

# COVID-19 con Fases Inciertas: Problemas de Estimación con una Ilustración para Argentina



Hildegart Ahumada, Santos Espina, Fernando H. Navajas

20 de junio de 2020

Disponible en SSRN: <https://ssrn.com/abstract=3633500> o <http://dx.doi.org/10.2139/ssrn.3633500>

Traducción: Enrique A. Bour

## Resumen

*Utilizamos un enfoque para evaluar el desempeño de COVID-19 que parte de lo que consideramos es el conjunto de hipótesis más probable sobre la incierta evolución de la pandemia, que prevé una secuencia de diferentes ciclos de duración y magnitud desconocidas a lo largo de 18-24 meses. Esta pauta implica una estrategia de investigación en la que el pronóstico de series temporales a corto plazo de evolución de los casos y fallecimientos observados desempeña un papel central tanto en la detección de transiciones de fase a fase de las infecciones como también en la estimación de parámetros e indicadores estructurales necesariamente cambiantes de un modelo SIRD. Ilustramos nuestro enfoque con el desempeño de la Ciudad de Buenos Aires, que representa una parte importante del caso argentino con una introducción temprana de un bloqueo seguido de una segunda ola posterior. Este enfoque puede ampliarse para incluir medidas de intensidad y cumplimiento de los cierres, así como la heterogeneidad entre áreas. Hemos hallado que la movilidad (como sustituto de la eficacia del bloqueo) tiene un impacto en los casos observados en la Ciudad de Buenos Aires con un retraso de 8 días y los fallecimientos se relacionan con casos nuevos registrados entre 16 y 19 días antes. La movilidad tiene un claro impacto sobre la tasa de crecimiento de casos y por extensión de fallecimientos. Nuestro enfoque y resultados tienen implicancias para el diálogo político.*

JEL No. C5, I1

[Se incluye la traducción de las secciones 1. Introducción, 2. Cuestiones de estimación y pronóstico de COVID-19 y el modelo SIR (parte inicial), 5. Resumen de los resultados y observaciones finales, y Referencias]

## 1. Introducción

Lejos de ser un fenómeno bien comprendido, prevalece mucha incertidumbre en cuanto a la actuación y los resultados observados de la pandemia COVID-19 porque está rodeada de muchas incógnitas, como cabe esperar de esta pandemia mundial de reciente aparición. Esto hace que el proceso epidemiológico que configura la dinámica de COVID-19 sea incierto tanto en términos de tiempo como de ritmo de cambio o evolución, asimismo porque el desarrollo de una vacuna altera fundamentalmente el escenario. Esta incertidumbre científica se enfrenta desde todos los ángulos de estudio, incluidos los modelos económico-epidemiológicos sobre duración e intensidad óptimas de los cierres que utilizan para sus fines de simulación valores de parámetros o valores de intervalo tomados de estudios epidemiológicos (Acemoglu y otros, 2020; Álvarez y otros, 2020; Garriga y otros, 2020; González Eiras y Niepelt, 2020 por mencionar una lista breve pero representativa). Algunas síntesis científicas basadas en modelos epidemiológicos y pruebas empíricas e históricas prevén una pauta con ciclos por delante en un período de 18 a 24 meses (Moore et al., 2020) administrada o condicionada a la ausencia de una vacuna. Desde nuestra perspectiva, este punto de vista debería tener importantes implicancias metodológicas para los esfuerzos de medición y estimación a fin de seguir y pronosticar la dinámica de COVID-19, que son útiles para ajustar los parámetros utilizados en las simulaciones y la modelización o las evaluaciones. Implica claramente que no estamos presenciando, excepto quizás para su despegue, una trayectoria no mitigada para la mayoría de los casos de países, debido a la interacción con las intervenciones o los cierres y el comportamiento, preventivo o no, de la sociedad. Los arranques y los efectos iniciales de mitigación para aplanar la curva se han estimado de una forma estrechamente ligada a los parámetros estructurales del modelo SIR (por ejemplo, Harris, 2020), con técnicas de predicción (por ejemplo, Castle, et al, 2020), con marcos epidemiológicos sofisticados (Imperial College, 2020) o mediante modelos econométricos mixtos en forma reducida (Hsiang et al, 2020). Sin embargo, el reconocimiento de que tal vez estemos asistiendo sólo a una fase inicial de una trayectoria de varios ciclos implica una estrategia completamente diferente a fin de evitar un modelo SIR de un solo pico que podría conducir a errores de previsión y, posiblemente, de política. La pauta en muchos países es que tal vez no haya un único proceso o ciclo con un pico, sino más bien fases de una dinámica temporalmente reprimida que se desplazará en el tiempo, pero ésta es también una hipótesis incierta.

Las políticas de mitigación, las elecciones humanas y los shocks, hacen que el pronóstico de casos y fallecimientos esté sujeto a cambios en su distribución, lo que lleva a una inestabilidad de parámetros y a graves errores de pronóstico. Este es un hecho que se ha descubierto hace algún tiempo en el campo de la modelización de series temporales macroeconómicas (véase Hendry, 2000; 2020) y que se ha aplicado recientemente a la modelización de arranques de COVID-19 (Castle et al, 2020). Utilizan la modelización de predicción como una estrategia conveniente para predecir la trayectoria de casos de COVID-19 a corto plazo, al tiempo que comparan

sus predicciones con las de una modelización epidémica convencional como el modelo SIR, con parámetros obtenidos de una estimación no lineal. Sugieren una complementariedad entre los algoritmos de predicción de corto plazo y los modelos epidemiológicos para el análisis de la trayectoria esperada. Sin embargo, por razones reflejadas en la literatura epidemiológica (Moore et al, 2020) el proceso general de la pandemia es incierto en cuanto a su dimensión, duración, velocidad y ciclos de recurrencia. Esta última pauta puede afectar la predicción del pronóstico a largo plazo con el modelo SIR o con modelos de curvas logísticas empíricas (Gompertz) que asumen una sola trayectoria de pico (véase, por ejemplo, Batista, 2020; Sánchez-Villegas, 2020, Lee et al, 2020). Otros modelos más complejos basados en información detallada y que utilizan variantes de modelos de crecimiento no lineales (IHME, 2020) han sido expuestos por la prensa especializada a críticas por fallas en el pronóstico (subestimación) en los EE.UU. (Wallace-Wells, 2020) y los modelos de pronóstico de redes neuronales aplicados a Brasil también han llevado a una subestimación significativa (Pereira et al, 2020) o han sido superados por modelos de series temporales de crecimiento exponencial (Martínez et al, 2020). Por último, volviendo a una estrategia de pronóstico a corto plazo, uno de los modelos más completos y reconocidos para el pronóstico de COVID-19 con resultados para muchos países (Imperial College, 2020) tiene también un horizonte a corto plazo, centrándose en la evolución de fallecimientos observados en lugar de casos observados, debido a los problemas de medición de estos últimos, y utilizando un marco SEIR.

