



## **Trabajo final de graduación**

# **“Un modelo epidemiológico para explicar el contagio de comportamientos prosociales durante la guerra de Ucrania-Rusia”**

**Universidad de San Andrés**

**Departamento de Economía**

**Licenciatura en Economía**

Autor: Juan Pablo Pironi Delcarlo

Legajo: 30182

Mentora: Silvia Lassalle

Buenos Aires, 27 de febrero de 2023

## **Resumen:**

Este trabajo realiza un análisis observacional sobre las fluctuaciones en los comportamientos prosociales ante el repentino aumento de las donaciones monetarias en respuesta a la invasión rusa de Ucrania en febrero de 2022. Para ello, bajo el marco teórico de las normas sociales y su proliferación, proponemos un modelo dinámico con el objetivo de entender bajo qué condiciones los comportamientos prosociales fluctúan en el largo plazo y se difunden a lo largo de la población. Probamos que, se puede representar con un modelo epidemiológico simple, en cierta medida, el incremento considerable en las donaciones, tanto en cantidad, como en monto, a partir del contagio social en masa, el cual sostenemos que se produce por el incremento generalizado del flujo de información sobre la guerra de Ucrania-Rusia.



Universidad de  
**San Andrés**

## Índice

|   |           |
|---|-----------|
| 1. Introducción                                 | Página 3  |
| 2. Estadística descriptiva                      | Página 7  |
| 3. Modelo teórico                               |           |
| 3.1 Presentación del modelo epidemiológico      | Página 12 |
| 3.2 Descripción del modelo SIS - PDP            | Página 14 |
| 3.3 Equilibrio del modelo                       | Página 15 |
| 4. Caso práctico: Donaciones                    |           |
| 4.1 Parámetros y condiciones iniciales          | Página 17 |
| 4.2 Resultados                                  | Página 19 |
| 4.2.1 Modelo base: Parámetros constantes        | Página 19 |
| 4.3.2 Robustez del modelo: Cambio de parámetros | Página 23 |
| 4.3.3 Caso hipotético                           | Página 27 |
| 5. Conclusión                                   | Página 31 |
| 6. Anexo  | Página 33 |
| 7. Bibliografía                                 | Página 36 |

## **1. Introducción**

La invasión rusa sobre Ucrania que comenzó el 24 de febrero de 2022 ha sido un registro histórico, no sólo por los trágicos acontecimientos, sino también por el gran involucramiento a nivel mundial por parte de la ciudadanía, tanto en términos de opinión pública, como a través de donaciones monetarias con el fin de ayudar a las áreas afectadas. El acontecimiento indujo a millones de personas a contribuir por medio de donaciones a la causa ucraniana. Tales incrementos súbitos en las donaciones de dinero, son reflejo de la proliferación de comportamientos prosociales en masa, o manada, como consecuencia de la alta difusión global a través de los diferentes medios de comunicación sociales y mediáticos sobre el suceso.

Hechos bélicos, como el estudiado en este trabajo, entre otras catástrofes socio-económicas, como pandemias, desastres climáticos, etc., más allá de las desafortunadas consecuencias que traen consigo, también son una oportunidad para la generación de nuevos donantes en las respectivas causas. Por tal motivo, estos eventos suelen ser estudiados en profundidad para comprender los mecanismos que estimulan los comportamientos prosociales a nivel colectivo. Pues bien, contribuyen así a las organizaciones de fondos de caridad, quienes utilizan tales investigaciones para entender cómo y en qué contextos es posible mantener y/o aumentar la cantidad de donantes y el monto total de sus contribuciones (es decir, entender cómo ampliar la curva de demanda de donaciones). En específico, para estas fundaciones es particularmente relevante entender el comportamiento de los donantes, ya que los donativos provenientes del ciudadano promedio representan, según el informe sobre la sostenibilidad financiera de las Organizaciones de la Sociedad Civil de América Latina (Rodríguez et al., 2021), el 31.5% de los ingresos totales de las fundaciones de caridad promedio, siendo su principal ingreso en comparación con fondos provenientes de empresas, agrupaciones de contribuyentes, etc.

Ahora bien, existen diversas teorías en torno al surgimiento de los comportamientos prosociales (e.g., kin selection; Hamilton, 1964; reciprocal altruism; Trivers, 1971), recién estos últimos años surge una nueva teoría que propone que el modelo, el ejemplo, tiene un rol fundamental en la formación, desarrollo y fluctuación de los comportamientos prosociales en la sociedad, la teoría coevolutiva de la cultura y los genes (Boyd, Richerson & Henrich, 2011; Chudek & Henrich, 2011; Richerson & Boyd, 2008). Esta teoría propone que la prosocialidad humana se explica a partir del aprendizaje cultural y social. Entendiendo así al aprendizaje cultural como todas aquellas conductas sociales que

aceptamos, imitamos y/o nos adaptamos. Concretamente, en el caso del aprendizaje de las conductas prosociales, bajo esta teoría, los humanos se comportan de forma benevolente dado que observan que los demás también se comportan de dicha manera.

En principio, dichas enseñanzas culturales forman, con el paso del tiempo, normas sociales, las cuales se desarrollan producto de la interacción social. Estas normas varían entre sociedades y son específicamente importantes cuando se trata de comportamientos prosociales, ya que reconcilian la tensión entre lo que es bienestar personal (un bien para mí) y bienestar social (un bien para los demás). En concreto, existen evidencias de estudios de campo y experimentales (Henrich et al., 2001, 2006) que comprueban que ciertas sociedades tienden a comportarse de forma más prosocial que otras; se cree que es producto de las instituciones y normas sociales propias de cada sociedad. En suma, existen diferentes normas que pueden evocar comportamientos más deseables (o indeseables) en una determinada sociedad.

En este campo de estudio, principalmente, se dedican a comprender, por un lado, cómo es posible cambiar tales normas y, por otro lado, qué mecanismos entran en juego en su determinación. En primer lugar, referente a los cambios en las normas sociales y su relación con los comportamientos prosociales, en los trabajos de McEvily et al. (2006) y Bicchieri & Xiao (2009), especialistas en la materia, demuestran que, cambiando ciertas normas sociales, es posible cambiar las preferencias sociales (esto es, por ejemplo, cuán altruistas o egoístas decidimos ser ante los demás) y, también, las expectativas sociales (es decir, lo que pensamos o creemos acerca del comportamiento de los demás). En concreto, a partir de varios experimentos, los investigadores demuestran que, estableciendo como norma social el hecho de comportarse prosocialmente, las personas tienden a actuar de forma más prosocial. Sin embargo, en la realidad, por fuera de los experimentos controlados, cambiar estas normas para modificar cierto comportamiento en una sociedad (como es el caso de donar) es de gran dificultad. Para lo cual, Bicchieri (2016), en su libro sobre cómo cambiar las normas sociales, nos explica cuáles son los factores que deben surgir para que se reemplace una norma social por otra, destacando así que “las personas deben enfrentar un problema de acción colectiva [definido], deben tener razones compartidas para cambiar [de comportamiento], sus expectativas sociales deben cambiar colectivamente y sus acciones deben coordinarse.” (p. 111). Dicho esto, en nuestro caso de estudio (las donaciones a la causa ucraniana), observamos que se cumplen tales condiciones para, así, contemplar un posible surgimiento de un cambio normativo en la sociedad. En suma, el problema colectivo está presente, se comparten las razones para ayudar a la causa, las expectativas sociales

cambiaron drásticamente y las acciones caritativas se coordinan. Y, además, tal coordinación social se potencia gracias a los reportes públicos de la fundación ucraniana, garantizando a los donantes que el resto también está comprometido con la causa.

Por otro lado, debemos entender más en profundidad por medio de qué mecanismos varían las normas y qué impacto tienen sobre los comportamientos prosociales. En general, las normas sociales se determinan, primero, por lo que las personas observan que otros hacen y dicen (normas descriptivas) y, segundo, por lo que las personas piensan que deberían hacer (normas normativas, relacionadas con las expectativas sociales; qué se espera como comportamiento adecuado). Por lo cual, la información social que recibimos sobre lo que los demás hacen, o creemos que hacen, es fundamental para determinar el impacto que tienen sobre nuestra conducta. Asimismo, se suele relacionar la literatura de normas sociales con la de los efectos de pares, dado que surge la misma dinámica de contagio social de comportamientos; es decir, al presentarse cierta información sobre lo que los demás hacen, el individuo puede imitar u adaptarse a tal comportamiento (por ejemplo, si observo que mi grupo de referencia suele colaborar, entonces también colaboro), o bien desviarse de tal accionar (por el contrario, si observo que en mi grupo de referencia nadie se ayuda, entonces, yo sí ayudo). Dentro de ambas literaturas, existe una extensa y variada evidencia experimental, en la cual se mide el impacto que tiene observar comportamientos prosociales de otros sobre la conducta posterior de un observador. En un trabajo reciente (Jung et al., 2020), proponen un meta-análisis que engloba una gran diversidad de artículos (88 estudios) sobre el efecto de las normas sociales en estos comportamientos, sintetiza el tamaño del efecto, dado por la diferencia de promedios entre los grupos de tratamiento (modelo prosocial) y los grupos de control. Esta diferencia, medida por el parámetro  $g$ , queda estimada con valor  $g = 0.45$ , en un intervalo de confianza  $IC = [0.36, 0.54]$ , con un nivel de confianza de 95% y un  $p$ -valor de  $p < .001$ . Exceptuando por sesgos de publicación (quitando estudios atípicos), arrojan un tamaño de efecto estimado de  $g = 0.37$ ,  $IC = [0.29, 0.45]$  con 95% de confianza y  $p < .001$ . Es decir, por el hecho de observar a otro comportarse de forma prosocial, aumentan las chances promedio de contagio en la conducta un 37%.

No obstante, cabe aclarar, que los efectos de las normas sociales a veces pueden generar el efecto contrario al deseado. En el caso de las donaciones, el hecho de proveer información que confirme que otras personas están donando puede generar la percepción en el individuo de que su donación ya no es necesaria. En otras palabras, el atractivo de donar decrece con cada donativo observado, como si el impacto de la donación se redujese (Teunenbroek et al, 2020). A pesar de ello, diversos estudios

experimentales siguen afirmando que el contagio social es un mecanismo fundamental para sostener y reproducir en el tiempo los comportamientos prosociales. Saeri et al. (2022), a través de un meta-meta-análisis (análisis de otros meta-análisis) de estudios experimentales y de campo sobre el impacto de diferentes intervenciones para el aumento de las donaciones, encuentran que la replicabilidad de estos comportamientos (por medio del contagio social) es de las intervenciones con mayor impacto para aumentar las donaciones. Para lo cual, el contagio social puede ser un mecanismo que resuelve, en parte, el "problema de acción colectiva", que modifica la norma social, llevando así a no donantes, a donar, y a ya donantes, a donar más.

