0,6	0,5	0,4	0,2	0
FC _{it}	30	40	50	60	70	80	90	100
HM _{it}	8	7	6	5	4	3	2	1
HB _i	8	7	6	5	4	3	2	1
Taxas de Crescimento Logarítmicas (Casos Por Milhão) Estimadas:								
	-3,40%	-2,78%	-2,31%	-1,80%	-1,33%	-0,90%	-0,52%	-0,57%

Pode-se notar, na tabela 6.2, uma redução considerável nas taxas de variação estimadas em relação à tabela 6.1, reiterando os efeitos benéficos do isolamento social estrito. Em particular, no cenário intermediário da coluna 5, a taxa reduz-se de 4,34% para -1,33%.

O objetivo do restante desta seção é explorar quantitativamente a dependência dos efeitos do isolamento social sobre a evolução da pandemia, para diferentes valores assumidos pelas demais variáveis (efeitos de interação).

O efeito do isolamento social depende de outras variáveis consideradas no modelo, que neste caso são a temperatura, o número de dias a partir do primeiro caso e o percentual de idosos na população. Especificamente, os resultados do modelo em (5.1) permitem concluir que, tudo o mais constante, estima-se que ao isolamento social estrito está associada uma redução de $100 \cdot (0,04652 - 0,0002\text{Temp}_{it} + 0,00009\text{FC}_{it} + 0,01387\text{EP}_{it}) = (4,652 - 0,02\text{Temp}_{it} + 0,009\text{FC}_{it} + 1,387\text{EP}_{it})$ pontos percentuais na taxa de variação do número de casos por milhão da COVID-19.

A tabela 6.3 fixa a população de idosos em 14% e reporta os efeitos do isolamento social estrito, considerando diferentes valores de temperatura e do número de dias decorridos do primeiro caso.

Tabela 6.3 - Redução (p.p.) na Taxa de Crescimento da COVID-19, Associada ao Isolamento Social, Supondo uma População com 14% de Idosos (≥ 65).

Days From First Case → Temperature (°C) ↓	10	20	30	40	50	60	70	80
-10	5,14	5,23	5,32	5,41	5,50	5,59	5,68	5,77
-5	5,04	5,13	5,22	5,31	5,40	5,49	5,58	5,67
0	4,94	5,03	5,12	5,21	5,30	5,39	5,48	5,57
5	4,84	4,93	5,02	5,11	5,20	5,29	5,38	5,47
10	4,74	4,83	4,92	5,01	5,10	5,19	5,28	5,37
15	4,64	4,73	4,82	4,91	5,00	5,09	5,18	5,27
20	4,54	4,63	4,72	4,81	4,90	4,99	5,08	5,17
25	4,44	4,53	4,62	4,71	4,80	4,89	4,98	5,07
30	4,34	4,43	4,52	4,61	4,70	4,79	4,88	4,97

Para ilustrar os resultados da tabela acima, considere, por exemplo, uma temperatura média de 20°C e 60 dias contados a partir do primeiro caso. Nestas condições, em um país com 14% de população idosa, ao isolamento social estrito estaria associada uma redução de 4,99 pontos percentuais na taxa de crescimento da COVID-19.

A tabela 6.4 fixa em 80 o número de dias a partir do primeiro caso, e reporta os efeitos do isolamento social estrito, considerando valores distintos da temperatura e do percentual de idosos.

Tabela 6.4 - Redução (p.p.) na Taxa de Crescimento da COVID-19, Associada ao Isolamento Social, Supondo 80 Dias Decorridos a Partir do Primeiro Caso

Elderly Percentage → Temperature (°C) ↓	2	6	10	14	18	22	26	30
-10	5,60	5,66	5,71	5,77	5,82	5,88	5,93	5,99
-5	5,50	5,56	5,61	5,67	5,72	5,78	5,83	5,89
0	5,40	5,46	5,51	5,57	5,62	5,68	5,73	5,79
5	5,30	5,36	5,41	5,47	5,52	5,58	5,63	5,69
10	5,20	5,26	5,31	5,37	5,42	5,48	5,53	5,59
15	5,10	5,16	5,21	5,27	5,32	5,38	5,43	5,49
20	5,00	5,06	5,11	5,17	5,22	5,28	5,33	5,39
25	4,90	4,96	5,01	5,07	5,12	5,18	5,23	5,29
30	4,80	4,86	4,91	4,97	5,02	5,08	5,13	5,19

Para ilustrar os resultados da tabela acima, considere, por exemplo, uma temperatura média de -10°C em um país com 22% de idosos. Nestas condições, a 80 dias do primeiro caso, o isolamento social estrito ocasionaria uma redução de 5,88 pontos percentuais na taxa de variação diária dos casos por milhão da COVID-19.

