

# EL BOOM DE TWITCH: EL AUGE DE LA PLATAFORMA POR EL IMPACTO DE LA PANDEMIA DE COVID-19

## THE TWITCH BOOM: THE RISE OF THE PLATAFORM DUE TO THE IMPACT OF THE COVID-19 PANDEMIC

**Nicolás Alvarez**

Instituto de Investigaciones Económicas y Sociales del Sur (IIESS UNS-CONICET)  
Bahía Blanca, Buenos Aires, Argentina  
[nalvarez@iieess-conicet.gob.ar](mailto:nalvarez@iieess-conicet.gob.ar)

Fecha de recepción: 14/09/2023 – Fecha de aceptación: 02/10/2023  
DOI: <https://doi.org/10.36995/j.visiondefuturo.2024.28.02.002.es>

### RESUMEN

La pandemia de COVID-19 provocó que distintos países de todo el mundo decretaran medidas de distanciamiento social y cuarentenas estrictas, generando cambios en los hábitos de consumo cotidiano de las personas. El incremento del tiempo de permanencia en los hogares fomentó nuevas formas de entretenimiento en casa, impulsando distintos tipos de entretenimiento e interacción en línea. El objetivo principal del presente trabajo es medir y analizar el impacto de los efectos de la pandemia en el consumo de contenidos en una plataforma online de transmisiones en vivo, Twitch. El método de investigación se desarrolló a través del uso de datos referidos a la cantidad de visualizaciones totales promedio en la plataforma, y se buscó determinar los efectos iniciales y prolongados de la pandemia en el comportamiento y evolución de los contenidos consumidos en la plataforma. Las técnicas estadísticas utilizadas fueron la Regresión Discontinua y Diferencias en Diferencias. Los resultados obtenidos sugieren que la pandemia provocó un aumento en la cantidad de personas conectadas de manera concurrente entre un 30% y 40%. Además, se observa que este cambio de nivel en las visualizaciones de la plataforma es persistente en el tiempo y, en el nuevo nivel pos pandemia, se mantiene la tendencia de crecimiento observada antes de la pandemia.

**PALABRAS CLAVE:** Streaming online, Twitch, Valuación de impacto, Covid-19.

### ABSTRACT

The COVID-19 pandemic led various countries worldwide to implement social distancing measures and strict quarantines, resulting in changes in people's daily consumption habits. The increase in time spent at home fostered new forms of home entertainment, driving various types of online entertainment and interaction. The main objective of this study is to measure and analyze the impact of the pandemic's effects on content consumption on an online live streaming platform, Twitch. The research method involved the use of data related to the average total views on the platform, aiming to determine the initial and prolonged effects of the



pandemic on the behavior and evolution of consumed content on the platform. Statistical techniques employed included Regression Discontinuity and Differences in Differences. The results suggest that the pandemic led to an increase in the number of concurrently connected users by 30% to 40%. Furthermore, it is observed that this change in the platform's viewership level persists over time, maintaining the growth trend observed before the pandemic at the new post-pandemic level.

**KEYWORDS:** Live streaming, Twitch, Impact valuation, Covid-19.

## INTRODUCCIÓN

A fines del año 2019 la Comisión Municipal de Salud de Wuhan (China) notifica la detección de un conglomerado de casos de neumonía que posteriormente se determina que fueron causados por un nuevo coronavirus. Para el 11 de marzo de 2020, con casos reportados en 114 países y una preocupación por los alarmantes niveles de propagación de la enfermedad y su gravedad, el director general de la Organización Mundial de la Salud (OMS) declaró a la enfermedad causada por el nuevo coronavirus (COVID-19) como una pandemia (OMS, 2020). A partir de ese momento, para reducir la propagación del virus, distintos países de todos los continentes fueron introduciendo medidas de restricción/bloqueo de movilidad, incluidas órdenes de permanecer en el hogar (stay-at-home) y, medidas de distanciamiento físico y social (Scerbakov et al., 2022).

El contexto de pandemia, caracterizado por las medidas de distanciamiento físico y social, provocó cambios en la sociedad de muchas maneras; como la forma de trabajar, socializar e incluso en cambios en los hábitos de consumo, entre ellos, en qué se utiliza el tiempo libre. Las medidas de contención de la propagación del virus provocaron que la gente pase mucho más tiempo en su casa y, de esta forma, fomentaron la búsqueda de nuevas formas de entretenimiento doméstico, promoviendo el consumo de plataformas digitales y que las personas pasen más tiempo conectadas (Pineiro-Chousa et al., 2023; Gómez-Carmona et al., 2022). Desde el hogar, con una conexión a internet y dispositivos como computadoras, consolas, teléfonos inteligentes, entre otros, las personas pueden acceder a una amplia variedad de servicios de entretenimiento; entre las que destacan las plataformas de contenido multimedia y videojuegos (Laming, 2020; Aguilar Del Castillo, 2021). En este sentido, en los últimos años han surgido varios estudios que estudian el efecto del COVID-19 en los distintos sectores de la economía y los negocios.

La industria de contenidos digitales de entretenimiento observó los efectos del confinamiento, tanto en un aumento de su demanda por motivos de dispersión como por la búsqueda de una mayor interacción social debido a la coyuntura de aislamiento (Aguilar Del Castillo, 2021). En este sentido, se vivió el auge de las nuevas redes sociales sincrónicas, que se diferencian de las tradicionales por no contar con una separación temporal inherente

entre la creación y el consumo de contenidos. En estas plataformas de transmisiones en vivo los espectadores pueden interactuar con el creador u otros espectadores, permitiendo que el consumo de contenidos se convierta en una experiencia social de co creación colectiva (Giertz et al., 2022). Los videojuegos en línea y las transmisiones de sesiones de juego en vivo en línea pueden proporcionar un medio para socializar con otros y crear un sentido de comunidad y bienestar, muy necesario ante el clima de incertidumbre emocional provocada por la pandemia (Scerbakov et al., 2022; Woo Chae y Hyun Lee, 2022).

La plataforma de streaming, Twitch, al momento de la pandemia era la plataforma líder en el mundo en transmisiones en vivo que se enfocaban en contenido de videojuegos (Scerbakov et al., 2022). Por este motivo, resulta de interés estudiar el impacto que tuvo en la plataforma este aumento de la demanda de entretenimiento en línea provocado por las medidas de distanciamiento social para minimizar la propagación del virus. A continuación, se plantean las preguntas de investigación de especial interés:

P1: ¿La pandemia de COVID-19, y las medidas de mitigación con estrictas medidas de distanciamiento social, afectó al consumo de transmisiones en la plataforma Twitch (cantidad de visualizaciones promedio)?

P2: ¿El efecto de la pandemia de COVID-19 en la plataforma Twitch es persistente en el tiempo? Es decir, ¿el impacto perduró en el tiempo o se limitó a un umbral cercano al período de pandemia?

## **DESARROLLO**

### **Marco Teórico**

#### **Economías de plataforma**

En los últimos años, la proliferación de computadoras personales, Internet, dispositivos móviles y servicios en la nube han dado lugar a la formación y crecimiento exponencial de las plataformas digitales. Estas plataformas en línea ofrecen servicios digitales que facilitan la interacción a través de Internet entre grupos de usuarios diversos pero interdependientes. La revolución digital ha impulsado nuevas estructuras organizativas que permiten la creación y captura de valor en la economía digital. Estas plataformas digitales crean valor al facilitar los intercambios o transacciones y promover la innovación, lo que resulta en una drástica reducción de los costos del rápido escalamiento global. Algunos ejemplos de estas plataformas en línea incluyen mercados en línea, tiendas de aplicaciones, motores de búsqueda, redes sociales y plataformas destinadas a la economía colaborativa (Gawer, 2021; Brynjolfsson et al., 2018).