Seguidamente, así como en los estudios experimentales varían de forma controlada las normas sociales, también existen estudios observacionales que aprovechan shocks que afectan a la sociedad en su conjunto para intentar representar teóricamente las normas sociales y sus fluctuaciones. Dicho en otras palabras, se dedican a estudiar cómo la interacción social puede generar que ciertos comportamientos se propaguen en una población y se estandaricen en el tiempo. Estos estudios dinámicos utilizan catástrofes climáticas u emergencias sociales para ver cómo cambian a lo largo del tiempo las acciones caritativas. En el caso de Schweitzer y Mach (2008) y Korolov et al. (2016), utilizan los tsunamis por su alta difusión mundial y su conocida repercusión en los llamados a la caridad. En el primer trabajo citado, analizan una serie de tiempo que contiene cantidad y monto de donaciones, antes y después del tsunami. Encuentran que aumenta exponencialmente las donaciones, en ambos aspectos, durante 3 semanas pasado el acontecimiento. Prueban que es posible describir las fluctuaciones dinámicas de las donaciones en estos contextos con modelos simples como un modelo epidemiológico extendido SIR (susceptible-infectado-recuperado). En el segundo trabajo, (Korolov et al., 2016), estudian cómo el aumento a la exposición de información sobre el desastre climático, a través de redes sociales, aumenta significativamente las donaciones. Encuentran que existe una relación casi cuadrática entre el intercambio de información vía twitter y tomar acción sobre donaciones a la caridad en tiempos y escenarios de emergencia. Mientras que se da una relación casi lineal en contextos normales.

El objetivo central de este trabajo, similar al propuesto en los últimos artículos citados sobre los análisis observacionales, se basa en estudiar cómo es el comportamiento dinámico de las donaciones posterior al estallido del ataque bélico en Ucrania. Para tal fin, proponemos un modelo dinámico con el objetivo de entender bajo qué condiciones los comportamientos prosociales fluctúan en el largo plazo y se difunden a lo largo de la población. De esta forma, podremos dilucidar intuiciones sobre

el rol de las normas sociales en la difusión de estos comportamientos. Probaremos la hipótesis de cómo un shock exógeno común a un gran porcentaje de la población puede generar un aumento de las donaciones, tanto en cantidad, como en monto, a través del contagio social en masa, el cual sostenemos que se produce por el aumento generalizado del flujo de información. Por último, vale aclarar que ambos conjuntos de literaturas citados, tanto los trabajos experimentales que intentan vislumbrar el impacto de las normas sociales sobre los comportamientos prosociales, como los estudios observacionales del comportamiento de los donantes, nos servirán como evidencia para sostener nuestra hipótesis, la fundamentación del modelo dinámico que utilizaremos y la definición de sus parámetros.

Para tal fin, en primer lugar, realizamos una estadística descriptiva para tener mayor noción de los datos con los que trabajaremos y elaborar ciertas intuiciones generales sobre las donaciones. En segundo lugar, proponemos y explicamos el modelo teórico y, posteriormente, hallamos sus equilibrios. En tercer lugar, establecemos las condiciones iniciales del modelo y sus parámetros para, luego, realizar la comparación entre el modelo y los datos. Por último, presentamos las conclusiones del trabajo.

## 2. Estadística descriptiva

En principio, contamos con 9770 datos de donaciones monetarias diarias por un monto total de 13384807.20 dólares estadounidenses en el período comprendido entre el 1 de febrero de 2022 y el 8 de noviembre de 2022, provenientes de la fundación más importante y con mayor trayectoria de Ucrania (fundada en 2014), *Come Back Alive*, destinada a prestar apoyo a las Fuerzas Armadas de Ucrania a través del suministro de tecnología, formación y munición para salvar vidas y defender Ucrania<sup>1</sup>. De todas las donaciones que recibe la fundación, por transferencias bancarias y envíos internacionales, nosotros contamos exclusivamente con donaciones en criptomonedas, porque son datos públicos, mientras que los anteriores son privados de la entidad.

De todas formas, vale aclarar que el hecho de que sean criptomonedas no saca validez a nuestras conclusiones, ya que estos nuevos medios de pago son ampliamente utilizados por los donantes y son

---

<sup>1</sup> Come Back Alive, s.f.; <https://www.comebackalive.in.ua/es/home>



los principales fondos de caridad internacionales. Además, se estima que las donaciones anuales en criptomonedas aumentaron exponencialmente de \$ 4.2 millones (dólares americanos) en 2020 a \$ 69.6 millones en 2021, de los cuales un 42% de las donaciones se realizaron bajo la criptomoneda Ether (ETH) y un 36% de las donaciones en la criptomoneda Bitcoin (BTC) (The Nonprofit Times, 2022). A saber, ambas criptomonedas mencionadas son monedas digitales basadas en la tecnología de contabilidad distribuida de *blockchain*. Siendo Ether (ETH) la moneda nativa de la *blockchain* de Ethereum y Bitcoin (BTC) la moneda utilizada en la *blockchain* de Bitcoin.

Habiendo dicho eso, los datos de donaciones fueron recopilados por medio de las páginas de seguimiento de las transacciones de cada criptomoneda, por un lado, las transferencias en Bitcoin por medio de la página “BTC.com”<sup>2</sup> y, por otro lado, las transacciones en Ether desde la página de “Etherscan”<sup>3</sup>. Cabe aclarar que realizamos la conversión a dólares americanos de las donaciones monetarias utilizando el precio histórico de las respectivas criptomonedas a partir de *Yahoo Finance* a una frecuencia diaria, utilizando el precio de cierre.

En primer lugar, para tener una mayor noción de la representatividad de nuestra muestra, realizamos una pequeña comparación general entre las donaciones totales recibidas por la fundación ucraniana y las donaciones recibidas en criptomonedas por la misma entidad. Para tal fin, consultamos el reporte de fondos de la fundación<sup>4</sup>, el cual está disponible en su página web. Vale aclarar, para que los datos sean comparables hacemos la conversión a dólares americanos utilizando el tipo de cambio fijo de la moneda ucraniana, grivna (UAH), entre el 1 de febrero de 2022 y el 21 de julio de 2022 (primer período, antes de la devaluación) y entre el 22 de julio de 2022 hasta el 8 de noviembre de 2022 (segundo período, después de la devaluación), obtenemos la Tabla 1. En resumen, la fundación recibió durante el período analizado una suma total de 1321916 donaciones por un monto total de USD 164795555.97, de los cuales un 8.7% corresponde a criptomonedas siendo estos de USD 14305493.93, incluyendo únicamente las monedas Bitcoin y Ether. Además, la fundación reporta el monto promedio de donación, el cual, durante el primer período (preajuste), fue de USD 159.62 y

---

<sup>2</sup> BTC, s.f.; <https://explorer.btc.com/btc/address/bc1qkd5az2ml7dk5j5h672yhxmhmx9tuf97j39fm6>

<sup>3</sup> Etherscan, s.f.; <https://etherscan.io/address/0xa1b1bb8070Df2450810b8eB2425D543cfCeF79b>

<sup>4</sup> Save Life, reporte de fondos, s.f.; <https://savelife.in.ua/en/reporting-en/>

USD 1516.48 en criptomonedas y, durante el segundo período (posajuste), de USD 61.94 y USD 365.24 en criptomonedas.

**Tabla 1**

*Datos disponibles de donaciones: Fundación Come Back Alive*

| Donaciones  | Donaciones totales   | Donaciones en criptomonedas |
|---|----------------------|-----------------------------|
| Monto total en dólares americanos                                   | \$ 164795555.97      | \$ 14305493.93              |
| Cantidad total  | 1321916              | 9770                        |
| Monto promedio en dólares americanos<br>(1er período – 2do período) | \$ 159.62 - \$ 61.94 | \$ 1516.48 - \$ 365.24      |

*Nota.* Información al 8 de noviembre de 2022. Recuperado de "Reporte de fondos de donaciones desde el 1 de febrero de 2022 al 8 de noviembre de 2022 [Archivo de datos]" por Come Back Alive, s.f. (<https://savelife.in.ua/en/reporting-en/>).

En segundo lugar, en la Figura 1 podemos observar el aumento drástico en la cantidad de donaciones diarias al momento de la invasión de Rusia sobre Ucrania el día 24 de febrero de 2022, llegando a su pico máximo el día 26 de febrero. También, de forma más visible en la Figura 2, podemos ver que el aumento destacado en las donaciones perdura por 2 semanas, entre el comienzo de la invasión y el 7 de marzo de 2022. Luego del hito, se puede observar un declive en las donaciones hasta, incluso, principios de mayo. Por último, se observan pequeños picos posteriores, los cuales podrían deberse a la acumulación de donaciones por parte de grupos coordinados.




Figura 1. Gráfico de frecuencia de donaciones por día.




Figura 2. Gráfico de frecuencia de donaciones por día, ajustando el eje de donaciones.

Por otro lado, también podemos ver lo anterior descrito en la Figura 3, en donde representamos el monto acumulado en dólares americanos. Se destaca por su gran crecimiento exponencial, que se extiende por 1 semana, posterior a la invasión. Luego, la acumulación de donaciones se suaviza, pero continúa en incremento hasta principios de mayo. Posteriormente, se mantiene constante en el tiempo.




Figura 3. Gráfico de donaciones acumuladas en dólares estadounidenses (USD) por día.

