

**Modelo Dinâmico por Incrementos (MDI) para previsão de período de estabilização da
pandemia do SARS-CoV-2**

**Dynamic Incremental Model (MDI) to forecast the SARS-CoV-2 pandemic stabilization
period**

**Modelo Incremental Dinámico (MDI) para pronosticar el período de estabilización
pandémica SARS-CoV-2**

Recebido: 01/07/2020 | Revisado: 05/07/2020 | Aceito: 13/07/2020 | Publicado: 27/07/2020

Marcus Vinicius Dantas de Assunção

ORCID: <https://orcid.org/0000-0002-3384-1899>

Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte, Brasil

E-mail: marcus.assuncao@ifrn.edu.br

Carla Simone de Lima Teixeira Assunção

ORCID: <https://orcid.org/0000-0003-2246-5100>

Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte, Brasil

E-mail: carla.teixeira@ifrn.edu.br

Rute Anadila Amorim de Oliveira

ORCID: <https://orcid.org/0000-0001-6011-3494>

Universidade Federal do Rio Grande do Norte, Brasil

E-mail: ruteaamorim@hotmail.com

Mariah Caroline Martins de Sousa

ORCID: <https://orcid.org/0000-0002-1851-1138>

Universidade Federal do Rio Grande do Norte, Brasil

E-mail: marihcaroline_@hotmail.com

Resumo

Desde o início do ano de 2020, o mundo vivencia uma pandemia de COVID-19, que desafia o setor público a tomar decisões rápidas e eficientes, pois o resultado é contabilizado em vidas. Desta forma, se faz necessário a busca por modelos preditivos, que subsidiem a decisão e auxiliem na compreensão do comportamento das transmissões. Neste contexto, o trabalho tem como objetivo apresentar um modelo dinâmico para o incremento diário do número de óbitos com o intuito de determinar uma faixa de segurança capaz de prever um período de estabilização destes óbitos. Para isto, o modelo utiliza as curvas exponencial e potencial como

limites para análise do comportamento da curva de incrementos. O modelo se mostrou eficiente quando comparado aos dados reais obtidos até o momento.

Palavras-chave: COVID-19; Modelo dinâmico; Predição; Óbitos.

Abstract

Since the beginning of the year 2020, the world has been experiencing a COVID-19 pandemic, which challenges the public sector to make quick and efficient decisions, as the result is counted in lives. Thus, it is necessary to search for predictive models that support the decision and assist in the understanding of the behavior of the transmissions. In this context, the work aims to present a dynamic model for the daily increase in the number of deaths in order to determine a safety range capable of predicting a stabilization period for these deaths. For this, the model uses exponential and potential curves as limits for analyzing the behavior of the increment curve. The model proved to be efficient when compared to the actual data obtained so far.

Keywords: COVID-19; Dynamic model; Prediction; Deaths.

Resumen

Desde el comienzo del año 2020, el mundo ha estado experimentando una pandemia de COVID-19, que desafía al sector público a tomar decisiones rápidas y eficientes, ya que el resultado se cuenta en vidas. Por lo tanto, es necesario buscar modelos predictivos, que respalden la decisión y ayuden a comprender el comportamiento de las transmisiones. En este contexto, el trabajo tiene como objetivo presentar un modelo dinámico para el aumento diario en el número de muertes con el fin de determinar un rango de seguridad capaz de predecir un período de estabilización para estas muertes. Para esto, el modelo utiliza curvas exponenciales y potenciales como límites para analizar el comportamiento de la curva de incremento. El modelo demostró ser eficiente en comparación con los datos reales obtenidos hasta ahora.

Palabras clave: COVID-19; Modelo dinámico; Predicción; Fallecidos.

1. Introdução

A evolução humana no planeta Terra tem sido marcada por diferentes ondas com impacto revolucionário diferenciado, seja positivo ou negativo, no seu desenvolvimento (Senhoras, 2020). As ondas negativas, de desenvolvimento involutivo, são marcadas por momentos de forte contração na dinâmica biogeográfica humana, identificadas tanto por

ondas bélicas (Mace, 2000) quanto por ondas de pragas e outras epidemias letais com fortes consequências no colapso demográfico (Alfani & Murphy, 2017).

Em primeiro lugar, observa-se que as pandemias mais notáveis e com amplas repercussões espaço-temporais na demografia humana são identificadas por uma periodização de eventos destacadas principalmente na literatura ocidental, partindo do século VI com a conhecida “Praga de Justiniano”, passando pelo século XIV com a “Peste Negra”, até se chegar no século XX com a “Gripe Espanhola” (Senhoras, 2020).

Epidemia, segundo Moura e Rocha (2012), representa a ocorrência de um agravo acima da média (ou mediana) histórica de sua ocorrência. O agravo causador de uma epidemia tem geralmente aparecimento súbito e se propaga por determinado período em determinada área geográfica, acometendo frequentemente elevado número de pessoas. Quando uma epidemia atinge vários países de diferentes continentes, passa a ser denominada pandemia.

