



Coronavirus: desde las ecuaciones de un desastre a una matemática de la esperanza

Todos los niños de occidente creen que, si cavan un túnel a través de la tierra, llegarán a China. Por supuesto, esto es falso en una gran mayoría de países, pero, si comenzamos a cavar en Santiago, el túnel se abrirá, después de más de doce mil kilómetros y después de atravesar el núcleo incandescente de nuestro planeta, a unos 700 kilómetros de una localidad China llamada Wuhan.

En diciembre del año pasado, los médicos de Wuhan reportaron una seguidilla de casos de neumonía atípica. El culpable, una entidad diminuta bautizada COVID-19, logró abrirse paso hasta Chile en menos de tres meses, no a través de nuestro túnel hipotético, sino que, siguiendo el camino largo, zigzagueando por la superficie y dejando una estela de contagio en casi todos los países del mundo.

Al día de hoy¹, se ha reportado más de un millón de casos de COVID-19 a nivel global – y, trágicamente, alrededor de setenta mil muertes. ¿Cómo puede una enfermedad propagarse desde unos pocos individuos en una ciudad de China hasta convertirse en una pandemia que no conoce fronteras? Y más aún: ¿en tan solo unas pocas semanas?

El término acuñado por la prensa y las autoridades para nombrar esta propagación salvaje es **crecimiento exponencial**. Este término, integrante infaltable del vocabulario matemático de todo científico, adquirió un sema de pesadilla. El crecimiento exponencial es lo que podríamos llamar la ecuación de un desastre. Afortunadamente, este no es el final de la historia. Hemos visto que las medidas adecuadas pueden frenar el contagio y, utilizando otro término que se popularizó en estos días, **aplanar la curva**. Y así como el crecimiento exponencial se puede vencer en la práctica, existen modelos matemáticos capaces de establecer un panorama más adecuado de la realidad.

Los modelos matemáticos permiten predecir la evolución de la enfermedad a partir de los datos disponibles. Alimentado con los datos correctos, un modelo adecuado puede reflejar los efectos de medidas de contención como distanciamiento social e incluso cuarentenas. En este sentido, los modelos matemáticos aportan sólidos cimientos sobre los cuales edificar las políticas de manejo de la pandemia.

En este ensayo, estudiaremos las predicciones dramáticas del modelo exponencial y resaltaremos sus limitaciones. Luego, discutiremos el modelo SIR que permite explicar el fenómeno de aplanamiento de la curva. Finalmente, estudiaremos una versión simplificada del modelo Covid19GeoModeller desarrollado en Chile y que permite diseñar medidas de

¹ Los datos utilizados en este ensayo están actualizados al 06 de abril 2020.



contención muy precisas. El uso de fórmulas y otros artilugios matemáticos se redujo todo lo posible – espero que este análisis sea accesible a personas más distanciadas de nuestro oficio.

Antes de empezar, quisiera enfatizar ciertas consideraciones con respecto al alcance de lo que aquí se establecerá y así guiar la lectura de este ensayo. La web abunda en artículos sobre esta pandemia orientados al ‘público general’. Cuando ‘público general’ se refiere a un ‘público muy general’, me pareció que los aspectos matemáticos no están suficientemente desarrollados a pesar de poder ser expuestos de manera elemental. Cuando el ‘público general’ se asume versado en argumentos cuantitativos, este análisis tiende a volverse más técnico y, por lo mismo, escueto en explicaciones. Este ensayo pretende situarse en la mitad de estas dos tendencias – de ahí su extensión. Advierto al lector que no soy experto en las matemáticas de la epidemiología y, por lo tanto, algunas de las explicaciones que siguen deben ser tomadas con cautela. Sin embargo, confío en que la médula de las ideas expuesta es cualitativamente correcta.

Iniciemos, entonces, nuestro paseo desde las ecuaciones de un desastre hasta la matemática de la esperanza.

Crecimiento exponencial: las ecuaciones de un desastre

A comienzos de la pandemia, era muy común escuchar la afirmación ‘La cantidad de contagiados se duplica cada 3,5 días’². Esta era más o menos la tendencia a mediados de marzo, cuando el número de contagiados crecía diariamente del orden de 24%. También era la tendencia a nivel mundial – fuera de China – a fines de febrero e inicios de marzo. Duplicar parece una operación inocente: pasar de 2 a 4, o de 3 a 6. Pero ¿qué pasa si duplicamos números grandes? Entre el 21 y el 25 de marzo, el número de contagiados en Chile pasó de 537 a 1142. 1142 es un número un poco mayor que el doble de 537 y marcó un hito: habíamos superado la barrera psicológica de los 1000 contagiados.