Cusumano et al. (2021) propone una tipología de plataformas que se basa en cómo generan valor y distinguen tres tipos principales: plataformas transaccionales, plataformas de innovación y plataformas híbridas. Las plataformas de transacciones facilitan las interacciones

entre muchas personas y organizaciones que de otro modo tendrían dificultades para encontrarse o realizar transacciones entre sí; es decir, reducen los costos de búsqueda y transacción. Las plataformas de innovación proporcionan una base tecnológica para que los innovadores desarrollen productos o servicios complementarios. Mientras que las plataformas híbridas son una combinación de ambas características.

Las plataformas de transmisión de contenidos, como Twitch, tienen un lugar destacado en el contexto de las economías de plataforma. De acuerdo con la tipología propuesta por Cusumano et al. (2021), estas plataformas se clasificarían principalmente como plataformas transaccionales, ya que facilitan la interacción en tiempo real entre múltiples usuarios, permitiendo la transmisión de contenido en vivo. Estas plataformas crean nuevos espacios innovadores donde individuos y organizaciones pueden conectarse con una fricción mínima y sin la necesidad de desarrollar sus propias soluciones técnicas o poseer todos los activos que ofrecen a los usuarios (Gawer, 2021). Los servicios de plataforma son capaces de aportar grandes beneficios a los consumidores y, aunque generalmente son ofrecidos de forma gratuita a los usuarios, las investigaciones demuestran sistemáticamente que los consumidores están dispuestos a otorgarle un valor financiero a varios de los servicios en línea. Esta situación, en la mayoría de los casos, todavía no se ve reflejada en las medidas de producto bruto interno (Brynjolfsson et al., 2018, 2019).

Las plataformas digitales, si bien se ofrecen de forma gratuita a los usuarios, permiten a los creadores de contenido y empresas generar ingresos a través de publicidad y suscripciones derivadas de la transmisión de contenido en vivo y la participación activa de la audiencia, creando una comunidad en línea de seguidores y creadores de contenido (Aguilar, 2021). En este sentido, Twitch y las plataformas similares son un ejemplo destacado de cómo las plataformas de transacciones pueden transformar la dinámica de la economía digital al conectar a millones de usuarios y crear nuevas oportunidades comerciales en el entorno de la transmisión de contenido en vivo.

### **Nuevas formas de comunicación**

La irrupción de las nuevas tecnologías de la información ha tenido un impacto significativo en la industria de los medios de comunicación tradicionales. Este fenómeno no es reciente, de hecho, en 2003 Henry Jenkins escribió sobre la emergencia de formatos alternativos de comunicación y el papel crucial que desempeñaba la audiencia en ellos. En este contexto, se destaca la participación activa de los usuarios en las redes sociales y las comunidades de seguidores a nivel global, fomentando la creación de prosumidores que contribuyen activamente en la generación de contenidos (Ferrarelli, 2016).

Según diversos analistas de medios digitales, ya no existe una edad fija para el consumo de plataformas de contenidos. Esto se debe principalmente a que los Baby Boomers, producto

del confinamiento provocado por la pandemia de COVID-19, adquirieron experiencia de uso al digitalizar gran parte de sus consumos en reemplazo de sus actividades en al aire libre. Por otro lado, las generaciones más jóvenes empiezan a recurrir y consumir plataformas digitales como Twitch y, a su vez, comentan y comparten sobre esos contenidos en las redes sociales como parte de la pertenencia a un grupo (Aguilar, 2021).

Este nuevo contexto da lugar a la proliferación de nuevas plataformas de contenidos digitales enfocadas en el ofrecimiento del Video On Demand (VOD) que, a diferencia de la televisión y otros medios tradicionales, son contenidos disponibles para ser consumidos en el momento que el usuario lo requiera. Netflix es una de las plataformas pioneras en la distribución de VOD y, por otro lado, con una oferta de contenidos en constante evolución, YouTube es otro ejemplo. Este giro de la distribución de contenidos llevó a las grandes productoras y distribuidoras de cine y televisión a crear sus propias plataformas digitales, dando lugar a lo que Elena Neira, licenciada en Derecho y Comunicación Audiovisual y especializada en nuevos modelos de distribución de contenidos de video digital, denominó “guerra de plataformas” o “Streaming Wars” (Matej, 2022).

Los servicios ofrecidos tradicionalmente por redes sociales (Facebook, por ejemplo), el intercambio de contenidos (YouTube, por ejemplo) y el microblogging (Instagram, por ejemplo), se caracterizan por una separación temporal inherente entre la creación y el consumo de contenidos (VOD). Es decir, son asincrónicos, el contenido no se consume inmediatamente y el creador no recibe un feedback en vivo. Por otro lado, este desfase entre creación y consumo de contenido, no aplica a los nuevos servicios de redes sociales sincrónicas emergentes o plataformas de streaming de contenido en vivo. Las interacciones en tiempo real facilitadas por la tecnología no son un fenómeno nuevo pero las redes sociales sincrónicas son únicas porque se centran en contenido disponible públicamente, consumido y creado colectivamente. En las transmisiones en vivo los espectadores pueden interactuar con el creador u otros espectadores a través de distintas herramientas de comunicación provistas por la plataforma (como chats en vivo, alerta de donaciones, entre otros). De esta forma, el creador de contenido recibe una retroalimentación en tiempo real, pudiendo reaccionar a las interacciones y comentarios de los usuarios, permitiendo que el consumo de contenidos se convierta en una instancia singular y una experiencia de co creación colectiva (Giertz et al., 2022). En este sentido, las motivaciones sociales, como conocer gente nueva, la interacción social y el sentido de comunidad, son importantes para los espectadores de transmisiones en vivo; situación que sugiere que los espectadores de transmisiones en vivo se sienten atraídos por canales en los que se sienten notados, importantes e influyentes (Hilvert-Bruce et al., 2018).

## Plataforma Twitch

Fundada en el año 2011, Twitch es la plataforma de streaming de video en vivo más popular del mundo. Si bien no es nueva y ha experimentado una notoria evolución desde su creación, tuvo un incremento significativo de su popularidad a partir de 2020 debido al confinamiento por la pandemia de COVID-19 (Padilla Molina y Navarro, 2022; Zhao et al., 2020). Twitch, que originalmente fue concebida como una plataforma centrada en la transmisión de videojuegos en vivo, en la actualidad ha diversificado su alcance para abarcar una amplia gama de contenidos, desde música en vivo y creación artística hasta discusiones en tiempo real sobre diversos temas (Sjöblom y Hamari, 2016). La importancia de la plataforma tuvo un crecimiento tan rápido que, en los últimos cinco años, se convirtió en una referencia en la industria de los juegos y, cada vez más, en el ecosistema de medios global en su conjunto (Johnson y Woodcock, 2018).