De acordo com a Organização Mundial da Saúde (2008), mesmo com a melhoria das condições socioeconômicas da população e o advento de vacinas e antimicrobianos ao longo do século XX, as doenças infecciosas são responsáveis anualmente por cerca de 10 milhões de óbitos no mundo e estão entre as principais causas de anos de vida perdidos.

No início do ano de 2020, o mundo tem vivenciado uma pandemia de COVID-19 causada pela síndrome respiratória aguda grave *SARS-CoV-2*. De acordo com a Organização Mundial da Saúde (2020), a maioria das pessoas infectadas apresenta sintomas respiratórios leves, são assintomáticas ou recuperam-se sem a necessidade de tratamento especial, no entanto, os idosos e pessoas com doenças cardiovasculares, respiratórias crônicas, diabetes ou condições médicas graves, podem desenvolver um caso crítico.

Zu (2020) relata que a síndrome respiratória aguda grave (SARS-CoV-2), foi noticiado em Wuhan, província de Hubei, China, no fim de 2019. Nas semanas seguintes, a infecção espalhou-se pela China e outros países ao redor do mundo. As comunidades de saúde pública, clínica e científica chinesas responderam prontamente para permitir o reconhecimento oportuno do novo vírus e compartilharam a sequência de genes virais para o mundo.

Em 30 de janeiro de 2020, a Organização Mundial da Saúde (OMS) declarou o surto uma Emergência de Saúde Pública de Interesse Internacional (PHEIC). Em 12 de fevereiro de 2020, a OMS nomeou a doença causada pelo novo coronavírus como Doença de Coronavírus 2019 (COVID-19).

Os primeiros esforços se concentraram na descrição do curso clínico, na contagem de casos graves e no tratamento de doentes. A experiência com a síndrome respiratória do

O Oriente Médio (MERS), gripe pandêmica e outros surtos demonstrou que, à medida que a epidemia evolui, enfrenta-se uma necessidade urgente de se expandirem as atividades de saúde pública para elucidar a epidemiologia do novo vírus e caracterizar seu impacto potencial. O impacto de uma epidemia depende do número de pessoas infectadas, da transmissibilidade da infecção e do espectro da gravidade clínica (Lipsitch *et al.*, 2020).

O recente surto de coronavírus, impactou imediatamente as exportações e reduziu drasticamente a disponibilidade de suprimentos (Ivanov, 2020). Araz *et al.* (2020) destaca que a pandemia de COVID-19 representa uma das principais perturbações encontradas nas últimas décadas, e possivelmente significa a “quebra de muitas cadeias de suprimentos globais”.

Deste modo, faz-se importante compreender os comportamentos das curvas de contágio e óbitos a fim de avaliar as medidas necessárias para que o número de casos seja diluído com o tempo e não sobrecarregue o sistema de saúde, conforme sugerem Assunção, Assunção, Martins e Oliveira (2020). Neste cenário, o desenvolvimento de modelos preditivos que sejam capazes de antecipar os fatos se torna fator determinante de decisões governamentais, para a preservação de vidas e melhor aproveitamento dos sistemas de saúde, que tem sua capacidade limitada.

Diante do contexto, este trabalho tem como objetivo apresentar um modelo dinâmico de incrementos com o intuito de determinar uma faixa de segurança capaz de prever um período de estabilização dos casos de óbito da pandemia da SARS-CoV-2.

O trabalho é justificado por haver uma busca científica incessante por previsões que norteiem os agentes públicos para as tomadas de decisões mais próximas da realidade de uma região ou país.

2. Referencial Teórico

2.1 Histórico de pandemias e surgimento do novo coronavírus

De forma subsidiária ao controle da situação epidemiológica em análise, os modelos matemáticos objetivam, por intermédio das simulações e consequentes intervenções provenientes dos estudos, perscrutar de forma quantitativa os efeitos de uma pandemia no meio social. Ainda sob tal viés, os modelos preditivos, seguindo a perspectiva de Montesinos-Lopez e Hernández-Suárez (2007), possuem a função de otimizar a compreensão de um cenário, possibilitando a prevenção efetiva de determinado grupo populacional; e de

determinar a incidência da patologia, auxiliando o processo de erradicação dessa mesma enfermidade.

Compactuando com o eixo lógico apresentado, Cruz (2011) afirma que modelos matemáticos predizem o comportamento de um sistema a partir de um acompanhamento descritivo e contíguo. Nesse sentido, a utilização de tais metodologias podem ser adaptadas a estados díspares, sendo um desses meios as áreas da epidemiologia, pretendendo observar sob uma perspectiva quantitativa e qualitativa dados epidêmicos. O autor ainda ressalta a imprescindibilidade dos modelos estarem em consonância com as realidades de interação populacionais, comportamento de indivíduos, ambiente de proliferação e tendência evolutiva do quadro.