Según este mecanismo, para obtener una aproximación de la cantidad de contagiados tras una semana, basta multiplicar el número inicial por 4. Para dos semanas, por 16. Siguiendo de este modo, para obtener la cifra de contagiados al cabo de un mes, tendríamos que multiplicar el número inicial por 256 y así pasaríamos, por ejemplo, de 5 contagiados a 1280 en ese período de tiempo. En este esquema, el número de contagiados tras cierta cantidad de intervalos de tiempo de largo 3,5 días, es igual al número inicial multiplicado por una potencia de dos. La gráfica de este crecimiento es dramática. La Figura 1 (izquierda) muestra la evolución de la pandemia en España durante el primer mes³. Vemos que el número de contagiados pasa rápidamente de algunos miles a más de 50 mil. La curva de Chile (derecha) es ciertamente menos dramática. Aún así, pasa de algunos cientos a alrededor de 2000 en una decena de días. Afortunadamente, tanto

² En adelante, el número de contagiados se refiere a las cifras entregadas por el ministerio de salud, esto es, de casos confirmados. El número de casos reales, incluyendo infectados asintomáticos, es desconocido.

³ Para España, el día 1 corresponde al 03 de febrero, mientras que, para Chile, corresponde al 03 de marzo.



en Chile como en España, esta tendencia dio rápidamente paso a un crecimiento menor. Analizaremos este fenómeno más abajo.




Figura 1: Chile y España durante la fase de crecimiento exponencial.

Como ya señalamos, a mediados de marzo, el número de contagiados crecía diariamente del orden de 24%. En este contexto, el número de contagiados en un día dado es igual al número de contagiados presentes el día anterior más el 24% de ese mismo número, es decir, su 124 por ciento. Esto se puede escribir mediante una fórmula muy sencilla: si denotamos por $I(n)$ e $I(n + 1)$ el número de infectados en los días n y $n + 1$ respectivamente, entonces

$$I(n + 1) = I(n) + k \times I(n),$$

donde k se conoce como la tasa de crecimiento – en nuestro caso, $k = 0,24$. Esto se conoce como un **modelo exponencial**. En la Figura 2, se contraponen los datos reales (en rojo) con la proyección usando la fórmula anterior. Vemos que el día 35, correspondiente al 6 de abril, la cantidad real de contagiados es algo menor que 5.000 mientras que la proyección del modelo exponencial es del orden de 13.000. Extrapolando, el modelo exponencial predice más de 45.000 contagiados tras 41 días e incluso cerca un millón y medio dos semanas y media después. Afortunadamente, algo detuvo el crecimiento exponencial o, al menos, disminuyó su tasa de crecimiento.

Las barras azules de la Figura 2 muestran la proyección de un modelo exponencial con una tasa de 12%, crecimiento más representativo de la situación a fines de marzo. Esta vez, la proyección al día 41 es un poco mayor a 10.000 casos. Esta cifra es considerablemente menor que la anterior pero aún es dramática y, como todo parece indicar, igualmente errada. Lo que tenemos que recordar de estas cifras es que, en un modelo exponencial, las cantidades proyectadas disminuyen drásticamente al disminuir la tasa de crecimiento.