La proliferación de plataformas de streaming en vivo, encabezada por Twitch, ha desempeñado un papel transformador en la evolución de las formas de comunicación e interacción en la era digital. Este tipo de plataformas permiten a los creadores de contenido establecer conexiones inmediatas con audiencias globales, a través de las experiencias compartidas y la participación continua en transmisiones en vivo. De esta forma el creador, a través de su intervención, puede lograr que la retroalimentación evolucione en interacciones sociales más personalizadas, desarrollando una conexión entre los participantes de la transmisión y fomentando el sentido de comunidad en el canal, redefiniendo las experiencias tradicionales de comunicación (Hilvert-Bruce et al., 2018; Giertz et al., 2022; Hamilton et al., 2014).

## Metodología

La plataforma Twitch, a través de una API, pone a disposición tanto para creadores de contenido como para desarrolladores, estadísticas relacionadas a sus transmisiones. A su vez, los desarrolladores pueden acceder a un set de estadísticas globales de Twitch; como la cantidad de espectadores en la plataforma, canales de transmisión activos, transmisiones en vivo, cantidad de horas vistas, entre otras. Actualmente, existen muchos desarrolladores que recopilan dicha información de Twitch y la ponen a disposición en sus plataformas web, de esta forma, se puede disponer de datos mensuales y diarios de la plataforma.

Dentro de la industria de entretenimiento y, estrechamente relacionados a algunas plataformas de streaming, se encuentra la industria de los videojuegos. Una de las principales plataformas de videojuegos, Steam, publica datos referidos a los usuarios conectados, usuarios jugando a algún videojuego ejecutado desde la plataforma y los juegos más demandados. A su vez, también existen varios desarrolladores que recopilan la información, la analizan y la ponen a disposición en sus páginas web.

El trabajo inicialmente consistió en explorar la información proporcionada por cada uno de los distintos desarrolladores con acceso a la API de Twitch, para recolectar datos. Posteriormente, se redujo y homogeneizó las categorías y los datos referidos a la plataforma para seleccionar las variables adecuadas para llevar a cabo un análisis de la evolución de la oferta y demanda de contenidos en Twitch. Por último, se aplican dos técnicas de evaluación de impacto para comprobar y estimar el efecto de la pandemia (tratamiento) en la cantidad de visualizaciones de la plataforma de streaming en vivo.

### **Fuentes de recolección**

En la tabla 1 se pueden observar las fuentes de información, de desarrolladores reconocidos por Twitch, que se consultaron y de las que se extrajo (de forma manual, no automatizada) los datos de interés referidos a métricas de la plataforma.

**Tabla 1**

*Desarrolladores reconocidos por Twitch, que publican información y métricas de la plataforma.*

<b>Desarrollador</b>	<b>Referencia</b>	<b>URL</b>
TwitchTracker	Plataforma web para visualizar de forma gráfica y dinámica datos referentes a la plataforma Twitch.	<a href="https://twitchtracker.com/">https://twitchtracker.com/</a>
SullyGnome	Plataforma web creada por David (SullyGnome), para visualizar de forma gráfica y dinámica, datos y análisis estadísticos referentes a la plataforma Twitch.	<a href="https://sullygnome.com/">https://sullygnome.com/</a>
Twitch Insights	Plataforma web creada por AlphaDuplo, para visualizar de forma gráfica y dinámica, datos de la plataforma Twitch.	<a href="https://twitchinsights.net/">https://twitchinsights.net/</a>
Streams Charts	Plataforma web propiedad de ESM.ONE, Inc, para visualizar de forma gráfica y dinámica, datos y análisis estadísticos referentes a distintas plataformas de streaming como: Twitch, Trovo, Facebook Gaming, entre otras.	<a href="https://streamscharts.com/">https://streamscharts.com/</a>
SteamDB	Plataforma web con información, gráficos dinámicos y datos disponibles respecto a la plataforma de videojuegos Steam.	<a href="https://steamdb.info/">https://steamdb.info/</a>

*Nota.* Elaboración propia.

### **Datos recolectados**

Entre los datos disponibles en las distintas plataformas de desarrolladores considerados, se seleccionaron determinadas variables que se pueden observar en la tabla 2, por considerarse de interés para el análisis de la evolución de la plataforma.

**Tabla 2**

Variables recolectadas de las plataformas de desarrolladores reconocidos por Twitch, descripción, periodicidad disponible y fuentes de información.

Variable	Referencia	Periodicidad (*)	Fuente
<b>Plataforma Twitch, globales</b>			
VIEWS_A	Cantidad de espectadores promedio al día.	Mensual	TwitchTracker SullyGnome Twitch Insights Streams Charts
VIEWS_P	Cantidad máxima de espectadores concurrentes en un momento determinado.	Diario	
WATCH_TIME	Horas totales de visualización de contenidos.	Por hora	
CH_A	Cantidad promedio de canales transmitiendo de manera concurrente en el día.	mensual	
CH_P	Cantidad máxima de canales transmitiendo de manera concurrente en el día.	mensual	
STREAM_TIME	Total de horas transmitidas en la plataforma en el período de tiempo considerado.	mensual	
GAME	Cantidad de juegos transmitidos en la plataforma (distintas categorías).	diario mensual	
ACT_AFF	Canales afiliados de twitch que se encuentran activos.	mensual	
ACT_PART	Canales partners de twitch que se encuentran activos.	mensual	
NEWACC	Total de cuentas creadas en la plataforma.	diario	
STATUS	Variable referencia de tratamiento, momento previo o posterior a la pandemia. Datos diarios: 11 de marzo de 2020. Datos mensuales: abril 2020.	diario mensual	Twitch Insights Elaboración propia
<b>Plataforma Twitch, categorías de transmisión</b>			
ALL	Cantidad de espectadores promedio al día que visualizan la plataforma (todas las categorías).	mensual	TwitchTracker
JC	Cantidad de espectadores promedio al día que visualizan la categoría de transmisión Just Chatting.	diario	
MC	Cantidad de espectadores promedio al día que visualizan la categoría de transmisión Minecraft.	diario	
FN	Cantidad de espectadores promedio al día que visualizan la categoría de transmisión Fortnite.	diario	
LOL	Cantidad de espectadores promedio al día que visualizan la categoría de transmisión League of Legends.	diario	
CSGO	Cantidad de espectadores promedio al día que visualizan la categoría de transmisión Counter Strike: Global Offensive.	diario	
VAL	Cantidad de espectadores promedio al día que visualizan la categoría de transmisión Valorant.	diario	
APEX	Cantidad de espectadores promedio al día que visualizan la categoría de transmisión Apex Legends.	diario	
<b>Plataforma de videojuegos, Steam</b>			
STEAMU_A	Cantidad promedio de usuarios conectados de forma concurrente.	diario	SteamDB
INGAME	Cantidad promedio de usuarios dentro de un videojuego, a través de la plataforma.	diario	