En este documento sostenemos que existe una conexión a explotar entre las previsiones de series temporales a corto plazo por un lado y los parámetros de un modelo SIRD por otro, en cuanto a la detección de regímenes de crecimiento presumibles que la epidemia pueda exhibir en un escenario incierto de ondas múltiples. Ello se debe a la observación de que un modelo de regresión dinámica de la tasa de crecimiento (con una aproximación logarítmica) de los casos observados de COVID19 se relaciona bien con el parámetro de la tasa de infección del modelo SIRD estimado de manera linealizada (en lugar de no lineal), como se contempla, por ejemplo, en Harris (2020). Así pues, los pronósticos de un modelo de series temporales que aproveche técnicas de saturación por impulsos y por pasos (Hendry y Doornik, 2014) para detectar rupturas permiten ayudar en el proceso de detección de cambios en la naturaleza evolutiva del proceso de COVID-19 y traducirlo directamente en parámetros SIRD, proporcionando un diálogo conveniente desde el punto de vista metodológico. Se puede realizar un enfoque complementario de previsión en el caso de los fallecimientos observados, que son un elemento necesario para el diseño de políticas y el debate.

Ilustramos nuestra estrategia de modelización para el caso de la ciudad de Buenos Aires que sirve a nuestro propósito y también representa hasta ahora el motor central y más rico de la dinámica observada. Esto puede describirse, hasta el momento de escribir esta versión, en general en tres etapas con una cuarta que probablemente venga pronto, cada una correspondiente a un mes diferente de marzo a junio. A mediados de marzo de 2020, cuando algunos países europeos mostraban la peor cara

de COVID-19 y dados los innegables vínculos con Italia y España en los genes, la cultura y, en particular, los lazos de viaje, el gobierno de Argentina sintió el abismo que se avecinaba, ya que los casos importados y los casos de contacto relacionados empezaron a generar una dinámica de pandemia. Con el apoyo de un sólido grupo de virólogos y expertos en atención sanitaria, el 20 de marzo se inició oficialmente una cuarentena que se ha ido ampliando desde entonces con normas de relajación desde fines de mayo. La enfermedad tendió a concentrarse cada vez más en la Ciudad de Buenos Aires y el Gran Buenos Aires, explicando más del 80% de los casos y fallecimientos, ya que los datos mostraban que el interior del país estaba en una situación diferente, excepto en un par de provincias. Las cifras del país reaccionaron muy rápidamente al cierre anticipado ya que esto pudo aplanar rápidamente la curva de casos reportados. Días después la Argentina fue clasificada el 7 de abril por la encuesta del Imperial College London (2020a) de 42 casos como un caso estable ( $R_t < 1$ ) y relativamente pequeño (muertes  $< 100$ ). Desde el principio el país mostró un número relativamente bajo de pruebas por millón de habitantes, una diferencia muy notoria con el vecino Chile, que inicialmente mostró una dinámica muy similar en términos de nuevos casos adicionales y de muertes para pasar después a un desempeño mucho peor. Posteriormente, el número de pruebas aumentó y los métodos mejoraron, pero tendían a una estrategia de pruebas prioritarias o focalizadas, que puede ser racionalizada dadas las limitadas capacidades de prueba (Kasy y Teytelboym, 2020). El país se mantuvo muy alejado de la organización de una política agresiva de pruebas y rastreo, aunque algunas estrategias aislacionistas sugeridas utilizando hoteles (por ejemplo, Galiani y Stambulsky, 2020) fueron aplicadas hasta cierto punto. Durante el mes de abril se alcanzó una clara meseta, lo que dio cierto consuelo a las autoridades, pero con una mayor preocupación en el sector empresarial por los efectos de rebote observados en la actividad económica y las consecuencias macroeconómicas y sectoriales percibidas de lo que parecía convertirse en un bloqueo prospectivo muy prolongado, dado que comenzó a principios del otoño. Los casos observados en la meseta de abril fluctuaron en torno a 120 casos diarios observados, mientras que los fallecimientos diarios siguieron siendo en promedio de un solo dígito, con hospitalizaciones críticas a niveles muy bajos en comparación con la capacidad hospitalaria disponible (y en aumento). Esta meseta de abril se vio sacudida en mayo cuando, además de un estallido inicial en los centros de atención de la Ciudad de Buenos Aires que fue controlado, surgieron casos ocultos en uno de los mayores barrios pobres, a raíz de un problema con el suministro de agua. Las pruebas de prioridad hacia esta zona dieron como resultado un asombroso aumento del porcentaje de casos positivos pero con un número relativamente bajo de hospitalizaciones, casos críticos y muertes, lo que puede explicarse por la demografía de los barrios pobres en comparación con el resto de la Ciudad (Panadeiros, 2020). Así, Buenos Aires (pero también la Argentina en menor medida) redujo por completo la tasa de letalidad observada hacia valores inferiores al 3% (en comparación con 5,5% del promedio mundial, 5,1% de Brasil y 1,6% de Chile, lo que demuestra que una tasa de letalidad observada muy baja puede ser compatible con un sistema de salud gra-

vemente estresado si el número absoluto de hospitalizaciones críticas llega a un límite). A partir de este punto, una segunda ola visible comenzó a acumularse progresivamente, con cierto rebalanceo entre vecinos pobres y no pobres que sugiere también quizás un patrón de transmisión, con casos observados multiplicados por un factor de 5 y defunciones por un factor de 3 entre el punto final de la meseta a pesar de la tendencia a la relajación del bloqueo mostrada en indicadores de movilidad en todo el país. Es probable que el riesgo de una próxima etapa de la pandemia se localice en el área del Gran Buenos Aires, como indican nuestros datos -hasta el 10 de junio-. Así, la Ciudad de Buenos Aires y la zona del Gran Buenos Aires llegaron en junio a un punto incómodo en el que, tras un encierro de diez semanas, las autoridades se vieron obligadas a adaptarse a la necesidad y la demanda de relajación del encierro,<sup>1</sup> al tiempo que se enfrentaban a una aceleración de casos totales observados y a un número de reproducción efectiva superior, pero con una baja tasa de mortalidad media y marginal observada. El entorno actual puede representar un equilibrio precario si la respuesta del comportamiento social y económico se mantiene cercana al patrón anterior al cierre.<sup>2</sup>