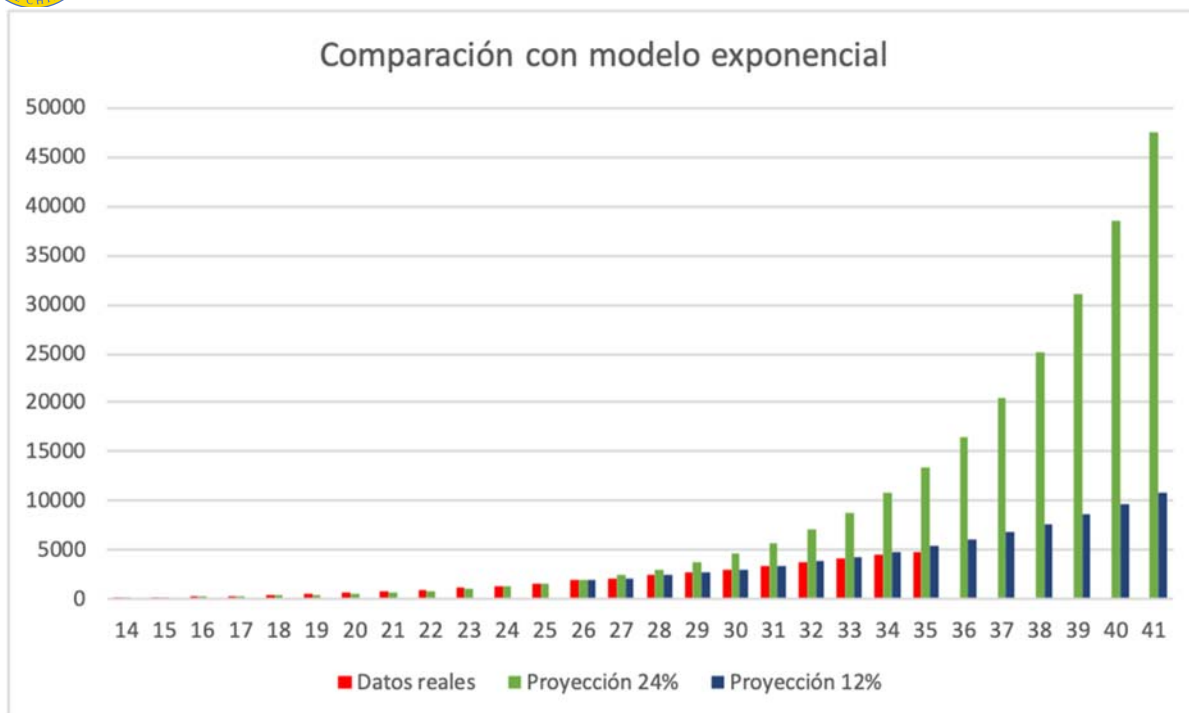


Figura 2: Comparación de datos reales con el modelo exponencial.

Para entender lo que ocurrió entre mediados y fines de marzo, conviene investigar el significado del número k . Cada persona infectada se relaciona con una cierta cantidad de individuos que denotaremos por m y que depende de la persona en particular. En cada contacto, hay una probabilidad p de transmitir la enfermedad, es decir, se espera que una persona contagiada contagie a su vez $p \times m$ personas. Este valor es el k propio de cada persona. La evidencia muestra que p es un número pequeño – menor que 1 – pero, si el número m es grande, entonces $k = p \times m$ puede ser grande. El valor $k = 0,24$ que utilizamos más arriba se puede interpretar como el promedio de los valores de k propios de cada contagiado a mediados de marzo. Los datos muestran que, a partir del 27 de marzo, el valor de k bajó apreciablemente. ¿Qué podría haber causado este fenómeno? La explicación más sencilla es que el distanciamiento social que hemos establecido disminuyó efectivamente el número m de personas con las cuales nos relacionamos en promedio. El efecto es una disminución de la tasa de crecimiento del modelo exponencial – o, si se prefiere, de la tasa de contagio – y, por lo tanto, nuestro modelo tiene que ser adaptado. Notemos que los esfuerzos de distanciamiento social fueron anteriores al 27 de marzo, pero sus efectos demoraron algunos días en observarse en los datos.

Si bien el decrecimiento de la tasa es una buena noticia, pone de manifiesto una debilidad de nuestro modelo. El modelo exponencial no nos permite formular predicciones acertadas si la tasa de crecimiento varía en el tiempo. Ya vimos la forma de la curva exponencial: abierta hacia arriba



y cada vez más empinada. Ahora, miremos la curva de España hasta el día de hoy (Figura 3, izquierda). Alrededor del día 33, la curva comienza a torcerse y pareciera convertirse poco a poco en la mitad de una campana. Esto ya no es la gráfica de un crecimiento exponencial. La curva chilena (Figura 3, derecha) exhibe la misma tendencia, aunque de manera menos marcada. Tras el día 25, la pendiente deja de crecer. Dentro de los próximos días, sabremos si nuestra curva sigue el destino de la curva española – sumado a nuestras cifras significativamente menores, esto sería una excelente noticia.

Podemos sacar dos conclusiones de la discusión anterior. Primero, el modelo exponencial es útil para modelar los inicios de una pandemia y, segundo, necesitamos un modelo capaz de adaptar la tasa de crecimiento a medida que pasa el tiempo. El modelo exponencial anuncia un crecimiento mucho mayor de lo que vemos en la práctica y esto es, en definitiva, una fuerte advertencia: ante la ausencia de medidas de contención, imperará el crecimiento exponencial y, en cosa de semanas, el número de contagiados será del orden de varios millones. Afortunadamente, las medidas de distanciamiento social frenaron esta tendencia.