**Nota.** Elaboración propia.

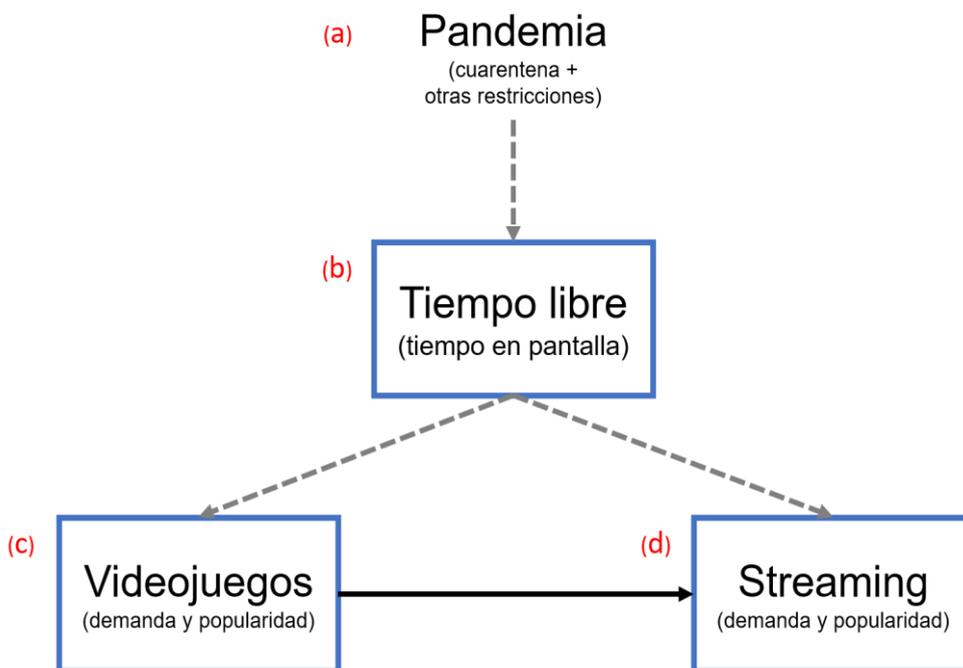
Nota. (\*) Los distintos tipos de periodicidad no se encuentran disponibles para todos los períodos de tiempo. Siendo, en casi todos casos, datos de periodicidad mensual los que se encuentran disponibles para el histórico completo de la plataforma.

## Definición del modelo

En impacto de la pandemia en las plataformas de streaming se dio principalmente a través de una mayor disponibilidad de tiempo libre por parte de las personas que, a su vez, tenían a los dispositivos digitales entre las pocas fuentes de entretenimiento a su disposición dentro de sus casas. Es decir, como se observa en el gráfico 1, la pandemia (a), a través de sus medidas de contención de la propagación del virus, impacta en el tiempo libre (b) de las personas y esto, a su vez (a través de un mayor tiempo en pantalla), tiene un impacto positivo en la cantidad de personas que visualizan las plataformas digitales de entretenimiento en línea; lo que incluye las plataformas de videojuegos (c) y streaming de video online (d).

## Gráfico 1

Relación de variables, vías de impacto de la pandemia en la cantidad de visualizaciones en la plataforma de streaming Twitch.



Nota. Elaboración propia.

La cantidad de tiempo disponible para el entretenimiento (b) y, particularmente el utilizado frente a la pantalla, afecta a nuestra variable dependiente (d) como un “backdoor” abierto (no lo observamos con los datos que disponemos). Incorporando una variable (c) que afecta a nuestra variable dependiente pero también se encuentra afectada por el backdoor identificado, lo podemos considerar. De esta forma, la cantidad de usuarios conectados a la plataforma de videojuegos (c), por su estrecha relación con los contenidos transmitidos (videojuegos) en la plataforma Twitch, sirve de variable para explicar la popularidad de la plataforma de streaming (d) y, a su vez, capturar el efecto que tiene la cantidad de tiempo disponible frente a pantalla (b) por parte de los usuarios (que afecta a la variable independiente

considerada). Aunque sería de interés realizarlo en posteriores investigaciones, en el presente trabajo no aislaremos el efecto causal de la variable explicativa y del backdoor, ya que queremos analizar el impacto global de nuestro tratamiento (a) en la variable dependiente (d).

Se utilizará la variable STEAMU\_A, variable que hace referencia a la cantidad de usuarios conectados a la plataforma Steam (c), como proxy del tiempo disponible en pantalla (b). Es decir, personas que están con la aplicación abierta y “logueados”, pero, en contraste con la variable PLAYERS, no se encuentran dentro de un juego en concreto. Por este motivo, la variable STEAMU\_A, tiene un comportamiento directamente proporcional a la cantidad de tiempo disponible y en pantalla de los usuarios. A medida que una persona disponga de mayor tiempo libre, es más probable que se encuentre logueada a la plataforma de videojuegos. Es decir, que se conecte a la plataforma para evaluar el catálogo de juegos disponibles en su biblioteca personal y/o en la tienda.

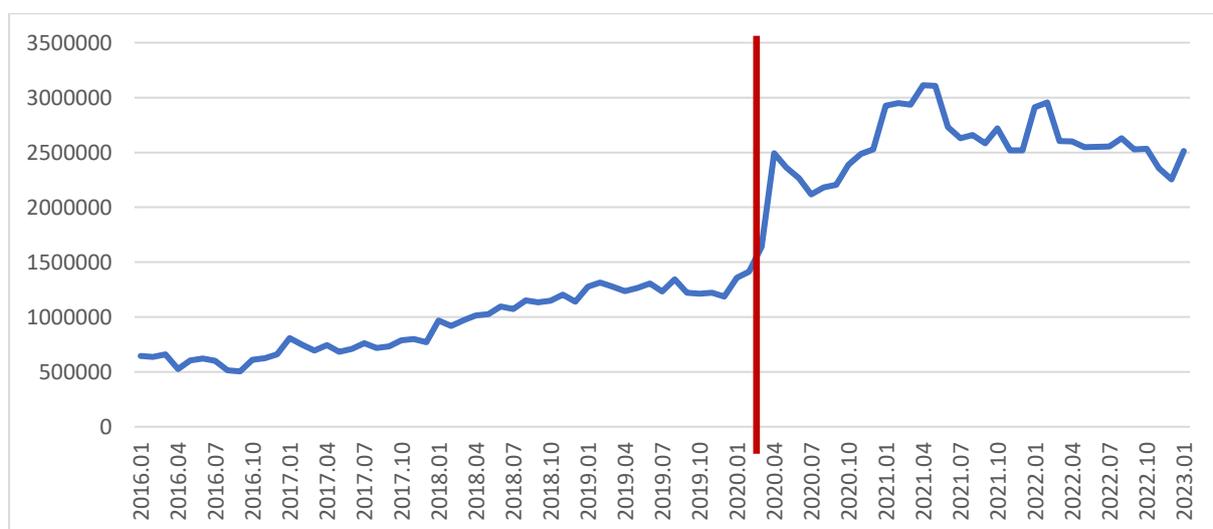
En resumen, debido a la gran interacción del público de Twitch y Steam, si una persona con el perfil de un usuario medio de Steam tiene más tiempo para conectarse/jugar a videojuegos, es razonable suponer que las personas con el perfil de usuarios de Twitch también van a disponer de más tiempo para conectarse a la plataforma de steaming.

### Análisis estadístico

Para llevar adelante los objetivos del estudio, se recopilaron de manera manual los datos, volcándolos en hojas de cálculo, posteriormente, se los analizó con el programa R Studio y, para finalizar, en algunos casos se llevó dichos datos a otros programas como Tableau para una mejor visualización de los mismos.

### Gráfico 2

*Cantidad de visualizaciones concurrentes promedio diario en la plataforma Twitch, datos mensuales, período 2016.01 – 2023.01. Ref. vertical: 2020.03.*



*Nota.* Elaboración propia.