En suma, vimos cómo los aumentos en las donaciones fueron repentinos al comienzo de la invasión, pero, luego, pasado el tiempo, las donaciones fueron disminuyendo hasta prácticamente desaparecer. Resulta interesante estudiar el comportamiento de los donantes, ya que la guerra e invasión de Rusia sobre Ucrania continuó en los meses posteriores con acontecimientos de la misma magnitud de relevancia y diferentes pedidos de ayuda internacional. Sin embargo, como vemos en los gráficos, no pareciera que los donantes reaccionen a tales pedidos por fuera de lo observado al comienzo del

suceso. Haciendo una consulta a los datos cronológicos de la guerra<sup>5</sup>, observamos que efectivamente han existido (a nuestro criterio) otras fechas importantes que podrían haber sido catalizadoras de nuevos contagios sociales (anuncios de bombas, rescate de civiles, pedidos de asistencia, etc.). Sin embargo, pareciera que no es el caso, dado que tales fechas no se corresponden con el aumento de las donaciones en los datos. El único caso en donde sí se adecua la noticia mediática con las donaciones es en los días siguientes al día de la invasión. De esta forma, podemos sugerir que la población reaccionó donando de forma destacada al comienzo de la guerra producto de la gran sorpresa (es decir, surge el contexto propicio para el cambio de norma social anteriormente mencionado), pero, luego, es probable que dejen de tener presente la información sobre la situación ucraniana, se olviden del conflicto, o bien pierdan el interés (en otras palabras, la norma social vuelve a estado previo por falta de coordinación social). Por tanto, consideramos que los shocks en las donaciones posteriores al comienzo de la invasión no son producto de otros hechos relevantes que funcionan como catalizadores de nuevos comportamientos prosociales, sino que representan rezagos del shock principal. En el Figura 4, podemos ver representado el interés público a partir de las búsquedas en el explorador web de Google. En resumen, es posible que el único shock que realmente haya modificado en cierta medida la norma social previa sea el observado en el pico máximo y los días siguientes.

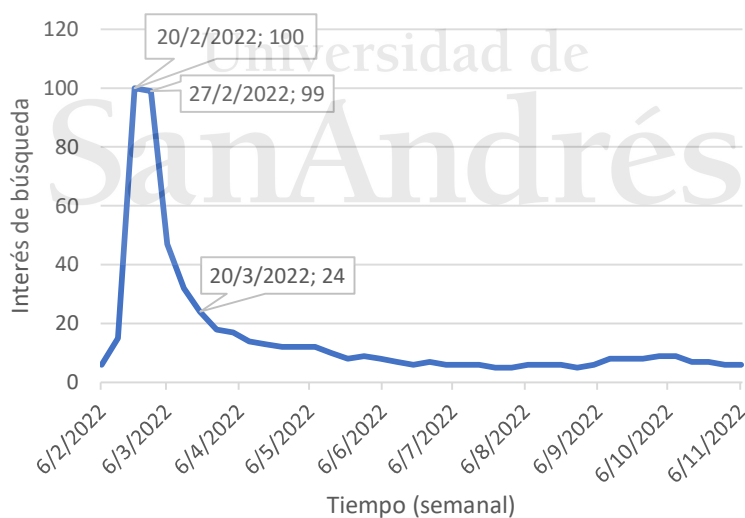


Figura 4. Gráfico de frecuencia semanal sobre el interés de búsqueda en todo el mundo entre febrero y noviembre de 2022 en el buscador de Google. Fuente de datos: Google Trends ([www.google.com/trends](http://www.google.com/trends)).

<sup>5</sup> CNN, s.f., <https://cnnespanol.cnn.com/2022/12/30/guerra-ucrania-cronologia-orix/>

### **3. Modelo teórico**

#### **3.1 Presentación del modelo epidemiológico**

Para empezar, existen diversos trabajos relacionados que utilizan modelos de contagio, los cuales incluyen modelos epidemiológicos, para representar y comprender los fenómenos de comportamientos en masa o replicabilidad de comportamientos sociales (normas sociales). Un ejemplo concreto que une las dinámicas epidemiológicas y este tipo de comportamientos se observa en estudios sobre la difusión y adopción de innovación (Bass, 1969) modas (Gladwell, 2000) y donaciones (Schweitzer y Mach, 2008). También se han utilizado para estudiar el contagio de comportamientos relacionados con el consumo de alcohol, drogas y el esparcimiento de rumores (Behrens et al, 1999; Bettencourt et al, 2006; Castillo-Garsow et al, 1997). En específico, en la literatura en economía, se utilizan los modelos de contagio como una formulación de comportamientos ajustados, en los cuales la adopción de ciertas acciones ocurre con cierta probabilidad proporcional al número de agentes en su entorno ejecutando tal comportamiento, con cierta posibilidad de revertir al comportamiento de statu quo; ver Jackson & Rogers (2007, p. 1) y López-Pintado (2008).

Entonces, para representar en el tiempo la proliferación de donaciones ante el evento bélico de interés, utilizamos un modelo dinámico ampliamente conocido en la disciplina de epidemiología (Kermack & McKendrick, 1927; Keeling & Rohani, 2008), llamado comúnmente modelo SIS, por sus siglas Susceptible-Infectado-Susceptible. El modelo SIS es un modelo compartimental, esto es, la población total se subdivide en dos compartimentos y se asume que los individuos dentro de cada compartimento poseen las mismas características. Además, en nuestro caso, utilizaremos el modelo en su versión determinística (no estocástica), lo cual significa que, dependiendo de las condiciones iniciales establecidas, el modelo generará cierto tipo de resultado concreto.

Por otra parte, el modelo SIS, a diferencia de la gran mayoría de modelos epidemiológicos, se caracteriza por no contar con agentes capaces de recuperarse de la enfermedad o comportamientos en nuestro caso, en otras palabras, este modelo no cuenta con inmunidad duradera. Con lo que sí cuenta es con cierta inmunidad temporal, esto es, implicarse en cierto comportamiento por un intervalo de tiempo determinado hasta dejar de tener ese accionar. Asimismo, al no existir tal inmunidad prolongada, permite al modelo representar la reincidencia en cierto comportamiento. Volviendo a

nuestro caso, en el modelo un individuo puede comportarse de forma prosocial varias veces a lo largo de su vida.

Por último, cabe agregar, según la revisión de literatura y categorización de los diferentes modelos epidemiológicos desarrollada por Funk et al (2010), el modelo SIS encaja en nuestro marco teórico, ya que se categoriza dentro de los modelos con fuente de información global (la información sobre la cual los agentes actúan está disponible para todos, tanto sobre el acontecimiento bélico, como las donaciones que realizan los demás), tipo de información basada en creencias (causado por múltiples -e incluso contradictorias- piezas de información, donde se mezclan las preferencias y expectativas sociales) y sobre el efecto del cambio de comportamiento a través de la modificación en sus parámetros (en nuestro caso, el cambio en las tasas de contagio y reincidencia de los comportamientos prosociales).

### 3.2 Descripción del modelo SIS - PDP

El modelo compartimental SIS es un modelo cerrado, porque la población total  $N$  se mantiene constante en el tiempo (suficiente para la proposición de este trabajo), excluyendo las muertes y nacimientos, variables usualmente añadidas en epidemiología. Por esto último, es que se lo suele utilizar como un modelo de corto plazo, estudiando primordialmente las transiciones entre los compartimentos.

Antes que nada, realizamos un pequeño cambio en la notación de las categorías del modelo para esquematizar mejor nuestro caso de uso. Entonces, en el modelo, como ya mencionamos, la población es dividida en dos categorías, por un lado, los *donantes potenciales* ( $P$ ), estos son los individuos vulnerables y susceptibles de ser contagiados hacia un comportamiento prosocial por parte de los *donantes actuales* ( $D$ ), siendo estos los individuos “infectados” con comportamientos prosociales, quienes efectivamente donaron. Cabe mencionar que suponemos que todos los donantes potenciales son antisociales, egoístas, de base, una suposición que está en línea con la teoría tradicional en economía, entre otras ciencias. Y, por último, cabe decir que nuestro modelo no cuenta con agentes que contagien comportamientos antisociales.

Entonces, tenemos que la población  $N$  es la suma de las dos clases, que varían en función del tiempo:

$$N = P(t) + D(t)$$

La transición entre estas clases ocurre a una tasa proporcional al número de individuos en las respectivas clases, ya sea por medio de la tasa de contagio constante  $\beta$  (transición de  $P$  a  $D$ ), o bien a través de la tasa de recuperación constante  $\gamma$  (transición de  $D$  a  $P$ ). En la Figura 5 mostramos el diagrama del modelo, dejando en vista su dinámica circular.



Figura 5. Diagrama de flujo del modelo PDP.

Las dinámicas del sistema pueden ser descritas por las siguientes ecuaciones diferenciales ordinarias:

$$\frac{dP}{dt} = -\frac{1}{N}\beta PD + \gamma D \quad P(0) = P_{t=0} \quad (1)$$

$$\frac{dD}{dt} = \frac{1}{N}\beta PD - \gamma D \quad D(0) = D_{t=0} \quad (2)$$

Siendo  $\beta > 0$  y  $\gamma > 0$  con condiciones iniciales  $P_{t=0}$  y  $D_{t=0}$ .

La primera ecuación (1) representa la evolución de la población  $P$ , los cuales se infectan en función de los contactos con los donantes actuales. Cabe destacar que, los contagios no se producen siempre que existe interacción, es por ello que el coeficiente de contagio,  $\beta > 0$ , indica la probabilidad de que se produzca un contacto suficiente para que haya transmisión del comportamiento prosocial más la probabilidad de que efectivamente se transmita. En otras palabras,  $\beta$  es la tasa de influencia (per cápita) efectiva de la información y normas sociales. Por último, la cantidad de sujetos, por unidad de tiempo, que se traspasan de  $P$  a  $D$ , se refleja en la notación como el producto  $\beta P(t)D(t)$ . Esto se puede describir como una interacción no local, como puede ser la interacción social que surge a través de los medios de comunicación. Esta suposición es apropiada, ya que los medios de comunicación informan de manera homogénea y constante sobre el desastre bélico y sus consecuencias, así como sobre la enorme cantidad de donaciones recibidas.

La segunda ecuación (2) muestra la evolución de la población  $D$ , los donantes actuales, quienes volverán a la clase  $P$  por medio del coeficiente de recuperación constante,  $\gamma > 0$ . Siendo este el

tiempo promedio de recuperación del comportamiento prosocial. En las próximas secciones desarrollaremos más exhaustivamente la función e interpretación de dichos coeficientes.

### 3.3 Equilibrio del modelo

Antes de comenzar a buscar los equilibrios del sistema, explicamos brevemente el número básico de reproducción ( $R_0$ ), o tasa de imitación según nuestra concepción. Siendo el número más utilizado en epidemiología,  $R_0$  se define como el número promedio de contagios que puede generar un donante introducido en una población susceptible de contagio a lo largo de un período infeccioso. En otras palabras, es el número promedio de personas influenciadas a empezar a donar (o aumentar su donación) por un actual donante. El principal objetivo del  $R_0$  es evaluar si una enfermedad se propagará o se controla. Si  $R_0 < 1$ , la enfermedad culmina y no existe un estado endémico, mientras que si  $R_0 > 1$ , el número de infectados tiende a un equilibrio endémico ( $D(t) > 0$ ). Volviendo a nuestro caso en concreto, en este trabajo buscaremos lo contrario a lo planteado en la mayoría de modelos epidemiológicos, nos interesa evaluar bajo qué condiciones podemos llegar a un equilibrio endémico ( $D(t) > 0$ ), con  $R_0 > 1$ , ya que nuestro objetivo es evaluar cómo podemos incrementar el contagio de comportamientos prosociales, como son las donaciones.