Terminamos nuestra discusión del modelo exponencial con unas palabras de cautela que podrán resultar reconfortantes. En los últimos días, las cifras de nuevos contagiados parecen muy grandes con respecto a lo que solían ser hace unas semanas. ¿Cómo reconciliar este hecho con la afirmación de que la tasa de crecimiento ha bajado? Si baja la tasa de crecimiento, baja la proporción de casos nuevos. Sin embargo, el número de casos nuevos se calcula como una proporción del número de casos actuales que es muchísimo más grande que el número de casos que había hace unas semanas. Esta es una característica del crecimiento exponencial: los números crecen rápidamente, y una pequeña proporción de un número muy grande, puede ser muy grande.




Figura 3: Curva chilena y curva española hasta el 06 de abril 2020.



El modelo SIR: una boa que se tragó un elefante y el aplanamiento de la curva

El crecimiento exponencial no dura para siempre. Si pensamos en enfermedades estacionales, se suele observar un aumento paulatino de casos y, luego, un **peak** durante unas semanas tras el cual el número de enfermos baja apreciablemente. En este caso, la curva que representa el número de contagiados tiene forma de campana o, si se prefiere, de una boa que se tragó un elefante (se pueden encontrar tres de estas curvas en la Figura 4). Para entender este fenómeno, es necesario recurrir a un modelo más preciso conocido como SIR que describiré a continuación. El modelo SIR es capaz de predecir la fecha y magnitud de este peak a partir del número actual de contagiados y de la misma tasa de crecimiento que incluimos en el modelo exponencial. En seguida, esta información puede utilizarse para estimar la capacidad hospitalaria necesaria durante la peor época de la pandemia. Tal como el modelo exponencial, el SIR describe la evolución de una pandemia en ausencia de medidas adicionales durante su desarrollo y, otra vez, predice cifras dramáticas que deben ser tomadas como una advertencia.

Ya observamos que el modelo exponencial es incapaz de adaptar su tasa de crecimiento de forma automática para reflejar los datos observados. En general, el modelo exponencial entrega estimaciones demasiado grandes y la razón es bastante sencilla: este modelo no considera pacientes recuperados o fallecidos. Una vez que un individuo se contagia, lo considera contagiado para siempre. De este modo, se sobreestima la cantidad de individuos contagiosos. De la misma manera, al no considerar sujetos recuperados e inmunizados⁴, el modelo exponencial sobreestima la cantidad de individuos susceptibles de ser contagiados. Para solucionar este problema, volvamos a nuestra discusión del parámetro k . Convenimos que $k = p \times m$, donde m es la cantidad promedio de contactos de una persona infectada y p es la probabilidad de contagio tras cada contacto. En base a esto, decretamos que la cantidad de nuevos contagios está dada por $k \times I(n)$, donde recordamos que $I(n)$ representa la cantidad de infectados presentes el día n . Pero, si el contacto se produce con una persona ya infectada o inmunizada, la probabilidad de contagio es igual a 0. Por lo tanto, solo una proporción de contactos tiene la posibilidad de convertirse en contagios. Esta proporción corresponde a la proporción de individuo susceptibles de ser contagiados. Así, si denotamos esta cantidad por $S(n)$ y por H el tamaño de la población, el número de casos nuevos en el día $n + 1$ estará dado por

$$k \frac{S(n)}{H} I(n).$$

En las primeras etapas del contagio, la proporción $S(n)/H$ es cercana a 1 dado que la mayor parte de los individuos es aún susceptible. De este modo, este modelo presenta inicialmente crecimiento exponencial. A medida que evoluciona el contagio, una proporción cada vez mayor de individuos está, o bien en la categoría de infectados o de **removidos** – es decir, inmunizados tras haber padecido la enfermedad o fallecidos. De este modo, la proporción $S(n)/H$ que multiplica a k en la fórmula de más arriba disminuye, lo que resulta en una ‘tasa de crecimiento efectiva’ menor que k . Esta disminución paulatina de la tasa permite al modelo escapar del

⁴ Dejamos de lado la discusión respecto de la inmunidad adquirida – o no – tras la recuperación.



crecimiento exponencial y, posteriormente, describir el peak de contagios. Faltaría entonces modelar el número $R(n)$ de removidos en el día n , es decir, de individuos que ya no participan en el proceso de contagio⁵. Hoy en día, se acepta ampliamente el hecho de que una persona infectada demora dos semanas en recuperarse. Por lo tanto, es razonable considerar que el número de nuevos removidos $R(n)$ coincide con el número de nuevos casos del día $n - 14$. Finalmente, $S(n) = H - I(n) - R(n)$.