Como podemos observar en el gráfico 2, los datos de cantidad de visualizaciones en la plataforma Twitch tienen un notable “salto” en torno al período de referencia de la pandemia. Es decir, las visualizaciones promedio diarias se vieron incrementadas en períodos posteriores a la declaración de pandemia mundial por parte de la OMS (2020.03).

Para poder evaluar el impacto de las restricciones impuestas en el contexto de pandemia sobre las variables consideradas, se propone realizar:

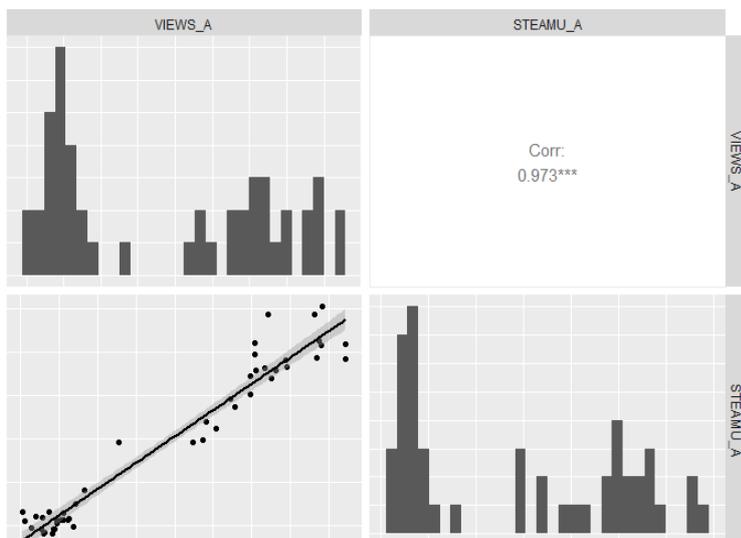
- Análisis descriptivo y visual de las variables, con el objetivo de ver la relación entre las variables y el posible impacto de las restricciones de la pandemia sobre las mismas.
- Especificación del modelo y control del cumplimiento de las condiciones para la regresión lineal y significancia de la misma.
- Cálculo y análisis de la regresión lineal entre las variables.
- Estimación de la discontinuidad en la regresión (RD).
- Estimación de la discontinuidad por diferencia en diferencias (DnD).
- Ejercicios de robustez.

## Resultados

En primer lugar, vamos a establecer un modelo lineal que nos permita analizar el impacto de la pandemia en nuestra variable de interés (VIEWS\_A). La variable STEAMU\_A, proxy de la variable tiempo libre y/o tiempo en pantalla de las personas, se presenta como una buena opción para explicar la dinámica global de la plataforma Twitch. Como se observa en el gráfico 3, la correlación entre ambas variables es de 0,973. Lo que nos permite avanzar con la construcción del modelo lineal.

### Gráfico 3

*Matriz de correlación, gráfico de dispersión e histograma de la variable de interés (VIEWS\_A) y la variable independiente (STEAMU\_A).*



*Nota. Elaboración propia.*

### Estimación del modelo

La variable STEAMU\_A, en nuestro modelo, captura el efecto del impacto pandemia en la cantidad de tiempo disponible por parte de las personas. Como análisis preliminares es necesario ver si esta variable, que se supone relacionada con nuestra variable explicativa, tiene poder predictivo sobre nuestra variable de interés (VIEWS\_A). Para ambas variables se dispone 48 datos mensuales, para el período comprendido por 2018.04 – 2022.03.

Para comprobarlo se estima un modelo de regresión lineal con VIEWS\_A como variable dependiente explicada por STEAMU\_A. Los resultados se presentan a continuación:

Coefficients:	Estimate	Pr(> t )
(Intercept)	-1.153e+06	8.24e-14
STEAMU_A	1.563e-01	< 2e-16
Residual standard error: 171100 on 46 degrees of freedom		
Multiple R-squared: 0.9474, Adjusted R-squared: 0.9462		
F-statistic: 828.4 on 1 and 46 DF, p-value: < 2.2e-16		

Como podemos observar, el modelo tiene una gran capacidad para explicar la variabilidad de la variable de interés (cantidad promedio diaria de visualizaciones en la plataforma Twitch). La regresión lineal simple  $VIEWS \sim STEAMU\_A$ , arroja un  $R^2 = 0,9474$ . Como su nivel de correlación lo permitía suponer, el valor del modelo con STEAMU\_A para explicar VIEWS\_A es bastante elevado. No obstante, únicamente la utilizaremos como variable de control para estimar el impacto de la cuarentena en las visualizaciones de Twitch.

Se hicieron verificaciones de las condiciones necesarias para poder aceptar un modelo lineal. Se comprobó la relación lineal entre las variables (de forma gráfica y con un coeficiente de correlación de 0,973). Los residuos del modelo son independientes de la variable explicativa (covarianza = 0.0004960273). Los residuos están distribuidos normalmente (media = -1.038281e-11; Jarque Bera Test = 0.2716). Se analiza gráficamente la varianza de los residuos y se observa que es aproximadamente constante a lo largo del eje x.

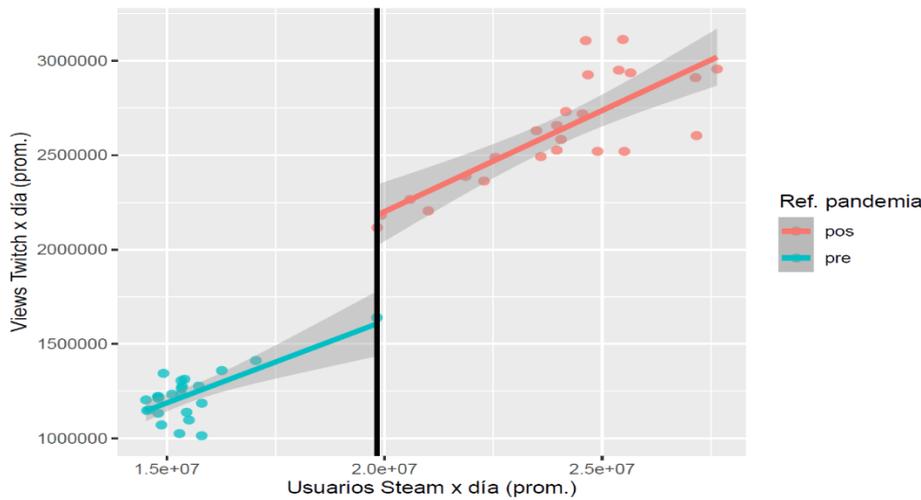
### Estimación de la discontinuidad en la regresión (RD)

Se testea la discontinuidad de la variable independiente, es decir, en la cantidad de visualizaciones en la plataforma Twitch. Para realizar la RD se utilizan datos mensuales desde el mes de abril del 2018 hasta marzo del 2022 (48 observaciones); la idea subyacente es que tenemos 2 períodos (anuales) pre tratamiento (pandemia) y otros dos posteriores.

Como se puede observar en el gráfico 4, existe una clara discontinuidad, por lo que podemos decir que la pandemia (2020.03) tuvo un impacto en la cantidad de visualizaciones de la plataforma. Nos queda averiguar cuál es el tamaño de dicha continuidad, lo cual se estima de forma paramétrica y no paramétrica.