Dicho esto, buscamos los equilibrios del sistema de ecuaciones diferenciales ordinarias, para ello empezamos calculando cuándo se cumple en la ecuación (1)  $\frac{dP}{dt} = 0$ , reordenando obtenemos:

$$\frac{dP}{dt} = D \left( -\beta \frac{P}{N} + \gamma \right) = 0 \quad (3)$$

Por un lado, en el caso donde  $D = 0$ , para todo  $P$ , el equilibrio se encuentra en  $(P, 0)$ . Siendo este el punto de equilibrio sin contagio social de comportamientos prosociales, ya que todos los agentes son posibles donantes y ninguno es donante actual.

Por otro lado, en el caso donde  $D \neq 0$ , el equilibrio se encuentra en  $(P^*, D^*)$ , siendo  $P^* = \frac{N\gamma}{\beta}$ , para todo  $D$ . Recordando que  $P(t) + D(t) = N$ , reordenamos y utilizamos  $P(t) = N - D(t)$  para obtener  $D^* = N(1 - \frac{\gamma}{\beta})$ . Concluimos,  $(\frac{N\gamma}{\beta}, N(1 - \frac{\gamma}{\beta}))$ , nombrado como punto de equilibrio endémico, porque al ser  $D \neq 0$  el contagio social está presente.



Analizamos la estabilidad de los puntos de equilibrio calculando la matriz Jacobiana:

$$J(P, D) = \begin{pmatrix} -\beta \frac{D}{N} & -\beta \frac{P}{N} + \gamma \\ \beta \frac{D}{N} & \beta \frac{P}{N} - \gamma \end{pmatrix} \quad (4)$$

Luego, evaluamos la matriz en el primer equilibrio,  $(P, 0)$ , sin comportamientos prosociales (recuerdo,  $P(t) = N$ ):

$$J(P, 0) = \begin{pmatrix} 0 & -\beta + \gamma \\ 0 & \beta - \gamma \end{pmatrix} \quad (5)$$

Buscamos los autovalores calculando el polinomio característico asociado:

$$\det \begin{pmatrix} -\lambda & -\beta + \gamma \\ 0 & \beta - \gamma - \lambda \end{pmatrix} = 0 \quad (6)$$

$$P(\lambda) = -\lambda(\beta - \gamma - \lambda) = 0 \quad (7)$$

Siendo los autovalores de la matriz del primer equilibrio:

$$\lambda_1 = 0 ; \lambda_2 = \beta - \gamma \quad (8)$$

Analizando los autovalores, podemos ver que el equilibrio sin comportamientos prosociales es asintótica-localmente estable (estabilidad marginal) si  $\lambda_2 = \beta - \gamma < 0$ . Entonces, debe suceder que  $\beta < \gamma$ . Reordenando la última expresión, obtenemos el número reproductivo básico:  $R_0 = \frac{\beta}{\gamma} < 1$

Podemos concluir, siguiendo el criterio de clasificación de sistemas dinámicos no lineales, que el equilibrio sin comportamientos prosociales es efectivamente asintótica-localmente estable, si y sólo si,  $R_0 < 1$ .

Ahora, evaluamos la matriz en el segundo equilibrio,  $(P^*, D^*)$ , el equilibrio endémico, en este caso, con la posibilidad de contagio de comportamientos prosociales (recuerdo,  $(\frac{N\gamma}{\beta}, N(1 - \frac{\gamma}{\beta}))$ ):

$$J(P^*, D^*) = \begin{pmatrix} -\beta + \gamma & 0 \\ \beta - \gamma & 0 \end{pmatrix} \quad (9)$$

Buscamos los autovalores calculando el polinomio característico asociado:

$$\det \begin{pmatrix} -\beta + \gamma - \lambda & 0 \\ \beta - \gamma & -\lambda \end{pmatrix} = 0 \quad (10)$$

$$P(\lambda) = -\lambda(-\beta + \gamma - \lambda) = 0 \quad (11)$$

Siendo los autovalores de la matriz del segundo equilibrio:

$$\lambda_1 = 0 ; \lambda_2 = -\beta + \gamma \quad (12)$$

Analizando los autovalores, podemos ver que el equilibrio endémico con comportamientos prosociales es asintótica-localmente estable (estabilidad marginal) si  $\lambda_2 = -\beta + \gamma < 0$ . Entonces, debe suceder que  $\beta > \gamma$ . Reordenando la última expresión, obtenemos el número reproductivo básico:  $R_0 = \frac{\beta}{\gamma} > 1$

Podemos concluir, siguiendo el criterio de clasificación de sistemas dinámicos no lineales, que el equilibrio endémico con comportamientos prosociales es efectivamente asintótica-localmente estable, si y sólo si,  $R_0 > 1$ .

## 4. Caso práctico: Donaciones

### 4.1 Parámetros y condiciones iniciales

A continuación, desarrollamos la aplicación del modelo. Definimos los parámetros asociados ( $\beta$  y  $\gamma$ ) para realizar, en la siguiente sección, un análisis comparativo entre los datos y el modelo planteado.

Comenzando por los parámetros, el coeficiente  $\beta$ , la tasa de contagio, la cual indica la probabilidad de que se produzca un contacto suficiente para que haya transmisión del comportamiento prosocial más la probabilidad de que efectivamente se transmita:

$$\beta = P(\text{tasa de contacto}) + P(\text{contagio efectivo})$$

Tales probabilidades, en el caso de interés estudiado, pueden variar producto del contexto, normas, actitudes, creencias, etc. A pesar de ello, las investigaciones experimentales y de campo dedicadas al estudio del impacto que tienen los comportamientos prosociales ajenos sobre nuestro comportamiento, se acercan a la definición del parámetro  $\beta$  mencionado. Dicha literatura ha sido

resumida y detallada en el meta-análisis más reciente en el tema (Jung et al, 2020) y que engloba a la mayor diversidad de artículos (88 estudios) sobre el efecto de las normas sociales en estos comportamientos, sintetiza el tamaño del efecto, dado por la diferencia de efectos promedios entre los grupos de tratamiento (modelo prosocial) y los grupos de control. Esta diferencia, medida por el parámetro  $g$ , queda estimada con valor  $g = 0.45$ ,  $p < .001$ ,  $IC = [0.36, 0.54]$  95%. Exceptuando por sesgos de publicación (quitando estudios atípicos), arrojan un tamaño de efecto estimado de  $g = 0.37$ ,  $p < .001$ ,  $IC [0.29, 0.45]$  95%. Suponemos que sus resultados y resumen de los artículos revisados y analizados se asemejan a la definición propuesta en este apartado, por ello, utilizaremos el efecto estimado por los autores para establecer nuestro coeficiente  $\beta = 0.37$ ,  $IC [0.29, 0.45]$ . En concreto, el  $\beta = 0.37$  se traduce como 37 de 100 interacciones en un tiempo dado resultará en el contagio efectivo del comportamiento prosocial.

Ahora bien, para establecer el coeficiente  $\gamma$ , el cual se define como el tiempo promedio de recuperación, o bien, visto por la inversa, el tiempo promedio de prevalencia del comportamiento prosocial  $1/\gamma$ . En suma,

$$\gamma = \frac{1}{\text{Días promedio para recuperarse}}$$

Antes que nada, cabe aclarar que no contamos con datos sobre cuántos días los donantes actuales demoran en volver a ser potenciales donantes, dado que tal información es inobservable. A pesar de ello, sí contamos en nuestra base de datos con 429 observaciones de frecuencia de donaciones a nivel individual (bajo la criptomoneda Ether), los cuales comienzan el 25 de febrero de 2022 (día posterior a la invasión). Gracias a esa frecuencia de donaciones podemos hacer cierto seguimiento del donante y calcular la diferencia de días que demora entre una donación y la siguiente.




Figura 6. Representación esquemática de los datos utilizados para el cálculo de gamma.

Sin embargo, como mencionamos, sigue siendo inobservable la cantidad de días que transcurren del traspaso de  $D$  a  $P$ . Entonces, para identificar el parámetro de interés, supondremos que el promedio ponderado de la diferencia de días entre una donación y otra es, efectivamente, la cantidad de días

promedio para recuperarse. En la Figura 7, se muestra el histograma de la diferencia de días promedio a nivel individual.




Figura 7. Histograma sobre la diferencia de días promedio individual entre donaciones.

En conclusión, primero, calculamos el promedio individual de la cantidad de días que los donantes demoran en volver a donar y, segundo, calculamos su promedio ponderado (ya que, los donantes de mayor frecuencia son más representativos que los de menor frecuencia). De esta forma, obtenemos que la diferencia de días, en promedio, es de 14 días. Por tanto, nuestro coeficiente de recuperación es  $\gamma = \frac{1}{14}$ , o  $\gamma = 0.0714$ , el cual se traduce, 7 de 100 donantes se recuperan y pasan a ser posibles donantes.

## 4.2 Resultados

### 4.2.1 Modelo base: Parámetros constantes

A continuación, proseguimos con la comparación entre el modelo y los datos de donaciones de la fundación de Ucrania. La resolución del modelo se ha realizado en *RStudio* por medio del paquete de solución de ecuaciones ordinarias diferenciales, *desolve* (Soetaert et al., 2010). Para encontrar las soluciones del modelo utilizando dicha herramienta (ver Anexo), debemos establecer las condiciones iniciales del modelo, estos son, el período de tiempo, la cantidad de agentes en cada compartimento en  $t = 0$  ( $P_0$  y  $D_0$ ) y los parámetros ( $\beta$  y  $\gamma$ ).

En primer lugar, el período de tiempo, ha sido establecido en 281 días, desde el 1 de febrero de 2022 hasta el 8 de noviembre de 2022 (comienzo y fin de nuestra muestra, respectivamente). En segundo lugar, la cantidad de donantes actuales iniciales ( $D_0$ ) se definió según el número promedio de

donantes al comienzo del período de tiempo, 1 de febrero de 2022, siendo este de  $D_0 = 1.5$ . Luego, con respecto a la cantidad de donantes potenciales ( $P_0$ ), siendo estos inobservables, su determinación será supuesta en  $P_0 = 20000$ . Cabe aclarar, como hemos desarrollado en la resolución del modelo, no debería afectar el análisis de forma significativa tal supuesto, dado que la convergencia hacia un equilibrio endémico o no depende exclusivamente de la relación entre los parámetros. Por último, los parámetros se establecen según lo desarrollado en la sección anterior, siendo  $\beta = 0.37$  y  $\gamma = 0.0714$ . Como hicimos mención en la Sección 3.3 (análisis de equilibrios del modelo), dado que la convergencia del modelo depende de la relación entre estos dos parámetros, notamos que en este caso  $\beta > \gamma$ , por lo cual, el modelo tiende a un equilibrio “endémico” y, por tanto, podemos realizar la comparación entre el modelo y los datos.