Esta es una versión simplificada del modelo Susceptible-Infectado-Removidos conocido por sus iniciales SIR⁶. Este modelo emula la transmisión de una enfermedad que le confiere inmunidad a los pacientes recuperados. Originalmente, el modelo SIR se formula como un sistema de ecuaciones diferenciales y se asume cierta tasa de recuperación en lugar de nuestra regla aproximada⁷. La ventaja del SIR simplificado es que se puede implementar fácilmente en una hoja de cálculo y permite formular predicciones que son cualitativamente correctas. En la Figura 4, se muestran las proyecciones del modelo correspondientes a valores de k iguales a 12%, 11% y 10%. A medida que baja este valor, ocurren dos cosas. Primero, la posición del **peak** – la cúspide de la curva o cantidad máxima de individuos infectados – se desplaza hacia la derecha y, segundo, la altura de este peak es cada vez menor. Es decir, el peor momento de la pandemia se retrasa y sus efectos son menores. Esto es lo que se ha llamado **aplanar la curva**.

Las cifras mostradas en la Figura 4 son, otra vez, muy distantes de lo observado en otros países y mucho mayores de lo esperado en el caso de Chile. Rescataremos, sin embargo, el aspecto cualitativo de estos gráficos: una pequeña baja en la tasa de crecimiento – que se logra, por ejemplo, con distanciamiento social – puede tener un efecto dramático en la evolución de la pandemia. Acá, al pasar de 12% a 10%, se redujo la altura del peak a menos de la mitad y se retrasó su ocurrencia. Otra vez, si bien las cifras gigantescas arrojadas por el modelo se alejan del comportamiento observado dentro y fuera del país, deben ser tomadas como una advertencia: ante la ausencia de medidas, estas son las cifras que podríamos obtener dentro de unas semanas. Notemos, sin embargo, que el cambio en la forma de la curva española de la Figura 3 no debe interpretarse como la inflexión propia de una curva de tipo SIR. Como vemos en la Figura 4, el peak previsto por el modelo SIR demora varios meses en manifestarse y es significativamente más alto. Este freno al crecimiento exponencial es reflejo de la cuarentena. Lo mismo es válido para la curva chilena: su pendiente ha dejado de crecer con el ímpetu de hace algunas semanas, pero esto no significa que llegamos al peak previsto por el modelo SIR – y que lo peor quedó atrás. Otra vez, la disminución de la tasa de crecimiento es efecto de las medidas de contención y, en el mejor de los casos, esta tendencia a la baja podría acentuarse durante los próximos días. Si, por el contrario, la tasa actual se mantiene, una evolución de tipo SIR iniciada con las

⁵ También dejamos de lado el fenómeno de ‘inmunidad de manada’ – herd immunity.

⁶ Para una introducción a SIR, véase <https://images.math.cnrs.fr/Modelamiento-de-una-epidemia.html?lang=fr>

⁷ El planteamiento y discusión del modelo SIR simplificado se puede encontrar en el reciente artículo: Pastén, H., Castillo, J., “Evolución de las epidemias: la matemática de aislarse”, <http://www.mat.uc.cl/~hector.pasten/preprints/Epidemia2020.pdf>



condiciones actuales desembocaría en números catastróficos y será necesario fortalecer las medidas⁸ para evitar ese escenario.

La altura del peak debe compararse con la capacidad hospitalaria. Se sabe que cierto porcentaje de infectados requiere de cuidados intensivos e incluso de ventiladores mecánicos⁹. La cantidad de ventiladores mecánicos disponibles será, según las estimaciones más optimistas, del orden de 2000. El cálculo es sencillo. Si el peak es demasiado elevado, morirá gente por falta de equipamiento médico. La meta es, por lo tanto, aplanar la curva lo más posible y todo parece indicar que caminamos en la dirección correcta.