Os principais enfoques dos modelos matemáticos são os processos de infecção e imunização e uma vez estudados os parâmetros de uma epidemia, como tempo médio de infecção de indivíduo, probabilidade de infecção, taxa de mortalidade, torna-se possível fazer previsões e até mesmo encontrar uma forma de combate eficaz. Devido a estes fatos o estudo de modelagem epidemiológica tem crescido cada vez mais e contribuído para as ciências da saúde de forma geral (Temime *et al.*, 2008).

Ainda nesse contexto, Botari (2009) afirma que a descrição evolutiva de uma doença está diretamente associada ao modelo adequado utilizado como parâmetro para os cálculos preditivos. Para isso, existem dois tipos de modelos matemáticos capazes de enquadrar diferentes cenários e, a depender da metodologia de cálculo escolhida, podem auxiliar no acompanhamento de casos, a fim de propiciar uma melhor leitura de contextos pandêmicos.

Em um modelo determinístico, os fatores que intervêm no estudo do processo ou fenômeno podem ser controlados e, portanto, seus resultados podem ser previstos com precisão. Em um modelo estocástico, não é possível controlar os fatores envolvidos no estudo do fenômeno e, conseqüentemente, não produz resultados simples e únicos (Montesinos-Lopez e Hernández-Suárez, 2007).

Isto posto, dentre os modelos mais utilizados em contextos pandêmicos pode-se citar o SIR e o SID que, de acordo com Anderson e May (1991) podem modelar-se de forma determinística ou estocástica, podendo a interação entre indivíduos ocorrer aleatoriamente em ambos os modelos matemáticos.

Kermack e Mckendrik (1927) estruturam a metodologia a SIR em três estágios. O primeiro estágio leva em consideração o quantitativo de indivíduos suscetíveis, os quais são os predispostos a adquirir a doença; a etapa seguinte é a de indivíduos infecciosos, ou seja, os que já podem ser enquadrados como infectados; e por fim, a terceira fase classifica

quantitativamente os que já se recuperaram da doença e não podem mais adquiri-la. Em contrapartida, o SID irá, pelo acréscimo de uma nova variável, trabalhar com o número de vítimas fatais, classificando os indivíduos como suscetíveis, infectados e mortos. Com tais dados, nos modelos citados, é possível prever os efeitos de uma pandemia, considerando variáveis populacionais e epidemiológicas.

2.2. Modelos preditivos para o vírus SARS-COV-2

Bastos e Cajueiro (2020), a partir da modelagem de dados com fins preditivos, buscam prever etapas do processo evolutivo do COVID-19 no cenário brasileiro. Para isso, utilizaram duas variações da metodologia SIR com incremento de um novo parâmetro, o qual considera os efeitos da medida de distanciamento social no país. Como resultado alcançado do modelo de pesquisa, os autores determinam que, a curto e longo prazo, a política de distanciamento imposta pelo governo é capaz de atenuar o padrão de infecção do vírus. No entanto, cabe registrar que, em caso do descumprimento de tal política, o pico de infecção identificado será adiado.

Ainda buscando alternativas preditivas para acompanhamento da evolução da propagação do SARS-COV-2, Vasconcelos *et al.* (2020) aplicaram a metodologia RGM para modelagem das curvas de mortalidade da doença, representado pelo número acumulado de óbitos em função do tempo, e utilizaram um modelo matemático para estudar a eficácia de possíveis estratégias de intervenção.

Partindo para o contexto mundial, em um estudo divulgado pelo *Imperial College London* (2020), pesquisadores mensuraram o impacto de diferentes intervenções sobre a mortalidade do COVID-19 e as solicitações de atendimento médico. O modelo matemático construído inclui dados como o período estimado de incubação do vírus e a capacidade hospitalar do Reino Unido e Estados Unidos. Como conclusão da pesquisa, a melhor opção para os países - que podem acatar por esse método - é optar por uma estratégia de supressão, ao invés de voltar esforços apenas para a mitigação da pandemia.

Liang (2020) analisa, por meio de ajuste não-linear, as características de crescimento do COVID, SARS e MERS. O estudo conclui, com auxílio de análise paramétrica, que a taxa de crescimento do COVID-19 é aproximadamente o dobro da do SARS e MERS, e o ciclo de duplicação do COVID-19 é de dois a três dias, sugerindo que o número de pacientes com COVID-19 dobraria em dois a três dias sem intervenção humana

Ghosal *et al.* (2020) propuseram um modelo, baseado em regressão múltipla e regressão linear, para traçar uma tendência relacionada à contagem de óbitos esperada na 5ª e 6ª semana do COVID-19 na Índia.

Há possibilidade ainda do uso de diferentes variáveis para a modelagem. Qin *et al.* (2020) propõe um modelo com base nos índices de pesquisa de mídia social para palavras como: tosse seca, febre, angústia no peito, coronavírus e pneumonia. Tal modelo apresentou altas correlações e se mostrou capaz de prever os números com seis a nove dias de antecedência.