Hechas las aclaraciones sobre las condiciones iniciales del modelo, obtenemos la cantidad de potenciales donantes y donantes actuales en cada momento del tiempo (ver Anexo 1):



Figura 8. Gráfico de cantidad de potenciales donantes ( $P$ ) y donantes actuales ( $D$ ) por día. Modelo base:  $P_0 = 20000$ ;  $D_0 = 1.5$ ;  $\beta = 0.37$ ;  $\gamma = 0.0714$

Concluimos que de 20001 agentes ( $N$ ), 16140 se indujeron en comportamientos prosociales y 3860 individuos no donaron, no fueron contagiados. Es decir, en una población compuesta por  $P_0 = 20000$  susceptibles a ser contagiados por  $D_0 = 1.5$  donantes, surgieron 16140.3 nuevos donantes. Además, se llega al pico máximo de contagios en el día 161.

En segundo lugar, graficamos la comparación entre la frecuencia de donaciones diarias de los datos y la cantidad de  $D_t$  por día:

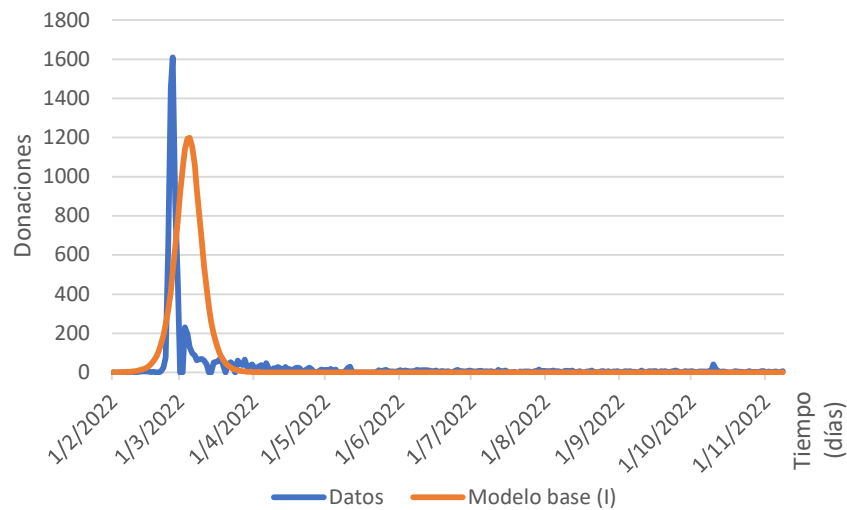


Figura 9. Gráfico comparativo de donaciones por día entre los datos y el modelo base ( $P_0 = 20000$ ;  $D_0 = 1.5$ ;  $\beta = 0.37$ ;  $\gamma = 0.0714$ )

Globalmente, observamos que el modelo representa la subida y caída abrupta en las donaciones en el período cercano al estallido de la guerra y, además, se condice adecuadamente con los datos en los momentos de estancamiento de las donaciones (períodos anteriores y posteriores al acontecimiento). Sin embargo, no se ajusta bien al momento del pico máximo. Tampoco al tiempo inmediatamente posterior, pareciera que el modelo sufre de cierto rezago, reacciona de forma tardía. Asimismo, no se adapta a los posteriores shocks y picos observados después del gran incremento. Por último, calculamos el R-cuadrado o bondad de ajuste, interpretado como el 14% de la variabilidad de las donaciones diarias es predicha por el número de donantes actuales del modelo. Cabe aclarar que, como en nuestro trabajo el interés central es presentar un modelo que pronostique correctamente a los datos, buscamos un R-cuadrado lo más grande posible. En la misma línea, resumimos otras medidas de error de pronóstico en la Tabla 2.

Por otro lado, también podemos observar las mismas conductas en el modelo cuando realizamos la comparación entre la cantidad de donaciones monetarias acumuladas (en dólares americanos) y la cantidad de donantes actuales acumulados ( $D_t$ ):

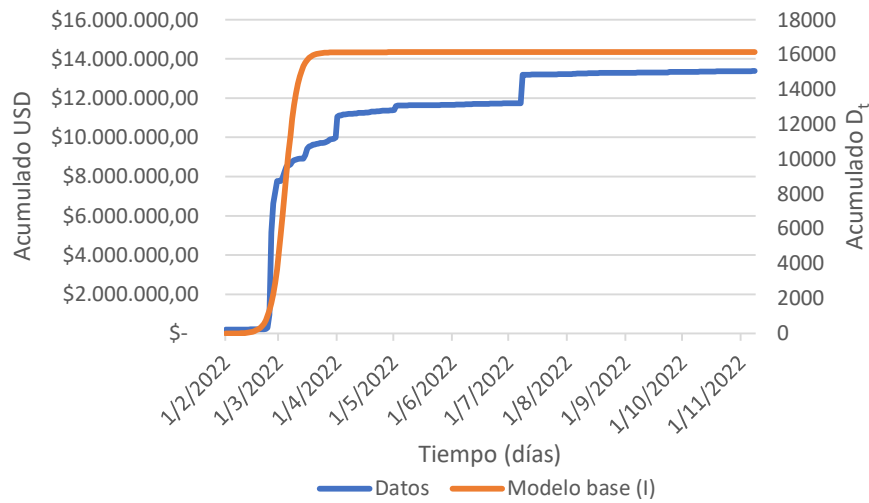


Figura 10. Gráfico comparativo de donaciones acumuladas en dólares estadounidenses (datos) y donantes actuales ( $D_t$ ) acumulados (modelo base:  $P_0 = 20000$ ;  $D_0 = 1.5$ ;  $\beta = 0.37$ ;  $\gamma = 0.0714$ )

Por la izquierda del gráfico, la cantidad de donaciones monetarias acumuladas y, por la derecha, la cantidad de donantes actuales acumulados. Nuevamente, en general e independientemente de la diferencia de escalas, el modelo pareciera no ajustar a los datos. Observamos, al principio del período, que el modelo crece de forma más paulatina que los datos, en otras palabras, vemos que el modelo sufre de cierto rezago a la reacción temprana. También podemos ver, en la segunda etapa, que ambas gráficas se estandarizan en el tiempo, manteniendo constantes las respectivas variables acumuladas. No obstante, e igual que en el caso anterior, el modelo falla en adaptarse a los shocks repentinos y no ajusta correctamente al crecimiento suavizado posterior al estallido bélico. Cabe mencionar que el modelo y los datos parecieran seguir un crecimiento logístico, usualmente observado en modelos epidemiológicos. Por último, extraemos el R-cuadrado para este último gráfico, resultando en que el 88% de la variabilidad de las donaciones monetarias acumuladas es predicha por la cantidad de donantes actuales acumulados de nuestro modelo.

Finalmente, para culminar, presentamos en la Tabla 2 las diferentes métricas para cuantificar los errores de pronóstico para las dos variables comparadas anteriormente (donantes por día y donaciones acumuladas). Cabe destacar que, debido a que las variables acumuladas se encuentran en diferentes unidades de medida, para calcular los errores de medición, antes que nada, precisamos estandarizar las variables (restándoles la media muestral y dividiéndolos por el desvío estándar muestral). Como resultado obtenemos la tabla que damos a continuación:

**Tabla 2***Estadística descriptiva y errores de pronóstico – Modelo base*

|                 | Donantes por día |                    | Donaciones acumuladas    |                                |
|-----------------|------------------|--------------------|--------------------------|--------------------------------|
|                 | Datos            | Modelo I           | Datos<br>(acumulado USD) | Modelo I<br>(acumulado $D_t$ ) |
| Promedio        | 30.14            | 57.44              | 11023207.14              | 14327.05                       |
| Desvío estándar | 147.14           | 207.19             | 3617850.46               | 4793.32                        |
| $R^2$           |                  | 0.1410             |                          | 0.8820                         |
| MSE<br>(RMSE)   |                  | 1.2424<br>(1.1146) |                          | 0.1212<br>(0.3481)             |
| MAD o MAE       |                  | 0.3755             |                          | 0.2840                         |

Nota: Utilizamos el R-cuadrado, previamente mencionado, y para calcular los errores de pronóstico el MAE (error absoluto medio, usualmente empleado en series de tiempo), MSE (error cuadrático medio) y RMSE (raíz del error cuadrático medio).

#### 4.2.2 Robustez del modelo: Cambio en parámetros

A continuación, a diferencia de la sección anterior y siendo más realista con la proposición de este trabajo (representar el cambio de las normas sociales a lo largo del tiempo), planteamos que aumenten las tasas de contagio ( $\beta$ ) y recuperación ( $\gamma$ ) de los comportamientos prosociales durante el período de mayor incremento en las donaciones. Para ello, subdividimos el período de tiempo analizado en dos etapas. Por un lado, llamaremos el período de “auge” de donaciones, desde el 21 de febrero de 2022 (día en que comenzó el conflicto internacional, con el presidente de Rusia, Vladimir Putin, reconociendo la declaración de independencia de la República Popular de Donetsk y la República Popular de Lugansk<sup>6</sup>) hasta el 27 de febrero de 2022 (día anterior a la segunda ronda de negociación entre las partes en conflicto que alivió temporalmente la disputa), y, por otro lado, el período de “no-auge”, el cual representa todo el resto de la muestra, es decir, el tiempo previo y posterior al período de “auge”.