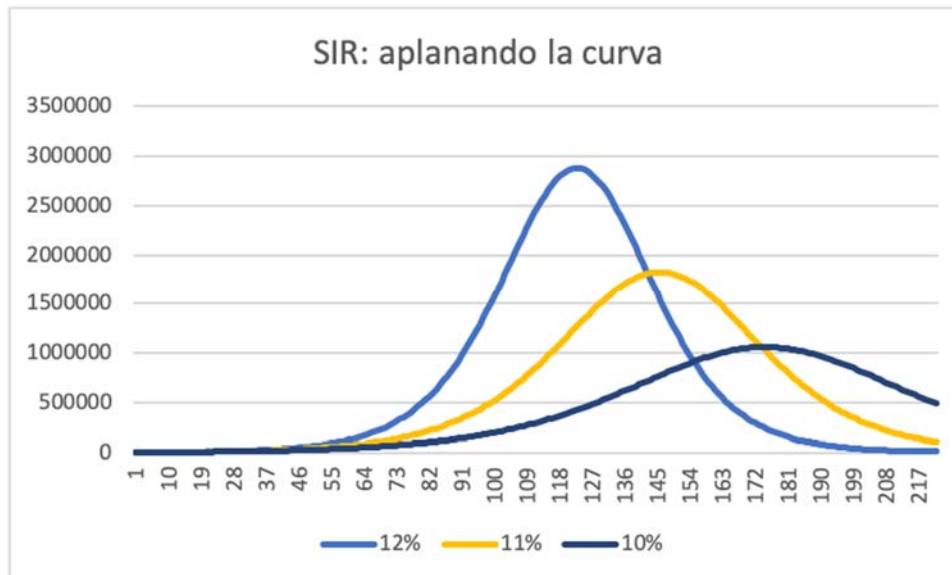


Figura 4: Aplanando la curva.

El modelo SIR coincide cualitativamente con lo que se espera de una enfermedad contagiosa como COVID19 y muestra claramente los efectos de una baja en la tasa de crecimiento sobre la intensidad del peak o número máximo de individuos infectados a lo largo del tiempo. Basta disminuir el valor del parámetro k para observar este aplanamiento de la curva – aunque los números proyectados siguen siendo dramáticos. Sin embargo, el modelo es poco flexible a la hora de intentar entender los efectos de ciertas medidas más complejas como, por ejemplo, una cuarentena parcial. Estas medidas pueden ser modeladas y justificadas por sólidos modelos matemáticos, al incorporar una componente fundamental a nuestro análisis: la geografía.

⁸ Una mirada a los datos entre el 5 y el 10 de abril – fecha posterior a la redacción de este ensayo – sugiere de hecho una tasa de crecimiento sostenida de 8%.

⁹ Alrededor de 2,3%: Guan WJ, Ni ZY, Hu Y, Liang WH, Ou CQ, He JX, et al. (February 2020). "Clinical Characteristics of Coronavirus Disease 2019 in China". *The New England Journal of Medicine*. Massachusetts Medical Society. doi:[10.1056/nejmoa2002032](https://doi.org/10.1056/nejmoa2002032). PMID 32109013



Un modelo espacial: cuarentena y matemática de la esperanza

Comenzamos con dos observaciones geográficas: primero, la pandemia no afectó de igual manera a todas las comunas del país y, segundo, su evolución espacial dista de ser sencilla. Esto se ve reflejado en el hecho de que algunas comunas insospechadas comenzaron repentinamente a aumentar sus cifras de contagiados. Por supuesto, la primera característica de esta pandemia es que no se mantiene localizada – ya lo dijimos, llegó a nuestro país desde las antípodas en tan solo algunas semanas. Lo mismo ocurre dentro de Chile: un foco de contagio en una comuna puede nutrir el número de contagiados en un lugar más o menos distante, a través de las intrincadas redes de relaciones laborales o el itinerario desafortunado de un turista imprudente.

La solución planteada por las autoridades fue limitar la circulación por ciertas zonas del país. Algunas comunas fueron aisladas por un período de varias semanas – y algunas se mantienen en aislamiento. Esta solución es bastante sensata y, de hecho, abundan las voces que reclaman una ampliación de esta cuarentena. Un efecto curioso es que aislar una zona no solo protege el resto del país del contagio, sino que puede incluso beneficiar la zona acordonada. Ya discutiremos este fenómeno.

La componente geográfica fue incorporada exitosamente por un equipo del Centro Interdisciplinario de Neurociencia de Valparaíso y de la Fundación Ciencia y Vida, en un modelo que se dio a conocer como Covid19GeoModeller¹⁰. Los detalles del modelo aún no han sido divulgados pero su estructura básica fue brevemente expuesta por Tomás Pérez-Acle en su cuenta de Twitter¹¹. Basado en esta información algo escueta, intentaré presentar una versión simplificada que ojalá reúna sus características principales¹².