Por fim, Wang *et al.* (2020) propõem um modelo preditivo para o pico da contaminação na região de Wuhan, na China, pós medidas de distanciamento social. O trabalho considera a taxa de contágio (R) e varia esta taxa conforme a implementação das medidas de isolamento, fazendo uso das medidas ajustadas por fase da epidemia. Um modelo de dinâmico denominado SEIR (Susceptível, Exposto, Infeccioso e Removido) foi aplicado para estimar a tendência epidêmica.

3. Materiais e Métodos

Os dados utilizados nesta pesquisa são secundários e foram coletados por meio dos boletins epidemiológicos do Ministério da Saúde do Brasil disponíveis em seu sítio eletrônico, nos meses de março e abril de 2020. Os dados foram analisados por meio do *software Statistical Package for the Social Sciences - SPSS* versão 24 e foram ainda analisados, como meio de validação, pelo Microsoft Office Excel.

No afã de se reduzir o grau de incerteza quanto à predição do comportamento da curva de óbitos, o modelo dinâmico por incrementos (MDI) propõe a construção de uma curva a partir dos incrementos diários de óbitos frente ao *quantum* acumulado até então. O modelo considera que os incrementos diários reduzir-se-ão à medida que a relação entre os óbitos e o total acumulado até então diminuirão com o passar do tempo.

Na busca por um modelo mais ajustado, foram testados os modelos polinomiais de segundo grau ($y = \beta_0 + \beta_1x + \beta_2x^2$) e terceiro grau ($y = \beta_0 + \beta_1x + \beta_2x^2 + \beta_3x^3$), o exponencial ($y = e^{\beta_0 + \beta_1x}$), o modelo logarítmico ($y = \beta_0 \ln x + \beta_1$) e, por fim, o modelo potencial ($y = \beta_1 x^{\beta_0}$). Após serem testadas todas as curvas, constatou-se que a evolução da


quantidade de óbitos correspondia a uma semelhança entre as curvas exponencial e potencial, atingindo-se um índice de ajustamento da curva (R^2) superior a 0,9, em todos os ensaios realizados.

Nesses modelos, β_0 é o coeficiente de incremento médio diário (interceptação com o eixo y), β_1 é o coeficiente de velocidade dos óbitos e x corresponde a quantidade de dias decorridos desde o 1º óbito. As variações apresentadas pelas séries foram suavizadas por meio de média móvel centrada em sete termos. Nesse processo, o coeficiente analisado do dia j (y_j) corresponde à média aritmética dos coeficientes dos últimos 7 dias, haja vista representar uma semana epidemiológica, e é representado pela Equação 1, onde “n” é igual a 7:

$$y_j = \frac{\sum_{i=1}^n y_{(j-i)}}{n} \quad (1)$$

As curvas exponencial e potencial serão utilizadas como limites para o comportamento da curva de incrementos diários de óbitos desenvolvida para a região estudada, conforme demonstrado na Figura 1.

Figura 1 – Limites preditivos a partir das curvas exponencial e potencial.



Fonte: Dados da pesquisa (2020).

A faixa de estabilização da pandemia, seja por medidas de distanciamento social ou por grande índice de recuperados da população, será determinada por meio da Equação 2.

$$(\mu - \sigma) * 0,05 \leq \delta \leq (\mu + \sigma) * 0,05 \quad (02)$$


Os valores dos limites inferior e superior da faixa de estabilização são multiplicados por 0,05, uma vez que a significância admitida nesse trabalho é de 95%. Os valores dos fatores $[(\mu - \sigma) * 0,05]$ e $[(\mu + \sigma) * 0,05]$ devem ser consultados a partir das curvas exponencial e potencial produzidas, para cada período, e observados os dias correspondentes aos valores consultados. Os dois dias encontrados irão compor a faixa de estabilização dos casos de óbitos (δ). Há ainda a possibilidade e se prever uma faixa para quantificar os óbitos esperados, dia a dia. Para tanto, basta substituir o valor de “x” nas expressões das curvas pelo valor correspondente ao dia vigente, a partir do 1º dia registrado com óbito.

4. Resultados e Discussão

O primeiro caso confirmado da *SARS-CoV-2* no Brasil deu-se em 26 de fevereiro de 2020, no estado de São Paulo enquanto o primeiro óbito foi registrado em 18 de março de 2020, na cidade de São Paulo. Até o dia 25 de junho de 2020, o Brasil já contava com aproximadamente 1,2 milhões de casos confirmados e um acumulado de 53.933 óbitos em decorrência da referida doença, segundo o Ministério da Saúde (2020).

A Figura 2 apresenta o quantitativo dia a dia dos óbitos registrados no país de forma absoluta e acumulada. Percebe-se, contudo, um comportamento polinomial na curva acumulada até o 20º dia - desde a primeira morte registrada - e, a partir do 21º dia, um comportamento exponencial da curva desenvolvida a partir dos óbitos registrados.