**Gráfico 4**

Testeo visual de discontinuidad de la variable *IEWS\_A*. Se colorean los valores según correspondan a un período antes o posterior a la pandemia.



Nota. Elaboración propia

Para realizar la estimación paramétrica de la discontinuidad, se define el modelo:

$$IEWS\_A = a + b \text{ STEAMU\_A} + c \text{ STATUS} + E$$

Se centra la variable *STEAMU\_A* para analizar el efecto alrededor del umbral, determinado por la variable *STATUS* (asume valores, pre y pos, en referencia a la pandemia).

**Tabla 4**

Comparación estimación paramétrica de la discontinuidad, con distintos anchos de banda (meses) respecto de la fecha de referencia (2020.03).

	Full data	Bandwidth = 12	Bandwidth = 6
(Intercept)	2199159.316 (57262.628)	2144552.525 (45835.848)	2154938.664 (21692.454)
STEAMU_A	0.103 (0.012)	0.130 (0.012)	0.090 (0.009)
STATUSpre	-521610.243 -110015.359	-315769.339 -93409.732	-509992.375 -49462.265
Num.Obs.	48	25	13
R2	0.965	0.978	0.993
R2 Adj.	0.963	0.976	0.992
AIC	1279.5	653.3	320.9
BIC	1287.0	658.2	323.1
Log.Lik.	-635.753	-322.660	-156.438
F	618.835	498.171	728.276
RMSE	136749.39	97487.03	40731.74

Nota. Elaboración propia

Como se puede observar en la tabla 4, los valores de la discontinuidad de los distintos anchos de banda no difieren mucho; a excepción del año de banda intermedio de 12 meses alrededor de la fecha de la pandemia, la que probablemente por la dispersión de los datos, estima un menor efecto negativo/positivo de la pandemia.

Esto se puede interpretar como que, utilizando todos los datos y con un ancho de banda de 6 meses antes y después de la pandemia, se observa que (a) el valor medio de las visualizaciones en el umbral es de 2.199.159 (todos los datos) y 2.154.938 (rango de 6 meses), representando el valor sobre el tratamiento. En el caso de considerar un período inmediato anterior a la fecha del tratamiento (c) el impacto del tratamiento es de 521.610 (todos los datos) y 509.992 (rango de 6 meses).

Esta situación puede ser interpretada como que en marzo del 2020 el promedio de las visualizaciones fue de 1.677.549 (todos los datos) y, el mes siguiente (pos pandemia), el promedio de las visualizaciones sufrió un incremento de 521.610 (31%). Estos resultados se condicen en el análisis completo de los datos, con el ancho de banda de 6 meses y con la representación gráfica de la discontinuidad (en la que se usó todos los datos) y, en el umbral de 6 meses, se verifica una situación similar. En el caso del ancho de banda de 12 meses este efecto se reduce al 17,3%.

A su vez, en el entorno del umbral, una mayor cantidad de usuarios conectados en la plataforma de Steam (b), aumenta la cantidad de visualizaciones en la plataforma Twitch. El valor de este aumento es de 0.103 (todos los datos), 0.130 (12 meses) y, 0.090 (6 meses) por cada usuario extra conectado en dicha plataforma de videojuegos.

### **Calculo por diferencia en diferencias**

Los modelos Diff-in-Diff (DnD), o de Diferencia en Diferencias, permiten realizar un análisis controlando la variable tiempo (respecto de la variable). Es decir, cuál es el impacto del tratamiento restando la dinámica propia de nuestra variable de interés observada previamente a que se implemente el tratamiento.

Un estudio previo de Scerbakov et al (2022), realiza un análisis del impacto del COVID-19 en una muestra de streamers establecidos en la plataforma con anterioridad a la pandemia, para poder estimar cómo les afectó la misma. Para estimar este efecto de tratamiento, realizan una diferencia de medias (impacto) entre distintos períodos de tiempo comprendidos por los mismos meses (reduciendo el sesgo temporal, por ejemplo, de fluctuaciones estacionales en el comportamiento de transmisión), antes y después de la pandemia.

En este sentido, para poder utilizar la técnica Diff-in-Diff se utilizará como grupo de control un período similar al período a evaluar, pero referido a un año anterior. De esta forma, se establecen dos períodos a considerar:

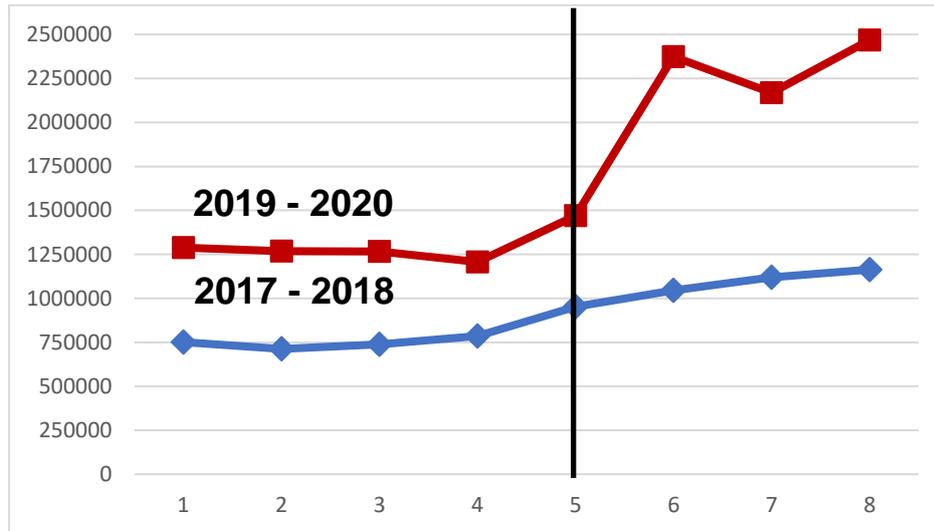
- Período control: enero 2017 - diciembre 2018 (24 meses).

- Período tratamiento: enero 2019 – diciembre 2020 (24 meses).

La principal diferencia con los períodos escogidos para realizar la RD, es que tenemos menos observaciones pos tratamiento (9 meses, abril 2020 – diciembre 2020). Esta selección reducida de los datos pos tratamientos se hace para poder realizar el supuesto de tendencias paralelas que permita la aplicación de la técnica Diferencia en Diferencias para el análisis.

### Gráfico 5

Supuesto de tendencias paralelas, cantidad de visualizaciones, datos trimestrales de los períodos 2019 – 2020 (tratamiento) y 2017 – 2018 (control). Ref. vertical: 2020.03.



Nota. Elaboración propia.

Como se puede observar en el gráfico 5, que a fines de suavizar el gráfico se encuentra en escala trimestral a pesar que se trabaja con datos mensuales, es razonable suponer que se cumple el supuesto de tendencias paralelas. La cantidad de visualizaciones de ambos períodos se vienen comportando de manera similar (evolución paralela), hasta el período posterior al tratamiento en el que la cantidad de visualizaciones diverge notablemente.

En primer lugar, se corre una regresión considerando únicamente el período de tratamiento respecto de la variable tratamiento.