El documento está organizado de la siguiente manera. En la sección 2 desarrollamos nuestro marco analítico conectando los parámetros de un modelo SIRD con un enfoque de pronóstico. La sección 3 proporciona una simple representación de datos del desempeño de COVID-19 en Argentina como uno con un desempeño inicial comparativamente exitoso pero con una segunda ola de infecciones a medida que la efectividad del bloqueo se va debilitando. La sección 4 brinda nuestro análisis de pronóstico econométrico de casos y defunciones observadas en la Ciudad de Buenos Aires. La sección 5 concluye con la relevancia de nuestro enfoque y resultados para

---

<sup>1</sup> Las pérdidas previstas en términos de producción se han actualizado bruscamente en la Argentina, además de los efectos indirectos fiscales y monetarios que amenazan con debilitar la estabilidad macroeconómica dado las perspectivas económicas heredadas y el escaso margen de maniobra. Así pues, tanto las limitaciones macroeconómicas como los sectores informales ejercen una fuerte presión para que se dé una respuesta de política integral que evite un escenario desorganizado. Los indicadores de evolución de hospitalizaciones, casos críticos y muertes hasta ahora contenidos, en comparación con la capacidad existente, se han utilizado para argumentar a favor de una reducción estratégica de la cuarentena (Urbiztondo, 2020) con un servomecanismo flexible para reaccionar ante posibles sorpresas. Una opinión opuesta se expresa en simulaciones que se basan en efectos dinámicos y en una gran incertidumbre sobre los peores escenarios y la capacidad de reaccionar a tiempo (Castro, 2020). Desde una perspectiva teórica, Barnett y otros (2020) muestran que la incertidumbre sobre la tasa de letalidad predispone a la elección óptima y asimétrica de un responsable político. Tiende a adoptar medidas más estrictas si su historial subestima los riesgos observados, mientras que tiende a una reacción de no cambio si su historial ha sido de sobreestimación de riesgos.

<sup>2</sup> Los estudios de ciencias del comportamiento están detrás del patrón cambiante de comportamiento social frente a COVID-19 (Bavel, et al, 2020; West et al, 2020). El comportamiento económico hacia la participación en el mercado cuando los agentes no internalizan los efectos sobre la salud de los demás es muy relevante para los resultados o la optimización (Eichelbaum, et al, 2020; Chang y Velasco, 2020). Simulaciones sencillas que asumen que las personas aprenden y corrigen el comportamiento muestran diferencias significativas en cuanto a los resultados para Argentina (Sturzenegger, 2020). Las encuestas de actitudes sociales para Argentina (Bozzoli et al, 2020) son preliminares pero sugieren que las preocupaciones económicas pueden afectar la forma en que las personas se comportan.

el diálogo y control de políticas, así como para enriquecer el modelo y las simulaciones con parámetros consistentes con los datos observados.

## 2. Cuestiones de estimación y pronóstico de COVID-19 y el modelo SIR

El modelo de referencia para la modelización de COVID-19 es el modelo SIR,<sup>3</sup> que ampliamos a una versión SIRD para incluir la dinámica de defunciones. Las expresiones (1) a (4) representan el modelo. Comprende un conjunto de cuatro ecuaciones diferenciales en las que un grupo susceptible  $S_t$  dentro de una población de tamaño  $N_t$  está siendo afectado por una enfermedad contagiosa que da lugar a un grupo  $I_t$  de individuos infectados que a medida que la enfermedad progresa conducen a la recuperación de  $R_t$  y a la muerte de  $D_t$  individuos. Por definición  $N_t = S_t + I_t + R_t + D_t$  mientras que  $C = I + R + D$  dice que los casos observados  $C$  son una variable que suma Infectados, Recuperados y Defunciones. Las ecuaciones ilustran las tasas de transición de  $S_t$  a  $I_t$  a  $R_t$  y a  $D_t$ , que se rigen por una tasa de infección  $\alpha$ , una tasa de recuperación  $\beta$  y una tasa de mortalidad  $\gamma$  y su interacción con grupos de susceptibles e infecciosos. Así pues,  $\alpha I/N$  es el número medio de contactos de una persona susceptible con la persona infectada en cada período de tiempo (por ejemplo, días), y  $\alpha$  es el número medio de contactos potencialmente contagiosos de una persona con otra persona, mientras que  $\beta$  es la parte diaria del número total de días que tarda una persona en seguir infectada (a efectos del contagio, i. e. es la inversa del período de infección) hasta que supera la ventana de contagio de la enfermedad y  $\gamma$  es la tasa a la que mueren las personas infectadas en el momento  $t$ , que no debe confundirse con la tasa de letalidad, que es la proporción (media o incremental) de muertes por casos observados.<sup>4</sup>

$$(1) \quad dS_t = -\alpha I_t S_t / N$$

$$(2) \quad dI_t = \alpha I_t S_t / N - \beta I_t - \gamma I_t$$

$$(3) \quad dR_t = \beta I_t$$

$$(4) \quad dD_t = \gamma I_t$$

### *Estimación econométrica*

La mayoría de los trabajos de la literatura reciente toman parámetros ( $\alpha$ ,  $\beta$ ,  $\gamma$ ) de valores (deterministas o estocásticos) para calcular o simular la evolución de las variables a partir de condiciones iniciales dadas. En correspondencia con estos parámetros hay valores asociados de los números de reproducción inicial ( $R_0 = \alpha/\beta$ ) y

<sup>3</sup> Debido a Kermack y McKendrick (1927); Heathcote (2000) es una visión general rigurosa. Véase también Atkeson (2020) y Stock (2020), a los que siguieron muchos trabajos de economía; Harris (2020, Apéndice) y Fernández-Villaverde y Jones (2020) para una representación orientada a la estimación y Yates (2020) para una divulgación abierta.