Figura 2 – Quantidade absoluta e acumulada de óbitos por dia registrados no Brasil por *SARS-CoV-2* até o dia 25/06/2020.



Fonte: Ministério da Saúde do Brasil (2020).

Então, como há comportamentos distintos apresentados em diferentes fases da curva de óbitos, resta clara a dificuldade na obtenção de uma predição que leve os agentes públicos a tomarem decisões calçadas em modelos preditivos com elevado grau de amplitude e com alta variabilidade nos dados. Com o intuito de se reduzir o grau de incerteza quanto à previsão do comportamento da curva de óbitos, foi aplicado aos dados do estudo de caso o modelo dinâmico por incrementos (MDI). A Figura 3 demonstra os incrementos diários dos casos de óbitos no Brasil durante a pandemia do *SARS-CoV-2* entre os dias 17/03/2020 e 25/06/2020.

Figura 3 – Incrementos diários x incrementos ajustados pela média móvel para $n=7$.



Fonte: Dados da pesquisa (2020).

O comportamento da curva de incrementos denota uma redução sistemática do percentual de mortos ante o acumulado. É importante ressaltar que muitos óbitos não foram

contabilizados na data da morte, uma vez que o Ministério da Saúde recomendou às secretarias de saúde dos estados brasileiros que, em decorrência da restrita quantidade de testes de detecção do coronavírus, somente deveriam ser testados pacientes que estivessem em estado grave. A falta de exames e as mortes de pacientes sem diagnóstico para COVID-19 provocaram uma fila de amostras de exames, que foram liberados conforme foram sendo processados, mas mascarando os dados. Considerando a necessidade de se trabalhar com dados mais homogêneos e buscando-se ainda a redução dos resíduos produzidos pela variabilidade dos dados, utilizou-se do recurso da média móvel aritmética, a fim de se corrigirem discrepâncias oriundas de intempéries diversas, quais sejam: erros de notificação, resultados tardios, exumação de corpos, entre outros.

As curvas que se assemelham ao comportamento do modelo dinâmico de incrementos são a exponencial e a potencial (função irracional) e estas serão utilizadas nesse trabalho para subsidiarem os limites admitidos como controle para se delinear a previsão de um recorte temporal que justifique o ponto de inflexão da curva de óbitos. A Tabela 1 mostra as curvas de controle para o período compreendido entre o primeiro e o vigésimo dia com registro de morte no Brasil e depois para períodos de 7 (sete) em 7 (sete) dias subsequentes.

Tabela 1 – Equações utilizadas e R^2

Período	Curva Potencial	R^2	Curva Exponencial	R^2
1° a 21° dia	$y = 1,4771 x^{-0,716}$	0,9336	$y = 0,8871 e^{-0,094x}$	0,9332
22° a 28° dia	$y = 1,5272 x^{-0,737}$	0,9519	$y = 0,7447 e^{-0,074x}$	0,9030
29° a 35° dia	$y = 1,6483 x^{-0,780}$	0,9575	$y = 0,6703 e^{-0,064x}$	0,9110
36° a 42° dia	$y = 1,7977 x^{-0,825}$	0,9566	$y = 0,6156 e^{-0,058x}$	0,9177
43° a 49° dia	$y = 1,8075 x^{-0,828}$	0,9630	$y = 0,5402 e^{-0,049x}$	0,8873
50° a 56° dia	$y = 1,8537 x^{-0,839}$	0,9676	$y = 0,4898 e^{-0,044x}$	0,8774
57° a 63° dia	$y = 1,8876 x^{-0,847}$	0,9713	$y = 0,4478 e^{-0,039x}$	0,8686
64° a 70° dia	$y = 1,9352 x^{-0,857}$	0,9740	$y = 0,4151 e^{-0,036x}$	0,8659
71° a 77° dia	$y = 2,0440 x^{-0,879}$	0,9722	$y = 0,3951 e^{-0,034x}$	0,8768
78° a 84° dia	$y = 2,1896 x^{-0,906}$	0,9681	$y = 0,3802 e^{-0,033x}$	0,8897
85° a 91° dia	$y = 2,3886 x^{-0,939}$	0,9603	$y = 0,3703 e^{-0,032x}$	0,9042
92° a 98° dia	$y = 2,5970 x^{-0,970}$	0,9545	$y = 0,3597 e^{-0,031x}$	0,9144

Fonte: Dados da pesquisa (2020).

As curvas potenciais apresentaram um ajuste importante, uma vez que o R^2 ajustado variou entre 0,9336 e 0,9740, mostrando um fator de explicação da variável independente (tempo) em relação à dependente (incremento diário médio) superior a 93% em todos os casos.

Já as curvas exponenciais, obtiveram R^2 ajustados variando entre 0,8659 e 0,9332, o que traz um fator de explicação da variável independente (tempo) em relação à dependente (incremento diário médio) superior a 86% em todos os casos.