Con lo que respecta al cálculo de los coeficientes de recuperación, se computan de la misma forma que en la Sección 4.1, con la salvedad de que se utiliza otro período. Primero, calculamos el  $\gamma_{Auge}$  a

<sup>6</sup> CNN, s.f., <https://cnnespanol.cnn.com/2022/12/30/guerra-ucrania-cronologia-orix/>



partir de todos los datos de frecuencia de donaciones que sean mayores al promedio total diario (es decir, para estimar este parámetro incluimos todos aquellos datos que estén por arriba del promedio de donaciones por día, siendo este de 6 donaciones, ver Figura 11). De esta forma, utilizamos los datos desde el 25 de febrero de 2022 (comienzo de datos de frecuencia) hasta el 9 de abril de 2022. Segundo, calculamos el  $\gamma_{No-auge}$  (utilizando los datos restantes, desde el 10 de abril de 2022 hasta el final de los datos de frecuencia, 4 de noviembre de 2022). Obtenemos que, en el período de auge, la diferencia de días entre una donación y la siguiente es, en promedio, de 9 días, mientras que, en el período de declive, las donaciones se realizan cada 39 días, en promedio. Así, obtenemos que el  $\gamma_{Auge} = 0.111$  y  $\gamma_{No-auge} = 0.0256$ . Cabe mencionar que, dado que no contamos con datos de frecuencia previos a la invasión, suponemos que aplicará para tal intervalo el gamma del período de no auge. Dicho sea de paso, podemos notar que el  $\gamma_{Auge} > \gamma_{No-auge}$ , siendo así que, en la etapa de auge, los donantes se recuperan más paulatinamente, permitiendo que existan una mayor cantidad de agentes  $D_t$  y, en definitiva, mayor probabilidad de contagio de comportamientos prosociales.




Figura 11. Gráfico de frecuencia de donaciones por día.

Finalmente, en relación al parámetro beta, también supondremos que aumenta durante el período de apogeo. Siguiendo con las mismas definiciones planteadas en la Sección 4.1, a partir de la evidencia experimental de Jung et al. (2020), el coeficiente de transmisión cambiará de  $\beta_{No-Auge} = 0.37$  (misma proposición anterior) a  $\beta_{Auge} = 0.45$  (límite superior del intervalo de confianza propuesto por los investigadores, IC [0.29, 0.45]) durante el período de apogeo. Por último, la cantidad de potenciales donantes iniciales se mantiene igual que en el planteo previo, siendo  $P_0 = 20000$  y la cantidad de donantes actuales iniciales  $D_0 = 1.5$ .

Realizadas las aclaraciones sobre las condiciones iniciales del modelo, obtenemos la cantidad de potenciales donantes y donantes actuales del modelo en cada momento del tiempo (ver Anexo 2):

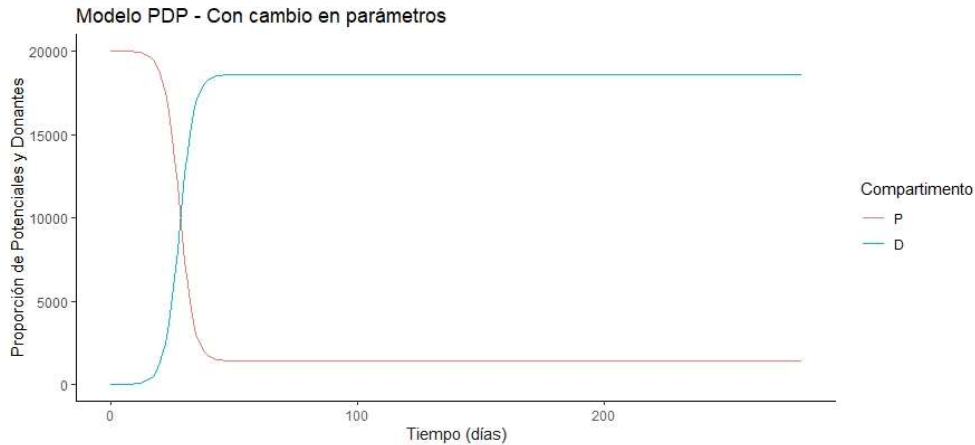


Figura 12. Gráfico de cantidad de potenciales donantes (P) y donantes actuales (D) por día. Modelo con cambio en parámetros:  $P_0 = 20000$ ;  $D_0 = 1.5$ ;  $\beta_{No-Auge} = 0.37$ ,  $\beta_{Auge} = 0.45$ ;  $\gamma_{No-auge} = 0.0256$ ,  $\gamma_{Auge} = 0.111$

Concluimos que de 20001 agentes ( $N$ ), 18595 se indujeron en comportamientos prosociales y 1406 no se contagiaron. Es decir, en una población compuesta por  $P_0 = 20000$  susceptibles a ser contagiados por el comportamiento prosocial de  $D_0 = 1.5$  donantes, surgieron 18596 nuevos donantes (2454.2 más donantes que en el caso anterior).

A continuación, presentamos gráficamente la comparación entre la frecuencia de donaciones diarias de la fundación ucraniana, la cantidad de  $D_t$  por día del modelo anterior y la cantidad de  $D_t$  por día del nuevo modelo con el cambio en parámetros:

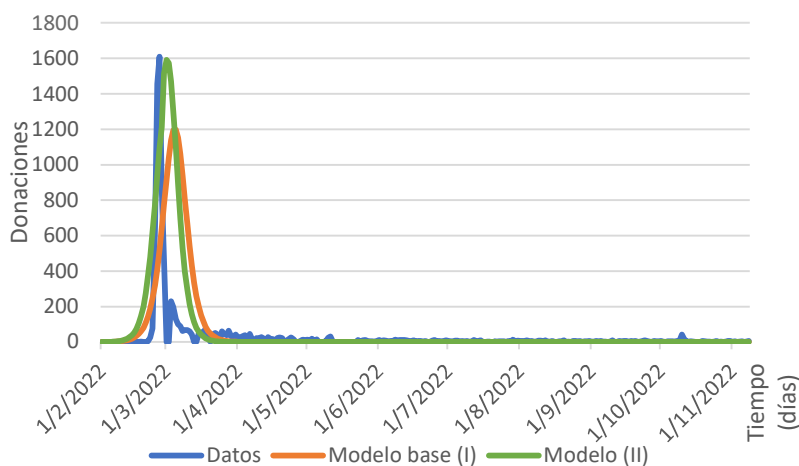


Figura 13. Gráfico comparativo de donaciones por día entre los datos, el modelo base (I) y el modelo con cambio de parámetros (II) ( $P_0 = 20000$ ;  $D_0 = 1.5$ ;  $\beta_{No-Au} = 0.37$ ,  $\beta_{Auge} = 0.45$ ;  $\gamma_{No-auge} = 0.0256$ ,  $\gamma_{Auge} = 0.111$ )

En comparación con el modelo anterior, podemos ver que el incremento en los parámetros durante el período de auge hizo posible centrar más adecuadamente el modelo a los datos, desviando la distribución hacia la izquierda. Además, propio del aumento de la tasa de contagio, vemos como el modelo nuevo alcanza el pico máximo de donaciones. De todas formas, el modelo continúa fallando en su adaptación al crecimiento repentino y a la caída abrupta y, además, no se ajusta correctamente a los shocks posteriores. Sin embargo, es posible que, nuevamente, adecuando las tasas de contagio y recuperación antes y después del período a los datos, el modelo se adapte mejor a tales picos. Resulta interesante este último punto, ya que podemos ver que efectivamente para representar los datos, los parámetros deben también variar con el tiempo, poniendo en vista la complejidad social.

Por otro lado, observamos conductas similares en el modelo cuando lo comparamos con la cantidad de donaciones monetarias acumuladas (en dólares americanos) y la cantidad de donantes actuales acumulados ( $D_t$ ):




Figura 14. Gráfico comparativo de donaciones acumuladas en dólares estadounidenses (datos) y donantes actuales ( $D_t$ ) acumulados (modelo II, con cambio en parámetros,  $P_0 = 20000$ ;  $D_0 = 1.5$ ;  $\beta_{No-Auge} = 0.37, \beta_{Auge} = 0.45$ ;  $\gamma_{No-auge} = 0.0256, \gamma_{Auge} = 0.111$ )

En este caso, notamos que el nuevo modelo se acopla de mejor forma a los datos en el primer período de auge, ajustándose al incremento súbito en las donaciones. No obstante, falla en readaptarse al período posterior, incrementando más que los datos y estandarizándose de forma brusca, no suavizada como se observa en los datos.

Por último, calculamos los errores de pronóstico para el nuevo modelo ajustado y obtenemos la siguiente tabla:

**Tabla 3***Estadística descriptiva y errores de pronóstico – Modelo con cambio de parámetros*

|                 | Donantes por día |                    | Donaciones acumuladas    |                                 |
|-----------------|------------------|--------------------|--------------------------|---------------------------------|
|                 | Datos            | Modelo II          | Datos<br>(acumulado USD) | Modelo II<br>(acumulado $D_t$ ) |
| Promedio        | 30.14            | 66.17              | 11023207.14              | 16727.87                        |
| Desvío estándar | 147.14           | 254.27             | 3617850.46               | 5261.69                         |
| $R^2$           |                  | 0.3159             |                          | 0.8882                          |
| MSE<br>(RMSE)   |                  | 0.8711<br>(0.9333) |                          | 0.1146<br>(0.3385)              |
| MAD o MAE       |                  | 0.3106             |                          | 0.2925                          |

Nota: Utilizamos el R-cuadrado, previamente mencionado, y para calcular los errores de pronóstico el MAE (error absoluto medio, usualmente empleado en series de tiempo), MSE (error cuadrático medio) y RMSE (raíz del error cuadrático medio).

### 4.2.3 Caso hipotético

En los apartados anteriores, logramos representar los datos de la forma más verídica posible, minimizando la cantidad de supuestos, restringiendo la capacidad de adaptación del modelo a los datos. En cambio, en este caso, reduciremos las restricciones y nos inclinaremos a realizar más supuestos sobre el modelo para que este sea más representativo de los datos observados.

Como hemos visto, el primer error notorio del modelo se encuentra en el pronto incremento en las donaciones y posterior decrecimiento. Para ello, por un lado, modificamos la tasa de contagio, tanto durante el período de no-auge, como en el período de auge. En primer lugar, bajaremos el coeficiente  $\beta_{No-Auge} = 0.37$  a  $\beta_{No-Auge} = 0.30$ , de esta forma, debería reducir el incremento temprano en las donaciones. En segundo lugar, subiremos el coeficiente  $\beta_{Auge} = 0.45$  a  $\beta_{Auge} = 0.90$ , lo que debería aumentar significativamente las donaciones en un período muy corto, como el observado en los datos. Además, cabe decir con respecto a este último punto que, proponiendo una tasa de contagio de 0.90, nos alejamos mucho de lo propuesto por la evidencia experimental de Jung et al (2020). Sin embargo, nos acercamos a la evidencia observacional de Korolov et al (2016), en donde, recordamos, encuentran una relación casi cuadrática entre el aumento en la exposición a la información social durante un desastre natural y las donaciones efectivizadas durante ese mismo tiempo. Por otro lado,

con respecto a la tasa de recuperación, proponemos que se estandarice durante toda la muestra, independiente de la etapa, a  $\gamma = 0.2$ . Con esto último, estamos suponiendo que los agentes, *ceteris paribus*, independientemente de su tipo y período en el que actúan, siempre mantienen una misma tasa de recuperación, es decir, una misma frecuencia de donaciones, en promedio.