<sup>4</sup> Esta es una versión SIRD hecha lo más simple posible. Véase Fernández-Villaverde y Jones (2020) para un modelo SIRD general más rico en el que distinguen una etapa "resuelta" entre infecciones y fallecimientos, por lo que éstos no dependen de ello sino de una fracción del grupo resuelto. En el modelo SIR más simple (por ejemplo, Harris, 2020)  $D$  ni siquiera está explícitamente modelado, aunque está subsumido en la definición de  $R_t$  como Retirado de la enfermedad.

efectiva ( $R_t$ ), que dan un parámetro muy referenciado y útil para evaluar la evolución de la enfermedad, más allá de las advertencias sobre el uso y abuso de este indicador (Aronson et al, 2020; Biggerstaff et al, 2014; Delamater et al, 2020). Alternativamente, los parámetros de (1) a (4) pueden estimarse a partir de los datos observados, dada la naturaleza observable de  $C_t (=I_t + R_t)$  y  $D_t$ . Desde una perspectiva econométrica, hay dos maneras de realizar esta estimación. La primera consiste en utilizar métodos de mínimos cuadrados no lineales, como se hace en Batista (2020) y Castle et al (2020), lo que permite prever la evolución del modelo SIR en función de esos parámetros, o bien utilizar esas estimaciones para ajustar los parámetros en los ejercicios de simulación. Una segunda alternativa, como se muestra en Harris (2020), consiste en derivar una forma linealizada del registro de casos diarios  $\Delta C_t$  para estimar (por medio de OLS o una regresión de Poisson) la tasa de infección  $\alpha$  y  $R_0$  (para valores supuestos de  $\beta$ ). Este método es muy útil para medir el inicio de la transmisión de la enfermedad y comprobar el aplanamiento de la curva (representado por la ruptura de la tendencia lineal de  $\log \Delta C_t$ ), que normalmente se producirá como resultado de intervenciones no farmacéuticas (NPI) estrictas, como cierres. Esto requiere un número suficiente de observaciones. Más allá de ese punto, dada la ruptura estructural producida por las NPI, la estimación de  $\alpha$  o de  $R_t$  se ajustará a los datos pero en una etapa diferente a definir. Si se produjera una nueva etapa u ola del proceso contagioso, habrá que realizar una nueva prueba una vez que se disponga de datos suficientes para ajustar los parámetros.

#### *Pronóstico a corto plazo de casos y fallecimientos notificados*

Predecir la evolución de los casos observados  $C_t$  es una de las tareas que atrajo muchos esfuerzos, especialmente al comienzo de la pandemia, para predecir la intensidad de la dinámica de COVID-19. Una vez más, esto puede hacerse de varias maneras diferentes, mediante simulaciones con parámetros supuestos, con un modelo SEIR basado en los fallecimientos observados (como en el informe del Imperial College, 2020) o mediante técnicas de predicción (Castle et al, 2020). El modelo utilizado por el Imperial College considera que las muertes notificadas son la única variable observable precisa y supone una relación estable del 1% con los casos verdaderos (no observados) y un período de 21 días desde la infección hasta la muerte con una ventana de 6,5 días de infecciones. Un fallecimiento en el momento  $t$  está relacionado con una infección contraída 21 días antes y una acumulación de casos (dado un  $R_t$  consistente y un período de tiempo de duplicación) que comienza 15 días ( $t-15, \dots, t$ ) antes y que llevará a otros fallecimientos más adelante ( $t+6, t+7, \dots$ ). Por lo tanto, el comportamiento de la serie temporal de fallecimientos es el principal impulsor del modelo y está inserto en un modelo SEIR, en el que  $E_t$  se presenta como una etapa entre Sospechoso e Infectado y es una adición necesaria para modelar el proceso temporal de la enfermedad y permitir que algunas NPI afecten el proceso infeccioso (véase Castro, 2020 para los modelos de Argentina, y Werning et al 2020 en el contexto de modelos de bloqueo económico óptimo). En el modelo del Imperial College, los pronósticos de fallecimientos (y de casos) provienen de la interacción

entre la  $R_t$  subyacente y la dinámica de los casos anteriores, más que como un modelo de pronóstico de series temporales.

Hasta donde sabemos, no se ha examinado a fondo el funcionamiento relativo de las previsiones de distintos métodos; una excepción es Castle et al, 2020) que han hecho algunas comparaciones de resultados. El horizonte de previsión suele ser corto para los modelos econométricos (semana o quincena), ya que el proceso de datos está sujeto a desplazamientos que pueden requerir una reestimación o actualización, en particular si el modelo econométrico subyacente tiene restricciones especificadas previamente que no se ajustan al Proceso de Generación de Datos (DGP) en algunos casos de países, como la hipótesis de una tendencia descendente para los países que pueden estar muy por delante de un determinado pico de enfermedad (mundial o local) (Liu y otros, 2020). Suelen ser necesarias predicciones a corto plazo para actualizar las decisiones de respuesta política en relación con el grado de NPI. El pronóstico del Imperial College para determinados países tiene una ventana de 28 días. Sin embargo, el pronóstico a corto plazo no informa sobre el proceso general subyacente (duración, pico, convergencia al autocontrol, efectos de un éxito esperado de la vacuna) de la enfermedad, a pesar de ser útil para actualizar esos ejercicios. Los pronósticos a más largo plazo están principalmente asociados a simulaciones que describen un proceso de convergencia en términos de casos y fallecimientos, como debería esperarse de un modelo SIR que tenga asociado un ciclo casi natural sin intervención. Un problema de estas previsiones es la existencia de ciclos en el proceso de enfermedad subyacente, hecho que ha sido bien documentado en pandemias anteriores y que puede seguir siendo una posibilidad plausible en el caso de COVID-19 (Moore et al., 2020). El rendimiento de algunos modelos de pronóstico ha sido criticado abiertamente en los EE.UU. (Wallace-Wells, 2020).

En el presente documento se adopta un enfoque que trata de realizar una estimación econométrica y un pronóstico a corto plazo de casos y fallecimientos observados, de manera que se puedan relacionar con parámetros estructurales del modelo SIRD anterior. Los pronósticos a corto plazo son flexibles para acomodar los efectos de shocks junto con el grado y eficacia variables de las NPI, incluida la respuesta de los agentes. Esto puede dar lugar a incertidumbre en cuanto al tiempo de aparición y la intensidad de un nuevo brote de la enfermedad.