Nos primeiros 21 dias de pandemia, considerando o primeiro óbito registrado, devem ser observadas as estratégias de enfrentamento utilizadas pelas autoridades sanitárias a fim de se fazer a leitura adequada dos gráficos produzidos pelo modelo dinâmico proposto a partir de incrementos diários de óbitos. Portanto, espera-se que produzam dados históricos a fim de subsidiarem as projeções futuras. No caso do Brasil, há um controle evidenciado a partir do 16º dia após a primeira morte registrada, conforme demonstrado nas Figuras 4 e 5. A tendência apresentada mostra um crescimento no número de casos de óbitos no referido país, mas com taxas decrescentes de incrementos, o que em alguns períodos conduz o gráfico à proximidade do limite imposto pela curva potencial e em outros momentos à curva exponencial.

Figura 4 – Modelo MDI dias 1º a 21º.


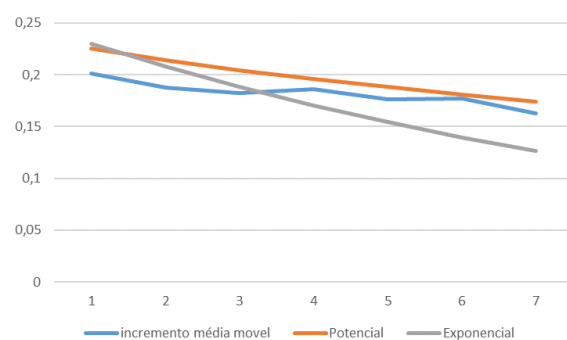


Figura 5 - Modelo MDI dias 14º a 21º.



Fonte: Dados da pesquisa (2020).

Convém pontuar que o controle estabelecido para uma semana que irá iniciar, deve seguir as curvas de controle formadas pelos dados da semana imediatamente anterior. Como exemplo, pode-se observar que as curvas potencial e exponencial apresentadas na Tabela 1, concernentes à semana do 22º ao 28º dia, produziram as curvas de controle da semana compreendida entre os dias 29 e 35, cujos resultados estão demonstrados pelas Figuras 6 e 7.

Figura 6 – Modelo MDI dias 1º a 35º.


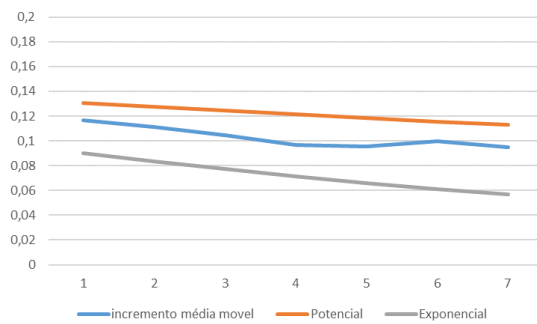


Figura 7 – Modelo MDI dias 29º a 35ª .



Fonte: Dados da pesquisa (2020).

Considerando que o modelo é dinâmico e construído a partir dados históricos do próprio caso em questão, faz-se necessária a correção das curvas de 7 em 7 dias, haja vista ser o período escolhido para a redução de resíduos da curva por meio da média móvel aritmética. A Tabela 2 contém todas as previsões construídas a partir das equações demonstradas na Tabela 1, confrontadas com os valores reais.

Tabela 2 – Previsão das escalas x valores reais.