En segundo lugar, en relación a la cantidad de agentes iniciales en cada compartimento, mantenemos igual que en las secciones anteriores la cantidad de donantes potenciales,  $P_0 = 20000$ . Mientras que, en cuanto a los donantes actuales, los aumentamos de  $D_0 = 1.5$  a  $D_0 = 10$ . Nuevamente, en este caso, nos alejamos de lo propuesto en el apartado anterior y suponemos que el compartimento de donantes debe ser mayor para compensar el aumento en la constante  $\gamma$  (ahora, durante todo el período, los donantes actuales se traspasan a donantes potenciales más rápido).

Realizadas las aclaraciones sobre las condiciones iniciales del modelo, obtenemos la cantidad de potenciales donantes y donantes actuales del modelo en cada momento del tiempo (v. Anexo 3):



Figura 15. Gráfico de cantidad de potenciales donantes (P) y donantes actuales (D) por día. Modelo III, caso hipotético:  $P_0 = 20000$ ;  $D_0 = 10$ ;  $\beta_{No-Au} = 0.3$ ,  $\beta_{Auge} = 0.9$ ;  $\gamma_{No-au} = 0.2$ ,  $\gamma_{Auge} = 0.2$

Observamos que, en comparación con los apartados previos, la cantidad de agentes no se cruzan. Además, vemos que ahora ocurren incrementos bien notorios durante la etapa de auge y cierta caída suavizada en el período siguiente. Concluimos que de 20010 agentes ( $N$ ), sólo 6670 se indujeron en comportamientos prosociales y 13340 no se contagiaron (a diferencia de 1406 del modelo anterior). Es decir, en una población compuesta por  $P_0 = 20000$  susceptibles a ser contagiados por el comportamiento prosocial de  $D_0 = 10$  donantes, surgieron 6670 nuevos donantes (11925 menos donantes que en el caso anterior). En nuestra opinión, información que se condice más con la realidad,

dado que la mayoría de las personas que pueden ser potenciales donantes, en su mayoría, no terminan donando.

Continuamos presentando gráficamente la comparación entre la frecuencia de donaciones diarias y la cantidad de  $D_t$  por día del modelo anterior y la cantidad de  $D_t$  por día de este nuevo modelo:




Figura 16. Gráfico comparativo de donaciones por día entre los datos, el Modelo II y el Modelo III, caso hipotético ( $P_0 = 20000$ ;  $D_0 = 10$ ;  $\beta_{No-Auge} = 0.3$ ,  $\beta_{Auge} = 0.9$ ;  $\gamma_{No-auge} = 0.2$ ,  $\gamma_{Auge} = 0.2$ )

En primer lugar, encontramos que, efectivamente, el modelo se ajusta mejor a los datos, resultado particularmente efectivo el incremento de la tasa de contagio durante el período de auge y la reducción del parámetro en la etapa contraria para, de esta forma, adaptarse al incremento súbito en las donaciones y la caída abrupta. Además, con este cambio de parámetros (y la cantidad de donantes actuales iniciales), podemos ver que, pasado el período de auge, el modelo coincide, en promedio, con los shocks de donaciones rezagadas, descendiendo de forma suavizada hasta mediados de abril, en donde los datos de donaciones también empiezan a estabilizarse en el tiempo.

Por último, comparamos la cantidad de donaciones monetarias acumuladas (en dólares americanos) y la cantidad de donantes actuales acumulados ( $D_t$ ):




Figura 17. Gráfico comparativo de donaciones acumuladas en dólares estadounidenses (datos) y donantes actuales ( $D_t$ ) acumulados (*Modelo III*, caso hipotético,  $P_0 = 20000$ ;  $D_0 = 10$ ;  $\beta_{No-Auge} = 0.3$ ,  $\beta_{Auge} = 0.9$ ;  $\gamma_{No-auge} = 0.2$ ,  $\gamma_{Auge} = 0.2$ )

En este caso, en general, notamos que el nuevo modelo se acopla de forma más precisa a los datos. Primero, se ajusta adecuadamente al comienzo de la muestra y al posterior incremento en las donaciones. Segundo, con respecto al período posterior a la etapa de auge, en comparación con la sección anterior, el modelo suaviza su crecimiento acumulado, similar al observado en los datos hasta finales de abril. Sin embargo, pierde su recorrido conjunto a principios de marzo (días posteriores al período de auge definido), en donde, nuevamente, los parámetros cambiaron.

Para culminar, comparamos los diferentes errores de pronóstico para los tres modelos presentados, sintetizados en la Tabla 4. En resumen, primero, comparando el modelo base con el modelo de cambio de parámetros, podemos ver que, por un lado, los errores se han reducido mínimamente y, por otro lado, que ha aumentado la variabilidad explicada, especialmente en la frecuencia de donaciones. En segundo lugar, comparando con el modelo más hipotético, vemos una reducción notable, tanto en los errores de ambas variables, como en la variabilidad explicada por el modelo.

**Tabla 4***Estadística descriptiva y errores de pronóstico – Comparativo modelos I, II y III*

|                | Donantes por día |                                   |                              | Donaciones acumuladas |                                   |                              |
|----------------|------------------|-----------------------------------|------------------------------|-----------------------|-----------------------------------|------------------------------|
|                | Modelo base (I)  | Modelo con cambio parámetros (II) | Modelo caso hipotético (III) | Modelo base (I)       | Modelo con cambio parámetros (II) | Modelo caso hipotético (III) |
| R <sup>2</sup> | 0.1410           | 0.3159                            | 0.9315                       | 0.8820                | 0.8882                            | 0.9315                       |
| MSE (RMSE)     | 1.2424 (1.1146)  | 0.8711 (0.9333)                   | 0.3922 (0.6262)              | 0.1212 (0.3481)       | 0.1146 (0.3385)                   | 0.0694 (0.2635)              |
| MAD o MAE      | 0.3755           | 0.3106                            | 0.1438                       | 0.2840                | 0.2925                            | 0.2423                       |

*Nota.* Utilizamos el R-cuadrado, previamente mencionado, y para calcular los errores de pronóstico el MAE (error absoluto medio, usualmente empleado en series de tiempo), MSE (error cuadrático medio) y RMSE (raíz del error cuadrático medio).

## 5. Conclusión

En conclusión, hemos analizado el comportamiento de las donaciones en masa ante el acontecimiento bélico entre Rusia y Ucrania. Dedujimos que el gran incremento en los actos benéficos se ha dado producto del incremento generalizado en el interés público por dicho suceso. También, hemos visto que se ha podido readaptar un modelo epidemiológico simple, como el modelo SIS sin dinámica vital, para representar el contagio de comportamientos. En segundo término, comprobamos que el modelo, a pesar de sus fallas, se ha ajustado medianamente a los datos. Luego, hemos subdividido la muestra en período de auge y no-auge para mejorar su precisión. Finalmente, por medio del cambio en los parámetros, llegamos a la conclusión, primero, de que la tasa de contagio en tiempos normales se adecua a lo descrito anteriormente en el trabajo de Jung et al (2020), pero dista de representar la tasa de contagio para el período de auge, la cual debimos incrementarla considerablemente para equiparar a los datos. Segundo, vimos que la tasa de recuperación, se mantiene similar a lo largo de toda la muestra, independiente del agente y entorno. En definitiva, destacamos que cuando el contexto es favorable para el cambio de cierta norma social que prolifera los comportamientos prosociales, reflejado en el aumento de las tasas de contagio, las donaciones aumentan, pero que cuando el contexto que desencadena tal norma social no está presente, el contagio de dichos comportamientos vuelve a sus niveles normales y, por tanto, los actos de caridad decaen.



En cuanto a las recomendaciones que podemos llegar a hacer a las fundaciones de caridad, primero, sugerimos generar espacios de interacción social para que los donantes actuales y potenciales donantes puedan intercambiar información, tanto presente, como del pasado. En segundo lugar, aconsejamos mantener incentivados a los donantes actuales con sus causas, principalmente, sosteniendo la coordinación social y haciendo especial hincapié en el impacto que sus donaciones tienen. En tercer lugar, recomendamos aprovechar los momentos de mayor conmoción social, como lo son los desastres naturales, guerras o todo evento masivo que genere un cambio abrupto en los comportamientos sociales para, así, generar la mayor cantidad de nuevos adeptos antes de que la norma social cambie nuevamente.

Por último, en vistas a futuros trabajos, sería interesante realizar un estudio que explore la variabilidad cuasi experimental antes y después del acontecimiento bélico, ya que nuestro trabajo dista de explorar efectos causales verdaderos. En nuestro caso, lo único que podemos concluir es, bajo el sentido de causalidad de Granger, que el cambio en las normas sociales y la información social están “temporalmente relacionadas”. Y, dado que una antecede siempre a la otra (la información social a la norma), nos ha sido útil en términos de predicción. Pero, sin lugar a dudas, el efecto causal contrario podría existir y debe ser estudiado en profundidad. Por otro lado, también puede ser interesante realizar el mismo estudio con datos de donaciones interanuales para investigar si se observan comportamientos estacionarios para, de esta forma, estimar correctamente los parámetros y su cambio a lo largo del tiempo.