Partiendo de la ecuación (2) y utilizando las definiciones y ecuaciones (3) y (4) anteriores podemos escribir  $dI_t + (\beta + \gamma) I_t = dI_t + dR_t + dD_t = dC_t = \alpha I_t S_t / N$ . Así pues, la tasa de crecimiento de los casos observados se relaciona con el parámetro de la tasa de infección  $\alpha$  como,

$$(5) \Delta \log C_t \cong (dC_t / C_t) = \alpha (I_t / C_t) S_t / N.$$

Un pronóstico a corto plazo (por ejemplo, semanal) de  $\Delta \log C_t$  es coherente con un valor pronosticado de  $\alpha$  dada la relativa estabilidad de los valores calculados de las



relaciones  $I/C$  y  $S/N$  a lo largo del período. También se relaciona con un valor de tiempo de duplicación de casos a futuro (en lugar de a pasado observado), dado por la aproximación por  $\log(2) / \log(1 + \Delta \log C_t)$ , también computado como  $\log(2) / \alpha$  al inicio de la epidemia (por ejemplo, Harris, 2020), dado que  $C_0 \cong I_0$  y asumiendo  $S_0 \cong N$ . También, por extensión, se puede obtener un valor de la tasa de reproducción efectiva pronosticada  $R_t = (\alpha/\beta) (S_t/N)$  a partir de (5) como en la expresión (6), utilizando el pronóstico de  $\Delta \log C_t$  como insumo y usando valores para  $(\beta)$  tomados de estudios epidemiológicos, que tienen una amplia gama de valores y son una fuente de incertidumbre (Moore et al, 2020). Hemos visto trabajos o presentaciones en los que la inversa de  $\beta$  oscila entre 3 días (Castro, 2020, para las simulaciones en Argentina); 6,5 días (Harris, 2020, basado en Ferguson et al, 2020); 10 u 11 días (Wolfel et al, 2020; NCID, 2020) y hasta 18 (o más) días (la mayoría de los trabajos de economía citados anteriormente, basados en Atkeson, 2020, cuya estimación se basa en Wang et al, 2020). Así pues, la estimación de  $R_t$  está sujeta a incertidumbre de los parámetros debido a las estimaciones de  $\alpha$  y  $\beta$ ; <sup>5</sup> utilizar  $\Delta \log C_t$  puede ser mejor que asumir  $\alpha$ .

$$(6) R_t = ((\Delta \log C_t) C_t / I_t) / \beta$$

También se pueden realizar pronósticos a corto plazo de las defunciones notificadas a partir de la evolución de los casos notificados. A partir de la ecuación (4) y utilizando (5) podemos derivar la siguiente relación entre la tasa de crecimiento de defunciones observadas y los casos observados,

$$(7) \Delta \log D_t \cong (dD_t/D_t) = (\gamma/\alpha) (C_t/D_t) (N/S_t) \Delta \log C_t.$$

Una relación como (7) entre  $\Delta \log D_t$  y  $\Delta \log C_t$  no tiene rezagos como cabría esperar de la evolución entre casos y fallecimientos simplemente porque esto se supone por escrito en la ecuación (4) anterior que no tiene valores retardados de  $I_t$ , ni tampoco efectos no lineales de  $I_t$  sobre  $D_t$  para captar los probables problemas de congestión en el sistema de salud (por ejemplo, Álvarez et al, 2020) que han sido bien documentados en los dramáticos inicios de Italia y España.

[...]

---

<sup>5</sup> En un intercambio sobre la confiabilidad de los parámetros estimados (que corresponden a estimaciones econométricas o epidemiológicas) para estimar  $R_0$ , Rodolfo Manuelli nos sugirió que podría haber en principio, con fines de simulación, una forma (no tradicional) de estimar  $R_0$  que evite el uso de esos parámetros y se base en la observación de personas infectadas ( $I_t$ ) y susceptibles ( $S_t$ ) a partir de información serológica, que hallamos que también podría aplicarse a la estimación de  $R_t$ . Esto se deriva de la ecuación (1) y (2), formando un cociente y utilizando la definición de  $R_0$ , normalizando (o no)  $N = 1$ , ya que esto puede ser más manejable.

## 5. Resumen de los resultados y observaciones finales

La incertidumbre que rodea la extensión, aparición e intensidad de las ondas de la pandemia COVID-19 tiene consecuencias para la forma en que evaluamos la situación actual de un país determinado y, aunque esta incertidumbre afecta a todos los países de manera diferente según su propia trayectoria y posición en la transmisión mundial de la enfermedad, parece estar presente en todos los casos. Esto no sorprendería a los epidemiólogos que han utilizado referencias históricas sobre las pautas probables que pueden surgir, y donde las segundas olas han estado presentes tanto en la llamada pandemia de "gripe española" de 1914-18 como en casos menos conocidos como la pandemia de 1957-58 (Moore et al, 2020; véase también Jefferson y Heneghan, 2020). Estas segundas olas no están necesariamente relacionadas con las estaciones (de invierno) y pueden verse a través de los países y dentro de los mismos. Las ondas no parecen generarse ex ante como ciclos de un modelo epidemiológico más rico, sino que parecen estar relacionadas con diferentes shocks de la pandemia. Tal vez esto parezca así porque ese tipo de modelos analíticos aún no han sido comprendidos y acordados, o tal vez las olas tengan hoy una importancia secundaria (no así en el pasado) porque el proceso de innovación y la vacuna deben ser la principal preocupación, ya que actúan sobre las actuales NPI que conforman la dinámica de la enfermedad.

Sostenemos que el pronóstico a corto plazo de casos y fallecimientos puede resultar más útil de lo que se pensaba debido a las olas de infección y puede hacerse de manera complementaria a un modelo epidemiológico que se ha convertido ahora en estándar de investigación que sirve de orientación política incluso cuando la posición final de la pandemia no se pueda pronosticar con exactitud. Mostramos que la predicción a corto plazo de la tasa de crecimiento de casos y fallecimientos de COVID-19 puede hacerse de manera que se relacione con parámetros clave del SIR y sus variantes. Creemos que esto es útil tanto para la evaluación de políticas como para el diálogo relativo a medidas como la flexibilización o el endurecimiento de las NPI y para ayudar a los modelos calibrados y a su simulación para utilizar parámetros que mejor se ajusten a los datos reales. En la medida que lo permitan conjuntos de datos más ricos, el enfoque puede acomodar heterogeneidad entre áreas y grupos, movilidad e interacciones espaciales, y el desempeño del sistema sanitario.