Coefficients:	Estimate	Pr(> t )
(Intercept)	1109442	3.17e-15
treatment	1226987	1.48e-13
Residual standard error: 115400 on 16 degrees of freedom		
Multiple R-squared: 0.9695, Adjusted R-squared: 0.9676		
F-statistic: 509 on 1 and 16 DF, p-value: < 1.482e-13		

Como se puede observar, existe una diferencia en la media de las observaciones afectadas por el tratamiento y las que se encuentran previamente.

Para poder realizar la diferencia en diferencias en un primer momento calculamos diferencia de medias entre el grupo tratamiento y grupo de control, considerando el período

posterior al tratamiento (abril 2020 – diciembre 2020 y abril 2018 – diciembre 2018). Es decir, uno va a estar afectado por el tratamiento y el otro no.

Diferencia pos tratamiento:  $DF_{pos} = 1.226.987$

A continuación, se calcula la diferencia de medias entre el grupo tratamiento y grupo de control, considerando el período previo al tratamiento (enero 2017 – marzo 2018 y enero 2019 – marzo 2020). En este caso, ninguno de los dos se ve afectado por el tratamiento.

Diferencia pre tratamiento:  $DF_{pre} = 512.334$

Por último, solo queda calcular la diferencia de las diferencias calculadas.

Diferencia en diferencias:  $DnD = 714.652$

El valor de la Diferencia en Diferencias es de 714.652, lo que teniendo en cuenta los valores alrededor del umbral de corte (1.639.798 y 2.492.780) nos da un incremento de 40,2% y 43,6%. El resultado, sensiblemente superior al obtenido con la Regresión Discontinua (+10%), puede deberse principalmente a que se utilizaron menos observaciones pos pandemia (24 observaciones en RD, 9 observaciones en DnD). Es decir, por darle una mayor ponderación de análisis a los valores cercanos al umbral.

Al realizar un análisis de regresión Diff-in-Diff obtenemos el mismo resultado que la diferencia de medias calculadas anteriormente y con significancia estadística.

### **Ejercicios de robustez**

Siguiendo el trabajo de Scerbakov et al. (2022), se realizan unas pruebas de diferencia de medias pareadas y no pareadas, con dos períodos pre pandemia (pre 1: 2018.04 - 2019.03 y, pre 0: 2019.04 - 2020.03) y dos períodos pos pandemia considerados (pos 1: 2020.04 - 2021.03 y, pos 2: 2021.04 - 2022.03). A través de la prueba de diferencia de medias de muestras pareadas, se compara cada valor/mes con el mismo valor/mes referido al período/año posterior o anterior, y así se comprueba la existencia de una diferencia de medias en los distintos períodos considerados eliminando cualquier posible variación estacional. Hay diferencia en todos los períodos considerados, observándose la mayor diferencia en el período inmediato posterior y previo a la pandemia (1.183.450 visualizaciones promedio), la menor de las diferencias se da entre los dos períodos pre pandemia (148.921,9), seguido por los dos períodos pos pandemia (267.559,8). Todas las diferencias son significativas estadísticamente. Es decir, la pandemia provocó un incremento en la diferencia de medias de los períodos inmediatos anterior y posterior.

Algunos ejercicios de robustez pueden ser, (1) usar la misma serie analizada, pero en otros períodos de igual longitud y composición, para ver si presenta la misma discontinuidad o, (2) realizar el mismo análisis, pero en otras series relacionadas como, en vez del total de la plataforma, analizar el comportamiento de las categorías de contenidos emitidos o los de otra plataforma. En este segundo caso, las distintas categorías de videojuegos, al tener una

dinámica propia, no es de esperar que presenten el mismo comportamiento que el total de la plataforma e inclusive puede que no se vean afectadas por el tratamiento. Estos ejercicios, se dejan para un trabajo posterior en el que se compare la evolución de las distintas categorías contrastándola con la evolución global de la plataforma. A continuación, se realizarán ejercicios de robustez teniendo en cuenta distintos períodos de la serie original analizada.

Para realizar el ejercicio de robustez de la técnica de diferencias en diferencias, de igual manera que en el ejercicio original, se considerarán dos períodos de igual longitud y comportamiento similar (tendencias paralelas) previo al tratamiento:

- Período control: enero 2015 - diciembre 2016 (24 meses).
- Período tratamiento: enero 2017 – diciembre 2018 (24 meses).

El tratamiento afecta a los últimos ocho meses del período tratamiento, es decir, del mes 17 al 24. No obstante, en este ejercicio no se puede considerar todo el período (24 meses) porque en el séptimo mes del primer período (control) tenemos una caída atípica. Si bien en este ejercicio de robustez no hay tratamiento, este valor atípico no es en el mismo sentido que el cambio provocado por el tratamiento. Por lo tanto, se consideran los primeros seis trimestres de cada período considerado, cinco dentro del período sin tratamiento y un trimestre posterior.

En primer lugar, calculamos diferencia de medias entre el grupo tratamiento y grupo de control:

Diferencia pos tratamiento:  $DF_{pos} = 405405$

A continuación, se calcula la diferencia de medias entre el grupo tratamiento y grupo de control, considerando el período previo al tratamiento:

Diferencia pre tratamiento:  $DF_{pre} = 227519.1$

Por último, solo queda calcular la diferencia de las diferencias calculadas:

Diferencia en diferencias:  $DnD = 177885.9$

El valor resultante es considerablemente menor al obtenido en el ejercicio original y, si realizamos un análisis de regresión Diff-in-Diff obtenemos el mismo resultado que la diferencia de medias calculadas anteriormente y con significancia estadística al 95%. Mientras que, no se encuentra significancia estadística para los efectos del período pos tratamiento.

Para poder realizar ejercicios de robustez con la técnica diferencias en diferencias se analizó la utilización de varios períodos de tiempo, pero en la mayoría de los casos eran heterogéneos dificultando la comparación con el período utilizado en el análisis original. No obstante, en todos los casos el efecto tratamiento se reducía y era insignificante estadísticamente acotándolo al período posterior.

### **Discusión metodológica**

Los resultados obtenidos en el análisis global de la plataforma Twitch muestran una reacción positiva inmediata, en términos de cantidad de personas conectadas de manera

concurrente, a los efectos de la pandemia del COVID-19. Esta situación contrasta con los resultados obtenidos por Scerbakov et al. (2022) para los streamers establecidos en la plataforma con anterioridad a la pandemia. El trabajo de Scerbakov et al. (2022) se utilizó de referencia metodológica para considerar distintos períodos respecto de la pandemia (antes, inmediatamente después y después) y realizar una comparación de medias. Posteriormente, se adoptó el criterio metodológico de parear las observaciones con períodos referidos a otros años para considerar un grupo de control aplicable en la técnica Diferencia en Diferencias.

Se analizaron las relaciones entre las distintas variables referidas a la plataforma Twitch (VIEWS\_A, VIEWS\_P, WATCH\_TIME, CH\_A, CH\_P, STREAM\_TIME, GAME, ACT\_AFF, ACT\_PART, NEWACC), principalmente referidos a la cantidad de personas creando contenido y la cantidad de personas visualizándolo. Como era de esperar, el nivel de correlación entre estas variables es muy elevado y, más allá de que teóricamente es muy difícil establecer una dirección única de causalidad, las definiciones de modelo lineal con estas variables no dieron resultados correctos. Por otro lado, se analizan los datos de las visualizaciones promedio de las categorías de contenidos históricamente más importantes de la plataforma (ALL, JC, MC, FN, LOL, CSGO, VAL, APEX) y, a excepción de Just Chatting (charla en vivo) y League of Legends (juego de estrategia), el crecimiento y evolución de las distintas categorías de contenido y el global de la plataforma están muy poco relacionadas.