Dia	Escala Exponencial	Escala potencial	Escala real	Dia	Escala Exponencial	Escala potencial	Escala real
22	0,1122	0,1615	0,1570	61	0,0334	0,0589	0,0536
23	0,1021	0,1565	0,1571	62	0,0320	0,0581	0,0515
24	0,0929	0,1518	0,1508	63	0,0306	0,0573	0,0523
25	0,0846	0,1474	0,1425	64	0,0369	0,0557	0,0516
26	0,0770	0,1433	0,1270	65	0,0355	0,0550	0,0501
27	0,0701	0,1395	0,1226	66	0,0341	0,0543	0,0500
28	0,0638	0,1359	0,1166	67	0,0328	0,0536	0,0488
29	0,0871	0,1277	0,1112	68	0,0316	0,0529	0,0477
30	0,0809	0,1245	0,1043	69	0,0304	0,0523	0,0475
31	0,0751	0,1216	0,0968	70	0,0292	0,0517	0,0466
32	0,0698	0,1187	0,0958	71	0,0322	0,0546	0,0433
33	0,0648	0,1161	0,0996	72	0,0311	0,0540	0,0427
34	0,0602	0,1136	0,0948	73	0,0300	0,0533	0,0404
35	0,0559	0,1112	0,0897	74	0,0289	0,0527	0,0393
36	0,0675	0,1007	0,0794	75	0,0279	0,0522	0,0378
37	0,0633	0,0986	0,0707	76	0,0269	0,0516	0,0360
38	0,0594	0,0966	0,0743	77	0,0260	0,0510	0,0341
39	0,0557	0,0946	0,0737	78	0,0279	0,0444	0,0338
40	0,0523	0,0928	0,0735	79	0,0269	0,0439	0,0337
41	0,0490	0,0910	0,0732	80	0,0260	0,0434	0,0337
42	0,0460	0,0893	0,0776	81	0,0252	0,0429	0,0320
43	0,0508	0,0807	0,0824	82	0,0243	0,0425	0,0309
44	0,0480	0,0792	0,0860	83	0,0235	0,0420	0,0306
45	0,0453	0,0778	0,0790	84	0,0227	0,0416	0,0302
46	0,0427	0,0764	0,0748	85	0,0230	0,0391	0,0292
47	0,0403	0,0750	0,0714	86	0,0223	0,0387	0,0279
48	0,0380	0,0737	0,0706	87	0,0215	0,0383	0,0260
49	0,0359	0,0725	0,0657	88	0,0208	0,0379	0,0250
50	0,0466	0,0708	0,0630	89	0,0202	0,0375	0,0244
51	0,0444	0,0697	0,0616	90	0,0195	0,0371	0,0244
52	0,0423	0,0686	0,0606	91	0,0189	0,0368	0,0238
53	0,0402	0,0675	0,0618	92	0,0195	0,0342	0,0231
54	0,0383	0,0665	0,0627	93	0,0189	0,0339	0,0224
55	0,0365	0,0655	0,0634	94	0,0183	0,0335	0,0218
56	0,0347	0,0645	0,0626	95	0,0177	0,0332	0,0222
57	0,0399	0,0624	0,0619	96	0,0172	0,0329	0,0221
58	0,0382	0,0615	0,0598	97	0,0166	0,0326	0,0219
59	0,0365	0,0606	0,0588	98	0,0161	0,0322	0,0232
60	0,0350	0,0597	0,0559				

Fonte: Dados da pesquisa (2020).

Nos 77 dias de observação foram identificados apenas 3 dias em que as quantidades reais de óbitos não estiveram inseridas entre os valores das curvas: os dias 43, 44 e 45. Esse quantitativo representa 3,89% da quantidade de dias aferidos, o que demonstra um bom ajuste no modelo apresentado.

A determinação do período de estabilização dos casos de óbitos da pandemia da *SARS-CoV-2* dar-se-á por meio da utilização da Equação 2, cujos resultados estão disponíveis na Tabela 3.

Tabela 3 – Previsão da faixa de dias da estabilização dos casos de óbito.

Dias a partir do 1º óbito	Previsão				
	64º ao 70º	71º ao 77º	78º ao 84º	85º ao 91º	92º ao 98
Média (μ)	0,1691	0,1573	0,1469	0,1375	0,1293
Desvio Padrão (σ)	0,1259	0,1206	0,1164	0,1124	0,1086
Limite Superior ($\mu + \sigma$) * 0,05	0,0147	0,0139	0,0131	0,0125	0,0119
Limite Inferior ($\mu - \sigma$) * 0,05	0,0021	0,0018	0,0015	0,0012	0,0010
Limite Superior (dias)	307	363	312	310	281
Limite Inferior (dias)	137	151	163	173	182

Fonte: Dados da pesquisa (2020).

Os resultados mostram que até o 98º dia (após a 1ª morte) a faixa de estabilização dos casos de óbitos (δ) da pandemia estaria compreendida entre os dias 182 e o 281, a depender das medidas adotadas pelos agentes governamentais e do comportamento praticado pela população quanto ao distanciamento social.

5. Conclusão

O objetivo desta pesquisa foi de apresentar um modelo dinâmico de incrementos com o intuito de determinar uma faixa de segurança capaz de prever um período de estabilização dos casos de óbito da pandemia da *SARS-CoV-2*.

O Modelo Dinâmico por Incrementos (MDI) apresentou um bom ajuste para as curvas potencial e exponencial, com R^2 superior a 0,86, o que ratifica o seu potencial preditivo. A grande contribuição do modelo para a sociedade é a previsão de uma faixa temporal de estabilização dos casos de óbito da pandemia, cujo resultado poderá subsidiar decisões mais

acertadas por parte dos agentes públicos quanto às medidas necessárias ao enfrentamento da pandemia em cada fase.

Portanto, é lícito dizer que o MDI trará uma maior precisão às previsões de tempo restante da pandemia, o que possibilitará ações preventivas de contingência no intuito de se preservarem vidas. Para evolução desse modelo, sugere-se a aplicação do modelo de modo regionalizado, a fim de se obterem resultados ainda mais precisos.

Referências

Alfani, G., & Murphy, T. E. (2017). Plague and lethal epidemics in the pre-industrial world. *the Journal of economic History*, 77(1), 314-343.

Anderson, R. M., & May, R. M. (1991). *Infectious diseases of humans*. 1991. *New York: Oxford Science Publication Google Scholar*.

Araz, O. M., Choi, T. M., Olson, D. L., & Salman, F. S. (2020). Role of Analytics for Operational Risk Management in the Era of Big Data. *Decision Sciences*.