A tabela 6.5 considera uma temperatura de 20°C, e reporta os efeitos da redução de 60% ou mais na circulação, variando o percentual de idosos e o número de dias a partir do primeiro caso.

Tabela 6.5 - Redução (p.p.) Taxa de Crescimento da COVID-19, Associada ao Isolamento Social, Supondo uma País com Temperatura Média de 20°C

Days From First Case → Elderly Percentage ↓	10	20	30	40	50	60	70	80
2	4,37	4,46	4,55	4,64	4,73	4,82	4,91	5,00
6	4,43	4,52	4,61	4,70	4,79	4,88	4,97	5,06
10	4,48	4,57	4,66	4,75	4,84	4,93	5,02	5,11
14	4,54	4,63	4,72	4,81	4,90	4,99	5,08	5,17
18	4,59	4,68	4,77	4,86	4,95	5,04	5,13	5,22
22	4,65	4,74	4,83	4,92	5,01	5,10	5,19	5,28
26	4,70	4,79	4,88	4,97	5,06	5,15	5,24	5,33
30	4,76	4,85	4,94	5,03	5,12	5,21	5,30	5,39

Para ilustrar os resultados da tabela acima, considere, por exemplo, um país com 2% de idosos a 20 dias do primeiro caso. Nestas condições, a uma temperatura média de 20°C, o isolamento social estrito conduziria a uma redução de 4,46 pontos percentuais na taxa de variação diária dos casos por milhão da COVID-19.

7. Conclusões

Um ponto de destaque nos resultados obtidos foi a forte relação observada entre o distanciamento social e a redução da evolução do número de casos da doença. Este resultado vai ao encontro do atual debate acerca da importância do isolamento social estrito (aqui definido como uma redução de 60% ou mais na circulação das pessoas) para o controle da evolução da pandemia.

Adicionalmente, os dados e o método adotado não permitem excluir a hipótese de que a evolução dos casos da COVID-19 possa estar associada a baixas temperaturas e à ausência da cobertura para BCG.

Os resultados aqui apresentados refletem a utilização de técnicas estatísticas, não havendo um modelo subjacente de natureza epidemiológica que permita conclusões mais específicas. Na ausência deste tipo de complementação, tais resultados não são suficientes para a formulação de políticas públicas.

Os autores colocam como possível trabalho posterior a continuidade da estimação com dados mais recentes. Isto é particularmente importante em função das novas características geográficas assumidas pela pandemia, com forte impacto no Brasil, em particular.

Referências Bibliográficas:

BAUMGARTNER, Matheus T. et al. Social distancing and movement constraint as the most likely factors for COVID-19 outbreak control in Brazil. **medRxiv**, 2020.

BCG ATLAS. **The BCG World Atlas**. Disponível em: <bcgatlas.org/index.php>. Acesso em: 22 abr. 2020.

CANO, Oliva Bendtsen; MORALES, Sabrina Cano; BENDTSEN, Claus. COVID-19 Modelling: the Effects of Social Distancing. **medRxiv**, 2020.

CARLETON, T.; MENG, K. C. Causal empirical estimates suggest COVID-19 transmission rates are highly seasonal. **medRxiv**, p. 2020.03.26.20044420, 2020.

CHEN, N. *et al.* Epidemiological and clinical characteristics of 99 cases of 2019 novel coronavirus pneumonia in Wuhan, China: a descriptive study. **The Lancet**, v. 395, n. 10223, p. 507–513, 2020.

CIA. **The World Factbook**. Disponível em: <<https://www.cia.gov/library/publications/the-world-factbook/rankorder/2102rank.html>>.

COELHO, Marco Tulio Pacheco et al. Exponential phase of covid19 expansion is driven by airport connections. **medRxiv**, 2020.

COWLING, B. J.; LEUNG, G. M. Epidemiological research priorities for public health control of the ongoing global novel coronavirus (2019-nCoV) outbreak. **Eurosurveillance**, v. 25, n. 6, p. 1–5, 2020.

CURTIS, N. *et al.* Considering BCG vaccination to reduce the impact of COVID-19. **The Lancet**, v. 6736, n. 20, p. 19–20, 2020.

DING, G. *et al.* Brief Analysis of the ARIMA model on the COVID-19 in Italy. **medRxiv**, p. 2020.04.08.20058636, 2020.

DROPKIN, Greg. COVID-19 UK Lockdown Forecasts and R0. **medRxiv**, 2020.

FERGUSON, Neil et al. Report 9: Impact of non-pharmaceutical interventions (NPIs) to reduce COVID19 mortality and healthcare demand, 2020.

FREDERICKS, B. **Top DHS scientists says heat, humidity slow coronavirus**. Disponível em: <<https://nypost.com/2020/04/23/top-dhs-scientists-says-heat-humidity-slow-coronavirus/>>. Acesso em: 5 ago. 2020.