La observación fundamental que motiva el modelo es que una persona tiene una probabilidad distinta de contagiarse, dependiendo de los lugares por donde transite. Si acude a una comuna donde la proporción de contagiados es mayor, tiene mayores chances de contagiarse. En la práctica, podemos suponer que una cierta proporción de habitantes de una comuna A se desplaza diariamente hacia la comuna B – llamaremos este número el flujo de A a B –, lugar donde tiene cierta probabilidad de contagiarse, y así con cada comuna de destino – incluida la propia comuna A. Las probabilidades de contagio dependen a su vez de la proporción de infectados en cada destino. Estos valores, debidamente ponderados por los flujos, constituyen una tasa de contagio efectiva para un habitante promedio de la comuna A. Simular una cuarentena total o parcial equivale a modificar el valor de los flujos. Por ejemplo, acordonar la

¹⁰ Para una introducción a los modelos que incorporan información geográfica: van den Driessche, P. (2008) “Spatial Structures: patch models” en Brauer, F., van den Driessche, P., Wu, J. (Eds.) “Mathematical Epidemiology”, Lecture Notes in Mathematics 1945, Springer

¹¹ <https://twitter.com/TomasPerezAcle/status/1242711421332459520>

¹² Para ser completamente honesto, el Covid19GeoModeller es una extensión del modelo SEIR donde la letra E adicional se refiere a ‘Expuestos’. No discutiremos esta diferencia.



comuna B tiene el efecto de disminuir drásticamente el flujo de A a B y el flujo de B a A. Ya veremos algunos números en una simplificación del modelo más abajo.

Los flujos incorporados al Covid19GeoModeller fueron calculados en base a información entregada por el Ministerio de Transporte, mientras que los distintos parámetros del modelo – como tasa de crecimiento y de recuperación – fueron calibrados con datos reales. El modelo fue luego aplicado para predecir el número de contagiados sin cuarentena, con cuarentena total y cuarentena parcial¹³. En cálculos efectuados alrededor del 24 de marzo, el equipo estimó que, sin cuarentena, el número de contagiados el 9 de abril sería del orden de 28.000 en la región metropolitana. También conjeturaron que un bloqueo importante podría reducir este número a alrededor de 4000 contagiados – una cifra que se acerca mucho más a la realidad que estamos observando. Este modelo no solo entrega números globales, sino que predice el crecimiento del número de contagiados en cada comuna. Esta información puede luego contraponerse con la capacidad hospitalaria de cada zona para planificar una adecuada repartición de los recursos médicos.

Para ilustrar el funcionamiento del modelo, supondremos que nuestro universo consta de las tres comunas A, B y C que tienen, respectivamente, una población de 600.000, 600.000 y 130.000 habitantes¹⁴. Inicialmente, hay 65 contagiados en A, 420 en B y 30 en C. Asumimos que una alta proporción de habitante de A se desplaza diariamente hacia B, una proporción apreciable se mantiene dentro de A y una pequeña proporción se desplaza hacia C. Por el contrario, una alta proporción de habitantes de B se mantiene dentro de B y solo pequeñas proporciones se desplazan hacia A y C. La comuna C tiene un alto flujo hacia B, un pequeño flujo hacia A y un pequeño flujo interno. La Figura 5 muestra la evolución de este universo ante la ausencia de medidas de contención. Lo primero que observamos es que las curvas correspondientes a las comunas A y B son muy similares – las diferencias tempranas entre ambas curvas se grafican a la derecha. Si bien la comuna A tenía inicialmente una baja proporción de contagiados, el alto contacto con la comuna B empeoró rápidamente sus cifras. Se puede ver que, durante el peak, el número de contagiados de las comunas A y B fue muy similar y del orden de 90.000.



¹³ <https://www.youtube.com/watch?v=cdIldMnsRTO>

¹⁴ El lector podrá reconocer una caricatura de algunas comunas o conglomerados de comunas de la región metropolitana.



Figura 5: (izquierda) evolución de las tres comunas, (derecha) evolución inicial de las comunas A y B.

Ahora, la Figura 6 muestra la evolución de la pandemia al acordonar la comuna B, es decir, reduciendo drásticamente los flujos desde B y hacia B. El efecto es claro. La gran cantidad de contagiados de B ya no estimula el crecimiento del número de infectados de A y este número no supera los 4000. Por otro lado, el peak de contagios de C bajó desde cerca de 20.000 a alrededor de 1000. Lo sorprendente es que la cantidad máxima de contagiados dentro de B también disminuyó considerablemente. Para explicar este hecho, notemos que los habitantes de A contagiados en B participan del contagio dentro de A al volver a esta comuna. Este efecto es suprimido al disminuir el flujo de A a B.



Figura 6: evolución de las tres comunas aislando la comuna B.