Aplicamos nuestra estimación y pronósticos de la tasa de crecimiento de casos y fallecimientos a los datos de la Ciudad de Buenos Aires (CABA) que tiene un arranque inicial a principios de marzo seguido de un cierre el 20 de marzo que mitigó y redujo el proceso de contagio y luego fue seguido por una segunda ola en mayo inicialmente asociada a barrios populares y luego se fue generalizando hasta mediados de junio que es cuando termina nuestra muestra. Los datos revelan que los casos fuera de CABA y en el área metropolitana perteneciente a la Provincia de Buenos Aires se están convirtiendo ahora en el principal foco de la dinámica de la enfermedad, pero no estudiamos ese proceso ya que el caso de CABA es suficiente para ilustrar nuestro

enfoque de modelización. Utilizamos técnicas de saturación en un modelo de selección automática de series temporales para elegir diferentes pasos en la tasa de crecimiento de los casos y las muertes en estos subperíodos con previsiones semanales y reestimación del modelo una vez que se detectan cambios en los datos. Nuestros resultados para la tasa de crecimiento diario de los casos observados muestran una tasa de alrededor del 4% (por debajo del pico del 20% al comienzo de la pandemia) después de la introducción del cierre en el 20 de marzo que se mantiene muy estable durante todo el mes de abril, con pronósticos que no requieren reestimación. Luego nuestras proyecciones detectan un salto de la tasa de crecimiento en mayo 6 que lleva a una duplicación de la tasa de crecimiento al 8% pero que resulta ser transitoria y asociada con casos en barrios populares y una tercera fase en la que el modelo y la proyección se estabilizan en torno al 4,5%. Esta tasa es consistente con una tasa de tiempo de duplicación de 16 días, un coeficiente de tasa de contagio  $\alpha = 0,07$  y una tasa de reproducción  $R_t$  claramente inferior a uno suponiendo valores de  $\beta-1$  por debajo de 14 días. Por otra parte, una tasa de crecimiento estable de defunciones, que se encuentra en torno al 70% de la de casos, es decir, 3%, aunque sea inferior a la implícita en el Imperial College (2020b) para Argentina, puede resultar menos confortable ya que implica pasar de unas 30 muertes por día a mediados de junio a 84 a mediados de julio y a 236 a mediados de agosto, siendo esta última bastante problemática para la gestión actual de las Unidades de Cuidados Intensivos (UCI), incluso sin tener en cuenta los efectos indirectos de un aumento similar en la Provincia de Buenos Aires. También hallamos pruebas de que los casos observados tienen un efecto sobre la mortalidad después de 16 a 19 días, lo que resulta algo menor que los 21 días considerados en los pronósticos del Imperial College (2020b).

Por lo tanto, cabría preguntarse, ¿cuál es el problema con la estrategia argentina? De hecho, nuestro enfoque muestra que hay uno, que se desarrolló como consecuencia del visiblemente temprano pero aún parcial éxito en la contención de la pandemia. La aceleración transitoria y la tasa de crecimiento sostenido de los casos observados después de la introducción de un cierre de 12 semanas es, creemos, una característica clave o un hecho estilizado del caso argentino representado por los datos de la CABA. En Ahumada et al (2020), al estimar una reducción del 75% de la tasa de contagio de un modelo SIR de 0,23, como se muestra en la información anterior al cierre, registramos un mensaje inconsistente en el anuncio de un pico estimado de la pandemia en junio, ya que esto dejaba abierto el interrogante sobre la evolución de estos casos en las semanas siguientes, ya que el cierre perdería su efectividad inicial. Una tasa de crecimiento estable de casos, defunciones de un solo dígito, una tasa de letalidad en descenso del 5% a menos del 3% (ya que los esfuerzos de prueba y los nuevos casos en jóvenes habitantes fuera de peligro de los barrios pobres hicieron que disminuyera la proporción de defunciones con respecto a casos) y una amplia capacidad de camas de UCI en hospitales podrían conducir a una estrategia "satisfactoria". A su vez, los resultados recientes muestran lo problemático que puede llegar a ser esto a medida que la presión social y económica para que se suavice el bloqueo vaya aumentando a lo largo de las semanas, con una respuesta de política que se adapte lo más posible a estas demandas (que se reproducen en muchos otros

países). En lugar de una reducción monótona de la tasa de crecimiento de casos y defunciones, como debería predecirse mediante un proceso de convergencia descrito en una curva de tipo Gompertz, tasas estables, aunque muestren tasas de pandemia no aceleradas, pueden elevar los casos diarios absolutos, las hospitalizaciones y las defunciones. Todo esto puede resultar muy costoso en términos de capacidad del sistema sanitario en el corto y mediano plazo, como lo demuestra la experiencia chilena.

A medida que las tasas de crecimiento sostenido elevaron las cifras absolutas diarias observadas y esperadas a valores cada vez menos confortables, una instancia de diálogo de política referente a la estrategia hacia la relajación del bloqueo ha ocupado el centro del escenario en el momento de escribir esta versión. Nuestros resultados contribuyen a este debate de política al mostrar que la disminución de eficacia del bloqueo, según un indicador de movilidad, ha tenido un importante impacto sobre la tasa de crecimiento de casos. Por lo tanto, el país se enfrenta a un tradeoff entre salud y resultados económicos/sociales. Un aumento (relajación) del actual nivel de movilidad (encierro) en alrededor del 40% en la Ciudad de Buenos Aires a, digamos, el 60% implicaría un aumento en la tasa de crecimiento de casos de alrededor del 3,5% (del 4,5% al 8%) lo que se traduce en un aumento en la tasa de crecimiento de fallecimientos de cerca del 2,5% (del 3% al 5,5%), generando un escenario altamente estresante. Por otra parte, una reducción de la movilidad a un nivel del 25% que representa el nivel observado a fines de marzo después del anuncio del cierre implicaría una reducción de las tasas de crecimiento de casos y muertes hacia un 2,5% y un 1,8% respectivamente, lo que sería más coherente con el control de la evolución de la pandemia, pero vendría con una segunda ola de contracción económica. El país necesita superar esta difícil elección porque ni siquiera está claro que se pueda aplicar un camino de regreso a marzo y el retorno a una actividad económica limitada puede desencadenar decisiones (participativas) de amplio margen por parte de las empresas, en particular en el sector de servicios, con graves efectos en los niveles de empleo. Para ello parece necesario aplicar rápidamente una nueva estrategia más agresiva de rastreo y aislamiento.