Assunção, C. S. L. T. Assunção, M. V. D., Sousa, M. C. M., & Oliveira, R. A. A. (2020). A relational study between government decrees and number of deaths by COVID-19 in Northeastern Brazil. *Research, Society and Development*, 9 (8), 1-20.

Bastos, S. B., & Cajueiro, D. O. (2020). Modeling and forecasting the Covid-19 pandemic in Brazil. *arXiv preprint arXiv:2003.14288*.

Botari, T., Alves, S. G., & Leonel, E. D. (2011). Explaining the high number of infected people by dengue in Rio de Janeiro in 2008 using a susceptible-infective-recovered model. *Physical Review E*, 83(3), 037101.

Brasil (2020). Ministério da Saúde. Boletins epidemiológicos diários. Brasília/DF.

Cruz, A. R. (2011). Uma metodologia multiobjetivo para o controle de epidemias através de vacinação impulsiva via algoritmo genético com operador de busca local baseado em aproximação quadrática convexa e validação estocástica.

Ghosal, S., Sengupta, S., Majumder, M., & Sinha, B. (2020). Prediction of the number of deaths in India due to SARS-CoV-2 at 5–6 weeks. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*.

Ivanov, D. (2020). Predicting the impacts of epidemic outbreaks on global supply chains: A simulation-based analysis on the coronavirus outbreak (COVID-19/SARS-CoV-2) case. *Transportation Research Part E: Logistics and Transportation Review*, 136, 101922.

Kermack, W. O., & McKendrick, A. G. (1927). A contribution to the mathematical theory of epidemics. *Proceedings of the royal society of london. Series A, Containing papers of a mathematical and physical character*, 115(772), 700-721.

Liang, K. (2020). Mathematical model of infection kinetics and its analysis for COVID-19, SARS and MERS. *Infection, Genetics and Evolution*, 104306.

Lipsitch, M., Swerdlow, D. L., & Finelli, L. (2020). Defining the epidemiology of Covid-19—studies needed. *New England journal of medicine*, 382(13), 1194-1196.

Mace, R. (2000). Evolutionary ecology of human life history. *Animal behaviour*, 59(1), 1-10.

Montesinos-Lopez, O. A., & Hernandez-Suarez, C. M. (2007). Mathematical models for infectious diseases. *Salud publica de Mexico*, 49(3), 218-226.

Moura, U. A. S., & Rocha, R. L. (2012). Endemias e epidemias: dengue, leishmaniose, febre amarela, influenza, febre maculosa e leptospirose. *Belo Horizonte: Nescon/UFMG*.

Organização Mundial de Saúde. The global burden of disease: 2004 update. Geneva: World Health Organization, 2008.

Organização Mundial de Saúde. Visão Geral do coronavirus. Disponível em:
< <https://www.who.int/health-topics/coronavirus>>. Acesso em: 26/04/2020.

Qin, L., Sun, Q., Wang, Y., Wu, K. F., Chen, M., Shia, B. C., & Wu, S. Y. (2020). Prediction of number of cases of 2019 novel coronavirus (COVID-19) using social media search index. *International journal of environmental research and public health*, 17(7), 2365.

Senhoras, E. M. (2020). Coronavírus e o papel das pandemias na história humana. *Boletim de Conjuntura (BOCA)*, 1(1), 31-34.

Temime, L., Hejblum, G., Setbon, M., & Valleron, A. J. (2008). The rising impact of mathematical modelling in epidemiology: antibiotic resistance research as a case study. *Epidemiology & Infection*, 136(3), 289-298.

Vasconcelos, G. L., Macêdo, A. M., Ospina, R., Almeida, F. A., Duarte-Filho, G. C., Brum, A. A., & Souza, I. C. (2020). Modelling fatality curves of COVID-19 and the effectiveness of intervention strategies. *PeerJ*, 8, e9421.

Walker P, Whittaker C, Watson O, Baguelin M, Ainslie K, Bhatia S et al (2020). Report 12: The global impact of COVID-19 and strategies for mitigation and suppression. London: Imperial College; 2020.

Wang, H., Wang, Z., Dong, Y., Chang, R., Xu, C., Yu, X., ... & Wang, Y. (2020). Phase-adjusted estimation of the number of coronavirus disease 2019 cases in Wuhan, China. *Cell discovery*, 6(1), 1-8.

Zu, Z. Y., Jiang, M. D., Xu, P. P., Chen, W., Ni, Q. Q., Lu, G. M., & Zhang, L. J. (2020). Coronavirus disease 2019 (COVID-19): a perspective from China. *Radiology*, 200490.

Porcentagem de contribuição de cada autor no manuscrito

Marcus Vinicius Dantas de Assunção – 30%

Carla Simone de Lima Teixeira Assunção – 30%

Rute Anadila Amorim de Oliveira – 20%

Mariah Caroline Martins de Sousa – 20%