## 6. Anexo

En los siguientes anexos enumerados, se adjuntan los códigos utilizados para la resolución del modelo en *RStudio* y la elaboración de las Figuras (8, 12 y 15), ordenado por sección. Cabe aclarar que las Figuras (1, 2, 3, 4, 7, 9, 10, 11, 13, 14, 16, 17), que incluyen datos de donaciones de la fundación, fueron realizadas con hojas de cálculo.

```

1 # Modelo base
  # Cargamos los paquetes necesarios,
  library(deSolve) # Ecuaciones diferenciales ordinarias, (Soetaert et al., 2010)
  library(ggplot2) # Grafico de las soluciones de las EDO's
  # MODELO BASE
  # Definimos las condiciones iniciales:
  state_values <- c(P= 20000, D= 1.5)
  parameters <- c(beta = 0.37, gamma = 0.0714)
  times <- seq(0, 280, by=1) #secuencia de 0 a 280 de a 1 --> 281 dias en total
  # Definimos las funciones para Ecuaciones diferenciales ordinarias:
  sis_model <- function (time, state, parameters) {
    with(as.list(c(state, parameters)), {
      N = P+D
      dP = gamma*D - (beta*D*P)/N
      dD = (beta*P*D)/N - gamma*D
      return (list (c(dP, dD)))
    })
  }
  # Resolvemos por medio del paquete deSolve
  library(deSolve)
  output <- as.data.frame(ode(y=state_values, times = times, func = sis_model, parms =
  parameters))
  # Extraemos los resultados de la cantidad de agentes S e I en el tiempo:
  output_full <- melt(as.data.frame(output), id='time')
  write.csv(output_full, file="Datos_PDP_param_constantes.csv")
  # Graficamos los resultados

```

```

ggplot(data=output_full, aes(x = time, y = value, color = variable, group = variable))+
geom_line()+ labs(title = "Modelo PDP", x = "Tiempo (días)", y = "Proporción de
Potenciales y Donantes", colour = "Compartimento")+ theme_classic() +
scale_fill_hue(labels = c("G1", "G2"))
2 # MODELO PDP: CAMBIO PARAMETROS SEGUN PERÍODO AUGE/NO-AUGE

state_values <- c(P= 20000, D= 1.5 )

times <- seq(0, 280, by=1)#secuencia de 0 a 280 de a 1 --> 281 días en total

parameters_1 <- c(start_interv = 20, end_interv = 26) # Intervención / Cambio
parámetros en período “auge”: 21/2/22 al 27/2/22

# Shock en parámetros:
sis_model_interv <- function (time, state, parameters){
  with(as.list(c(state, parameters_1)),{

    gamma = ifelse(
      (time < start_interv || time > end_interv), 0.026, 0.111)
    beta = ifelse(
      (time < start_interv || time > end_interv), 0.37, 0.45)

    N = P+D
    dP = gamma*D - (beta*D*P)/N
    dD = (beta*P*D)/N - gamma*D
    return (list (c(dP, dD)))
  })
}

library(deSolve)
output_intervention <- as.data.frame(ode(y=state_values, times = times, func =
sis_model_interv, parms = parameters_1))

output_full_interv <- melt(as.data.frame(output_intervention), id='time')
write.csv(output_full_interv, file="Modelo_PDP_param_según_auge_noauge.csv")

ggplot(data=output_full_interv, aes(x = time, y = value, color = variable, group =
variable))+ geom_line()+ labs(title = "Modelo PDP - Con cambio en parámetros", x =
"Tiempo (días)", y = "Proporción de Potenciales y Donantes", colour =
"Compartimento")+ theme_classic()
3 # MODELO PDP - CASO HIPOTETICO

```

```

state_values <- c(P= 20000, D= 10)
times <- seq(0, 280, by=1)#secuencia de 0 a 280 de a 1 --> 281 días en total

parameters_1 <- c(start_interv = 20, end_interv = 26) # Intervención / Cambio
parámetros en período AUGE: 21/2/22 al 27/2/22

# Shock parámetros:
sis_model_interv <- function (time, state, parameters){
  with(as.list(c(state, parameters_1)),{

    gamma = ifelse(
      (time < start_interv || time > end_interv), 0.2, 0.2)
    beta = ifelse(
      (time < start_interv || time > end_interv), 0.3, 0.9)

    N = P+D
    dP = gamma*D - (beta*D*P)/N
    dD = (beta*P*D)/N - gamma*D
    return (list (c(dP, dD)))
  })
}

library(deSolve)
output_intervention <- as.data.frame(ode(y=state_values, times = times, func =
sis_model_interv, parms = parameters_1))

output_full_interv <- melt(as.data.frame(output_intervention), id='time') #Base de datos
write.csv(output_full_interv, file="Modelo_PDP_caso_hipotetico.csv")

ggplot(data=output_full_interv, aes(x = time, y = value, color = variable, group =
variable))+geom_line()+ labs(title = "Modelo PDP - Caso hipotético", x = "Tiempo
(días)", y = "Proporción de Potenciales y Donantes", colour =
"Compartimento")+theme_classic() # Grafico

```

## 7. Bibliografía

- Bass, F. M. (1969). A New Product Growth for Model Consumer Durables. *Management Science*, 15 (5), 215–227.
- Behrens, D. A., Caulkins, J. P., Tragler, G., Haunschmied, J. L., & Feichtinger, G. (1999). A dynamic model of drug initiation: implications for treatment and drug control. *Mathematical Biosciences*, 159 (1), 1-20.
- Bettencourt, L. M., Cintrón-Arias, A., Kaiser, D. I., & Castillo-Chávez, C. (2006). The power of a good idea: Quantitative modeling of the spread of ideas from epidemiological models. *Physica A: Statistical Mechanics and its Applications*, 364, 513-536.
- Bicchieri, C., & Xiao, E. (2009). Do the right thing: but only if others do so. *Journal of Behavioral Decision Making*, 22 (2), 191-208.
- Bicchieri, C. (2016). *Norms in the Wild: How to Diagnose, Measure, and Change Social Norms*. Oxford University Press.
- Boyd, R., Richerson, P. J., & Henrich, J. (2011). The cultural niche: Why social learning is essential for human adaptation. *Proceedings of the National Academy of Sciences*, 108 (supplement\_2), 10918-10925.
- BTC.COM (s.f.). *BackAndAlive Donation Wallet*. Recuperado el 8 de noviembre de 2022 de <https://explorer.btc.com/btc/address/bc1qkd5az2ml7dk5j5h672yhxmhmx9tuf97j39fm6/>
- Castillo-Garsow, C., Jordan-Salivia, G., Rodriguez-Herrera, A. (1997). Mathematical models for the dynamics of tobacco use, recovery and relapse. *Biometrics Unity Technical Reports, Cornell University*, 18 pages.
- Chudek, M., & Henrich, J. (2011). Culture–gene coevolution, norm-psychology and the emergence of human prosociality. *Trends in cognitive sciences*, 15 (5), 218-226.
- CNN Español. (s.f.). Así ha sido, mes a mes, la guerra en Ucrania: datos y cronología sobre la invasión rusa. *CNN*. Recuperado el 30 de diciembre de 2022 de <https://cnnespanol.cnn.com/2022/12/30/guerra-ucrania-cronologia-orix/>
- Come Back Alive (s.f.). *Reporte de fondos de donaciones desde el 1 de febrero de 2022 a 8 de noviembre de 2022 [Archivo de datos]*. Recuperado el 8 de noviembre de 2022 de <https://savelife.in.ua/en/reporting-en/>
- Etherscan (s.f.). *BackAndAlive Donation Wallet*. Recuperado el 8 de noviembre de 2022 de <https://etherscan.io/address/0xa1b1bbB8070Df2450810b8eB2425D543cfCeF79b/>

- Funk, S., Salathé, M., & Jansen, V. A. (2010). Modelling the influence of human behaviour on the spread of infectious diseases: a review. *Journal of the Royal Society Interface*, 7 (50), 1247-1256.
- Gladwell, M. (2000). *The tipping point: how little things can make a big difference*. New York: Little, Brown and Company.
- Google Trends. (s.f.). "Ukraine". Recuperado el 15 de noviembre de 2022 de <https://trends.google.com/trends/explore?q=ukraine>
- Hamilton, W. D. (1964). The genetical evolution of social behaviour. II. *Journal of theoretical biology*, 7 (1), 17-52.
- Henrich, J., Boyd, R., Bowles, S., Camerer, C., Fehr, E., Gintis, H., & McElreath, R. (2001). In search of homo economicus: behavioral experiments in 15 small-scale societies. *American Economic Review*, 91 (2), 73-78.
- Henrich, J., McElreath, R., Barr, A., Ensminger, J., Barrett, C., Bolyanatz, A., ... & Ziker, J. (2006). Costly punishment across human societies. *Science*, 312 (5781), 1767-1770.
- Jackson, M. O., & Rogers, B. W. (2007). Relating network structure to diffusion properties through stochastic dominance. *The BE Journal of Theoretical Economics*, 7 (1).
- Jung, H., Seo, E., Han, E., Henderson, M. D., & Patall, E. A. (2020). Prosocial modeling: A meta-analytic review and synthesis. *Psychological bulletin*, 146 (8), 635-663.
- Keeling, M. J., & Rohani, P. (2008). *Modeling Infectious Diseases in Humans and Animals*. Princeton University Press.
- 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.
- Korolov, R., Peabody, J., Lavoie, A., Das, S., Magdon-Ismail, M., & Wallace, W. (2016). Predicting charitable donations using social media. *Social Network Analysis and Mining*, 6, 1-10.
- López-Pintado, D. (2008). Diffusion in complex social networks. *Games and Economic Behavior*, 62 (2), 573-590.
- McEvily, B., Weber, R. A., Bicchieri, C., & Ho, V. T. (2006). Can groups be trusted? An experimental study of trust in collective entities. *Handbook of trust research*, 52-67.
- Richerson, P. J., & Boyd, R. (2008). *Not by genes alone: How culture transformed human evolution*. University of Chicago press.

- Rodríguez, F, Millón, M E. & Weinmann, C. (2021). *Modelos de sostenibilidad financiera de las organizaciones de la sociedad civil en América Latina* (Informe OSC-10-02-2021). <https://do-general-statics.s3.amazonaws.com/support/tinker-report/Informe+-+Final+OSC-10-02-2021.pdf/>
- Saeri, A. K., Slattery, P., Lee, J., Houlden, T., Farr, N., Gelber, R. L., ... & Zorker, M. (2022). What works to increase charitable donations? A meta-review with meta-meta-analysis. *VOLUNTAS: International Journal of Voluntary and Nonprofit Organizations*, 1-17.
- Schweitzer, F., & Mach, R. (2008). The epidemics of donations: logistic growth and power-laws. *PLoS One*, 3 (1), e1458.
- Soetaert, K., Petzoldt, T., & Setzer, R. W. (2010). Solving differential equations in R: package deSolve. *Journal of statistical software*, 33, 1-25.
- The Nonprofit Times. (10 de febrero de 2022). Crypto Donations Skyrocketed In 2021. *The Nonprofit Times*. <https://www.thenonprofittimes.com/technology/crypto-donations-skyrocketed-in-2021/>
- Trivers, R. L. (1971). The evolution of reciprocal altruism. *The Quarterly review of biology*, 46 (1), 35-57.
- Van Teunenbroek, C., Bekkers, R., & Beersma, B. (2020). Look to others before you leap: A systematic literature review of social information effects on donation amounts. *Nonprofit and Voluntary Sector Quarterly*, 49 (1), 53-73.
- Yahoo Finance (s.f.). *Bitcoin USD (BTC-USD) datos históricos desde el 1 de febrero de 2022 al 8 de noviembre de 2022*. Recuperado el 8 de noviembre de 2022 de <https://finance.yahoo.com/quote/BTC-USD/history?p=BTC-USD/>