## Referencias

- Ahumada H, S. Espina-Mairal and F. Navajas (2020), “Modelos y pronósticos de la dinámica del COVID-19: Mirando la Argentina”, mimeo, FIEL, Abril 10.
- Alon T., M. Kim, D. Lagakos and M. Vuren (2020), “How Should Policy Responses to the COVID-19 Pandemic Differ in the Developing World?”, Working Paper 27273, National Bureau of Economic Research, May.
- Álvarez F., D. Argente, and F. Lippi, (2020) “A Simple Planning Problem for COVID-19 Lockdown,” Working Paper 26981, National Bureau of Economic Research, April.
- Aronson J., J. Brassey and K. Mahtani (2020), “When will it be over?": An introduction to viral reproduction numbers,  $R_0$  and  $R_e$ ”, Centre for Evidence-Based Medicine, Oxford University.
- Atkeson, A. (2020) “What Will Be the Economic Impact of COVID-19 in the US? Rough Estimates of Disease Scenarios,” Working Paper 26867, National Bureau of Economic Research, March.
- Batista, M. (2020). “Estimation of the final size of the coronavirus epidemic by the SIR model”, *MedRxiv*, Feb.28, <https://doi.org/10.1101/2020.02.16.20023606>.
- Barnett M., G. Buchak and C. Yannelis (2020), “Epidemic responses under uncertainty”, Working Paper 26867, National Bureau of Economic Research, May.
- Baum, C. and M. Henry, “Socioeconomic Factors influencing the Spatial Spread of COVID-19 in the United States”, May 29, <https://ssrn.com/abstract=3614877>
- Bavel et al (2020), “Using social and behavioural science to support COVID-19 pandemic response”, *Nature Human Behavior*, April 30, <https://www.nature.com/articles/s41562-020-0884-z>
- Biggerstaff, M., Cauchemez, S., Reed, C. et al. (2014) “Estimates of the reproduction number for seasonal, pandemic, and zoonotic influenza: a systematic review of the literature”. *BMC Infectious Diseases* 14, 480 <https://doi.org/10.1186/1471-2334-14-480>
- Bozzoli G, M. Grandes et al (2020), “Índice de propensión al riesgo en salud IPRIS”, Fundación Bunge y Born, Buenos Aires, Junio.
- Charpentier A., R. Elie, M. Laurière and V. Tran (2020), “COVID-19 pandemic control: balancing detection policy and lockdown intervention under ICU sustainability”, *MedRxiv*, May 22 <https://doi.org/10.1101/2020.05.13.20100842>

- Christen P., K. Hauck et al (2020), "Strengthening hospital capacity for the COVID-19 pandemic: JIDEA pandemic hospital planner", Report 15, MRC Centre for Global Infectious Disease Analysis, Imperial College London.
- Castle, J. L., Clements, M. P., & Hendry, D. F. (2015), "Robust approaches to forecasting", *International Journal of Forecasting*, 31(1), 99-112.
- Castle J., J. Doornik and D. Hendry (2020), "Short-term forecasting of the Coronavirus Pandemic 2020-07-27", University of Oxford, UK, April 27.
- Castro R. et al (2020), "Simulación de escenarios basados en modelos matemáticos para Covid19 en Argentina", Coloquio del Departamento de Matemática, FCEyN, UBA. Mayo de 2020.
- Chang R. and A. Velasco (2020), "Economic Policy Incentives to Preserve Lives and Livelihoods", DP14614, Center for Economic Policy Research, April.
- Delamater P. E. Street et al (2019), "Complexity of the Basic Reproduction Number (Ro)", *Emerging Infectious Diseases*, 25, 1, January, <https://doi.org/10.3201/eid2501.171901>
- Doornik, J. A. (2009), "Autometrics". In J. L. Castle & N. Shephard (eds.), *The Methodology and Practice of Econometrics: A Festschrift in Honour of David F. Hendry*. Oxford: Oxford University Press.
- Eichenbaum M., S. Rebelo, and M. Trabandt (2020), "The Macroeconomics of Epidemics," Working Paper 26882, National Bureau of Economic Research, March.
- Ferguson N et al (2020), "Impact of non-pharmaceutical interventions (NPIs) to reduce COVID19 mortality and healthcare demand", Imperial College, March 16. <https://spiral.imperial.ac.uk:8443/handle/10044/1/77482>
- Fernández-Villaverde, J. and C. Jones (2020), "Estimating and Simulating a SIRD Model of COVID-19 for Many Countries, States, and Cities," Working Paper 27128, NBER, May.
- Galiani S. and I. Stambulsky (2020), "La industria hotelera podría ser la puerta para salir de la cuarentena sin que se disparen los contagios", *Infobae*, <https://www.infobae.com/opinion/2020/05/10/la-industria-hotelera-podria-ser-la-puerta-parasalir-de-la-cuarentena-sin-que-se-disparen-los-contagios/>
- Garriga, C., R. Manuelli and S. Sanghi (2020), "Optimal Management of an Epidemic: Lockdown, Vaccine and Value of Life", April 27, latest version: [https://sidsanghi.github.io/website/OptimalManagement\\_COVID\\_GMS.pdf](https://sidsanghi.github.io/website/OptimalManagement_COVID_GMS.pdf)