Este modelo es, por supuesto, una caricatura. Los números deben ser considerados de forma cualitativa solamente – de hecho, las escalas de tiempo se omitieron en las gráficas. Lo sorprendente es que este modelo sencillo se acerca un poco más a la situación esperada y observada en otros países, simplemente al incorporar una noción de geografía. Lo más rescatable de esta simulación ingenua, es el drástico aplanamiento de la curva al aislar la comuna con el mayor número de contagiados – nótese que ni siquiera se simuló una cuarentena total dentro de B. El Covid19GeoModeller, por otro lado, es un modelo realista, robusto y debidamente calibrado y, si es utilizado en forma correcta, constituye una herramienta de análisis poderosa para apoyar la toma de decisiones. Este modelo permite `jugar con los parámetros' – en especial, controlar los flujos en función del tiempo – y diseñar de este modo soluciones efectivas y lo menos invasivas que se pueda.



Epílogo: alcance de los modelos matemáticos

Un modelo matemático es una caricatura de la realidad escrita en lenguaje matemático. Un buen modelo extrae las características esenciales de un problema y permite, a partir de los datos disponibles y a través de cálculos mecánicos encargados a una computadora, establecer predicciones que sustenten nuestras decisiones.

¿Es inválido el modelo exponencial? No. El modelo exponencial es adecuado para aproximar los inicios de una pandemia cuando la mayoría de la población es aún susceptible y antes de implementar medidas de contención. Cuando estos efectos comienzan a ser relevantes, es necesario recurrir a un modelo más elaborado. Así, el modelo SIR extiende el modelo exponencial al representar la cantidad de infectados con más cuidado y el modelo Covid19GeoModeller extiende el SIR al agregar consideraciones geográficas. Los modelos son aproximaciones de la realidad y, como toda aproximación, tienen un rango de validez. El desafío de la modelización consiste en utilizar el modelo correcto en el contexto correcto y saber interpretar las predicciones acertadamente.

Hemos tocado un punto fundamental: los modelos requieren datos de calidad para ser calibrados. Se ha levantado constantemente la preocupación por obtener datos fiables en un plazo razonable. Al prestar oído a los actores relevantes de la escena médica, pareciera que la falta de transparencia con los datos resultó perjudicial para un entendimiento temprano de la situación. Por otro lado, no está demás recordar que el mundo académico cuenta con expertos en datos de todo tipo y en todo rango de complejidad: los estadísticos. Un equipo poderoso en el estudio de una pandemia – y probablemente de cualquier situación en la que el análisis de datos resulta fundamental – debe incluir estadísticos profesionales. Los epidemiólogos están, por supuesto, entrenados en el manejo de datos propios de las epidemias, pero un estadístico aportará una intuición invaluable y un conocimiento actualizado de la disciplina. En este contexto, el equipo perfecto de análisis de datos epidemiológico nacería de una simbiosis entre estadísticos y epidemiólogos.

Similarmente, un adecuado uso de los modelos no se puede lograr sin la colaboración de los expertos en modelos matemáticos: los matemáticos. Por supuesto, es imposible diseñar un modelo adecuado sin la ayuda de un experto en el problema que se estudie – epidemiólogos en este caso. El epidemiólogo tiene la intuición de los aspectos medulares del problema que tienen que ser incluidos. Pero es tarea de los matemáticos escribir el modelo, asegurar que incorpora todos los efectos deseados, velar por su adecuada implementación y aplicación dentro de su rango de validez. Como matemático, no puedo más que lamentar que sea necesaria una crisis para recordarnos la importancia de los modelos matemáticos y de las matemáticas en general. La historia muestra que, en períodos de crisis, los países desarrollados siempre han recurrido a



sus matemáticos, pero no podemos olvidar que las matemáticas siguen omnipresentes en épocas de tranquilidad.

La matemática siempre ha sido nuestra aliada, pero debe usarse con cuidado. Las estrategias óptimas a nivel técnico podrían resultar en un desastre. Si bien los modelos nos orientan respecto de las medidas a adoptar, no podemos olvidar que diseñar e implementar estas medidas tiene una componente humana inherente y, así como los modelos necesitan de matemáticos y estadísticos para los aspectos técnicos, una adecuada intervención requiere de expertos en materia social: sociólogos, psicólogos, trabajadores sociales, comunicadores y otros. Por cierto, esta reunión de expertos de diversos ámbitos no es particular al manejo de una catástrofe. Así como los científicos reivindicamos el rol protagónico que debiera tener la ciencia en la toma de decisiones, no podemos minimizar los aspectos humanos que estas involucran. En definitiva, una solución cabal y humanista solo puede nacer de un equipo interdisciplinario.