FUKUI, M.; KAWAGUCHI, K.; MATSUURA, H. Does TB Vaccination Reduce COVID-19 Infection?: No Evidence from a Regression Discontinuity Analysis. **SSRN Electronic Journal**, p. 1–9, 2020.

HAMIEL, Uri; KOZER, Eran; YOUNGSTER, Ilan. SARS-CoV-2 Rates in BCG-Vaccinated and Unvaccinated Young Adults. **JAMA**, 2020.

MALONEY, WILLIAM F.; TASKIN, TEMEL. Determinants of Social Distancing and Economic Activity during COVID-19: A Global View (English). Policy Research working paper; no. WPS 9242; COVID-19 (Coronavirus). Washington, D.C.: World Bank Group, 2020

MILLER, A., M. J. REANDELAR, K. FASCIGLIONE, V. ROUMENOVA, Y. LI, A.;

OTAZU, G. H. Correlation between universal BCG vaccination policy and reduced morbidity and mortality for COVID-19: an epidemiological study. **medRxiv**, 2020.

PRICE, Gregory N.; VAN HOLM, Eric. The Effect of Social Distancing On The Spread of Novel Coronavirus: Estimates From Linked State-Level Infection And American Time Use Survey Data, 2020.

SALA, G.; MIYAKAWA, T. Association of BCG vaccination policy with prevalence and mortality of COVID-19. **medRxiv**, p. 2020.03.30.20048165, 2020.

SEVI, Semra et al. Logarithmic versus Linear Visualizations of COVID-19 Cases Do Not Affect Citizens' Support for Confinement. **Canadian Journal of Political Science/Revue canadienne de science politique**, p. 1-6, 2020.

SHET, A. *et al.* Differential COVID-19-attributable mortality and BCG vaccine use in countries. **medRxiv**, p. 2020.04.01.20049478, 2020.

SHI, P. *et al.* The impact of temperature and absolute humidity on the coronavirus disease 2019 (COVID-19) outbreak - evidence from China. **medRxiv**, n. 77, p. 2020.03.22.20038919, 2020.

SIEDNER, M. J. *et al.* Social distancing to slow the U . S . COVID-19 epidemic : interrupted time-series analysis. **medRxiv**, 2020.

SINGHAL, T. A Review of Coronavirus Disease-2019 (COVID-19). **Indian Journal of Pediatrics**, v. 87, n. 4, p. 281–286, 2020.

STATISTA. **Coronavirus (COVID-19) deaths worldwide per one million population as of May 8, 2020, by country**. Disponível em: <<https://www.statista.com/statistics/1104709/coronavirus-deaths-worldwide-per-million-inhabitants/>>. Acesso em: 8 maio. 2020.

TAG. **More research required to determine if century-old tuberculosis (TB) vaccine protects against SARS-CoV-2/COVID-19**. Disponível em: <<https://www.treatmentactiongroup.org/statement/treatment-action-group-statement-on-bcg-vaccine-and-covid-19/>>. Acesso em: 8 maio. 2020.

WANG, J. *et al.* High Temperature and High Humidity Reduce the Transmission of COVID-19. **SSRN Electronic Journal**, 2020.

WHO. **World Health Data Platform**. Disponível em: <BCG immunization coverage among 1-year-olds (%25)>. Acesso em: 4 maio. 2020.

____. **Bacille Calmette-Guérin (BCG) vaccination and COVID-19**. Disponível em: <[who.int/news-room/commentaries/detail/bacille-calmette-guérin-\(bcg\)-vaccination-and-covid-19](https://who.int/news-room/commentaries/detail/bacille-calmette-guérin-(bcg)-vaccination-and-covid-19)>. Acesso em: 8 maio. 2020.

WOOLDRIDGE, J. M. **Econometric analysis of cross section and panel data**. MIT press, second edition, 2010.

WORLD BANK. **Population ages 65 and above (% of total population)**. Disponível em: <<https://data.worldbank.org/indicator/SP.POP.65UP.TO.ZS>>. Acesso em: 11 maio. 2020.

Os artigos publicados são de inteira responsabilidade de seus autores. As opiniões neles emitidas não exprimem, necessariamente, o ponto de vista da Fundação Getulio Vargas.

EPGE Escola Brasileira de Economia e Finanças

Diretor Geral: Rubens Penha Cysne

Vice-Diretor: Aloisio Araujo

Coordenador de Graduação: André Arruda Villela

Coordenadores de Pós-graduação Acadêmica: Humberto Moreira & Lucas Jóver Maestri

Coordenadores do Mestrado Profissional em Economia e Finanças: Ricardo de Oliveira Cavalcanti & Joísa Campanher Dutra