- Garfield M., S. Ridley et al (2001), “Seasonal variation in admission rates to intensive care units”, *Anaesthesia*, 56, pp. 1136-40.
- González-Eiras, M. and D. Niepelt, “On the Optimal "Lockdown" During an Epidemic”, CEPR Discussion Paper No. DP14612. April. Available at SSRN: <https://ssrn.com/abstract=3594242>
- Harris J. (2020), “The Coronavirus Epidemic Curve is Already Flattening in New York City”, MIT, March 30, NBER Working Paper 26917.
- Hendry, D. F. (1999). “An Econometric Analysis of US Food Expenditure, 1931-1989”, Chapter 17, in Magnus, JR and Morgon, MS (eds.), *Methodology and Tacit Knowledge: Two Experiments in Econometrics*, Wiley & Sons.
- Hendry, D. F. (2000), “On detectable and non-detectable structural change”, *Structural change and economic dynamics*, 11(1-2), 45-65.
- Hendry D. (2020), “A Short History of Macro-econometric Modelling”, Nuffield College Oxford, January 20, [https://www.nuffield.ox.ac.uk/economics/Papers/2020/2020W01\\_MacroHist18.pdf](https://www.nuffield.ox.ac.uk/economics/Papers/2020/2020W01_MacroHist18.pdf)
- Hendry, D. F., and J. A. Doornik. *Empirical model discovery and theory evaluation: automatic selection methods in econometrics*, MIT Press, 2014.
- Hethcote H. (2000), “The Mathematics of Infectious Diseases”, *SIAM Review*, 42, 4, pp. 599-653.
- Hsiang, S., Allen, D., Annan-Phan, S. et al. (2020), “The effect of large-scale anti-contagion policies on the COVID-19 pandemic”, *Nature*, <https://doi.org/10.1038/s41586-020-2404-8>
- IHME (2020), “Forecasting the impact of the first wave of the COVID-19 2 pandemic on hospital demand and deaths for the USA and 3 European Economic Area countries”, *MedRxiv*, doi: <https://doi.org/10.1101/2020.04.21.20074732>
- Imperial College London (2020a), “Short-term forecasts of COVID-19 deaths in multiple countries”, MRC Centre for Global Infectious Disease <https://mrc-ide.github.io/covid19-short-termforecasts/index.html>.
- Imperial College (2020b), “Situation Report for COVID-19: Argentina, 2020-06-09”, downloadable from <https://mrc-ide.github.io/covid19-short-term-forecasts/index.html>.
- Jefferson T. and A. Heneghan (2020), “COVID-19 Epidemic ‘Waves’”, Centre for Evidence-Based Medicine, University of Oxford, April 30, <https://www.cebm.net/covid-19/covid-19-epidemicwaves/>

- Kasy M. and A. Teytelboym (2020), “Adaptive Targeted Infectious Disease Testing”, May 12, *Oxford Review of Economic Policy*, <https://doi.org/10.1093/oxrep/graa018>
- Kermack, W.O., and A.G. McKendrick. (1927, 1991). "A contribution to the mathematical theory of epidemics - I." *Bulletin of Mathematical Biology* (Reprinted) 53 (1-2):33-55.
- Lee Y., B. Lei and B. Mallick (2020), “Estimation of COVID-19 spread curves integrating global data and borrowing information”, *MedRxiv*, May 19 <https://doi.org/10.1101/2020.04.23.20077065>
- Martínez E., D. Aragon and A. Nunes (2020), “Short-term forecasting of daily COVID-19 cases in Brazil by using the Holt’s model”, *Journal of the Brazilian Society of Tropical Medicine*, Vol.:53, doi: 10.1590/0037-8682-0283-2020, May 20.
- Moore K., M. Lipsitch, J. Barry and M. Osterholm (2020), The Future of the COVID-19 Pandemic: Lessons Learned from Pandemic Influenza, Part 1, The CIDRAP viewpoint, Center for Infectious Disease Research and Policy, University of Minnesota.
- NCID (2020),”Period of Infectivity to Inform Strategies for De-isolation for COVID-19 Patients”, Academy of Medicine, Singapore, May 23. [https://www.ams.edu.sg/viewpdf.aspx?file=media%5c5556\\_fi\\_331.pdf&ofile=Period+of+Infectivity+Position+Statement+\(final\)+23-5-20+\(logos\).pdf](https://www.ams.edu.sg/viewpdf.aspx?file=media%5c5556_fi_331.pdf&ofile=Period+of+Infectivity+Position+Statement+(final)+23-5-20+(logos).pdf)
- Okell LC, R Verity, O Watson et al. (2020) “Have deaths from COVID-19 in Europe plateaued due to herd immunity?”. *The Lancet*; June 11. [http://dx.doi.org/10.1016/S0140-6736\(20\)31357-X](http://dx.doi.org/10.1016/S0140-6736(20)31357-X).
- Panadeiros M. (2020), “Coronavirus en CABA ¿No tan mal como parece?”, mimeo, Seminario FIEL, Mayo 24.
- Pereira I. et al (2020),”Forecasting Covid-19 dynamics in Brazil: a data driven approach”, *MedRxiv* doi: <https://doi.org/10.1101/2020.05.11.20098392>. May 18.
- Sáez M, A. Tobias, D. Varga and M.A. Barcelo (2020),”Effectiveness of the measures to flatten the epidemic curve of COVID-19. The case of Spain”, *Science of The Total Environment*, 727, <https://doi.org/10.1016/j.scitotenv.2020.138761> April
- Sánchez-Villegas P, Codina AD, (2020) “Modelos predictivos de la epidemia de COVID-19 en España con curvas de Gompertz”, *Gaceta Sanitaria* <https://doi.org/10.1016/j.gaceta.2020.05.005>



- Stock James H. (2020), “Data Gaps and the Policy Response to the Novel Coronavirus,” Working Paper 26902, National Bureau of Economic Research March.
- Sturzenegger F. (2020), “COVID-19: vidas vs economía, reflexiones y estimaciones”, Academia Nacional de Ciencias Económicas, Junio 5.
- Urbiztondo S. (2020),” Covid-19: Una actualización de la evolución de la pandemia en Argentina, y de los sensores para la flexibilización del aislamiento social”, *Indicadores de Coyuntura*, FIEL, Junio.
- Utsunomiya YT, Utsunomiya ATH, et al (2020), “Growth Rate and Acceleration Analysis of the COVID19 Pandemic Reveals the Effect of Public Health Measures in Real Time”. *Frontiers in Medicine*, 7:247. Doi: 10.3389/fmed.2020.00247
- Yates C. (2020), “How to model a pandemic”, *The Conversation*, March 25.
- Wallace-Wells (2020), “What the Coronavirus Models Can’t See”, *New York Magazine*, May 2.
- West R., S. Michie, J. Rubin and R. Amlot (2020), “Applying principles of behaviour change to reduce SARS-CoV-2 transmission”, *Nature Human Behavior*, May 6, <https://www.nature.com/articles/s41562-020-0887-9>
- Wölfel, R., V.M. Corman, W. Guggemos et al. (2020), “Virological assessment of hospitalized cases of coronavirus disease 2019”, *MedRxiv*, <https://doi.org/10.1101/2020.03.05.20030502>, March 8.