La relación entre las variables STEAMU\_A, referida a videojuegos (cantidad de personas conectadas a la plataforma Steam), y la variable de interés VIEWS\_A (cantidad de personas concurrentes en la plataforma Twitch), es muy fuerte:  $VIEWS \sim STEAMU\_A$ , arroja un  $R^2 = 0,9474$ . Se estable un modelo lineal y se hace un análisis detallado de los residuos del modelo aceptando su independencia, media igual a cero, homocedasticidad y normalidad. No se puede asumir la no autocorrelación de los residuos, algo que puede estar relacionado al uso de series de tiempo, no obstante, gráficamente no se observa un patrón lineal de comportamiento. Por lo tanto, existe una relación directa entre la industria de videojuegos y la plataforma de streaming online Twitch, que desde sus inicios está muy ligada a dicha industria.

Al analizar el modelo establecido se puede observar una clara discontinuidad de la variable respecto del tratamiento (11 de marzo del 2020) y se procede a estimar una Regresión Discontinua (RD). Teniendo 24 observaciones antes y 24 observaciones posteriores al tratamiento, se corre una RD con distintos anchos de banda (24 meses, 12 meses y 6 meses). Los valores son muy similares, especialmente para los 24 meses y 6 meses, el impacto promedio observado por la pandemia alrededor del umbral fue del 30%.

A continuación, se realizó un análisis de diferencia en diferencias (DnD), con el grupo de control establecido en un período, de igual longitud, previo al período considerado. La utilización de un período previo como control nos limita la longitud bajo tratamiento de nuestro

grupo de tratamiento considerado (24 meses, al igual que en RD, pero únicamente 9 meses bajo tratamiento). Esto puede explicar que los resultados de DnD sean sensiblemente superiores a los observados en la RD, evidenciando un impacto del 40%. El impacto inmediato es muy elevado, pero al considerar el impacto en un período mayor (como en RD) dicho impacto se reduce, pero es persistente el resto del período considerado.

El presente estudio es una primera aproximación al impacto de la pandemia en la plataforma Twitch, se requieren otros estudios para poder tener mayor certeza de la cuantía del impacto inmediato y de corto plazo. No obstante, si bien los resultados de este estudio nos permiten observar que efectivamente hubo un impacto positivo en la cantidad de visualizaciones de la plataforma, el resultado hallado más interesante es que existe un cambio de nivel y de tendencia que se mantienen hasta la fecha. Este estudio, con datos globales de Twitch y otra plataforma de entretenimiento en línea como Steam, encuentra resultados similares a los obtenidos por Scerbakov et al. (2022) con datos para streamers establecidos. Estos resultados sugieren que los efectos iniciales de la pandemia fueron mucho más rápidos (aumento más profundo) que los prolongados (aumento menos profundo pero persistente).

## **CONCLUSIONES**

Los efectos de la pandemia de COVID-19, a través de las restricciones a la movilidad implementadas por los distintos países del mundo, tuvieron un impacto en el comportamiento de consumo de entretenimiento en línea. En el caso de la plataforma online de transmisiones en vivo, Twitch, la misma experimentó un cambio de nivel provocado por un incremento inicial positivo en la cantidad de personas conectadas de manera concurrente de entre el 30 y 40% y, luego se estabilizó en una tendencia similar a la observada en períodos previos a la pandemia. En este sentido, se destaca la persistencia de este “boom” de la cuarentena en Twitch, es decir, que gran parte de las personas que llegaron en la pandemia no se fueron de la misma a medida que nos alejamos temporalmente de dicho acontecimiento. Este cambio de nivel persistente, aun cuando la tendencia se estabiliza en un crecimiento similar al de períodos anteriores al tratamiento, sugiere un cambio en el comportamiento de consumo de entretenimiento en línea que se ha vuelto una parte integral de la cultura de entretenimiento. A diferencia de otros consumos que, durante la cuarentena reemplazaron a otros, Twitch ha logrado crear y mantener una base de usuarios sólida. No obstante, cabe destacar las limitaciones del presente trabajo para explicar y predecir la dinámica de la plataforma en períodos cada vez más alejados a la pandemia, especialmente en los más recientes.

La dinámica de comportamiento de los datos globales de la plataforma Twitch, y el crecimiento observado producto del tratamiento, presentan una fuerte correlación positiva con el crecimiento observado en la categoría de contenidos Just Chatting. Por otro lado, las categorías de contenidos relacionadas a videojuegos, que son más tradicionales en la

plataforma, si bien se ven afectadas en alguna medida por el comportamiento de la misma, tienen su propia dinámica más relacionada a la popularidad del videojuego en cuestión. Esta situación sugiere que se debe estudiar la evolución de cada una de las categorías de manera independiente, especialmente la categoría Just Chatting (de charla en vivo) y las de IRL (In Real Life). El análisis del crecimiento sostenido de estas categorías, muy correlacionados con el observado por la plataforma, sugieren que podría ser fructífero para futuras investigaciones profundizar en el por qué esta categoría en particular experimentó un crecimiento sostenido. Además, dada la naturaleza del contenido de la categoría Just Chatting, es de interés estudiar el rol que tiene en su éxito la interacción del emisor con la audiencia, e inclusive entre miembros de la audiencia, dando lugar a la formación de comunidades.

El presente trabajo estudió el comportamiento de la plataforma Twitch a través de la demanda de contenidos (audiencia), pero resulta de especial interés un análisis sobre la dinámica de los creadores de contenido (streamers). La variable referida a la cantidad streamers activos en la plataforma se encuentra muy correlacionada a la cantidad de visualizaciones, por lo que una investigación más a fondo de esta relación podría arrojar luz sobre la importancia de atraer y retener a los creadores de contenido. Comprender cómo la plataforma puede fomentar un entorno atractivo para los streamers podría ser importante para mantener su dinámica de crecimiento continuo.

Por último, cabe destacar las limitaciones del presente trabajo para explicar y predecir la dinámica de la plataforma en períodos cada vez más alejados al tratamiento, especialmente en los más recientes. En este sentido, se destacan los resultados obtenidos para comprender el impacto de la pandemia tanto su nivel como en la tendencia inmediata posterior. No obstante, es importante tener en cuenta que la dinámica de la plataforma Twitch puede continuar evolucionando a medida que se supera la pandemia y se pueden requerir investigaciones adicionales para comprender plenamente estas dinámicas cambiantes.

## REFERENCIAS BIBLIOGRÁFICAS

- Aguilar Del Castillo, A. (2021). *Las plataformas digitales tras el Covid-19: Las nuevas tendencias y hábitos de consumo del entretenimiento*. Lima: Universidad Peruana de Ciencias Aplicadas. <http://hdl.handle.net/10757/657569>
- Brynjolfsson, E., Collis, A., y Eggers, F. (2019). Using massive online choice experiments to measure changes in well-being. *Proceedings of the National Academy of Sciences of the United States of America*, 116(15), 7250-7255. <https://doi.org/10.1073/pnas.1815663116>
- Brynjolfsson, E., Eggers, F., y Collis, A. (2018). Measuring Welfare with Massive Online Choice Experiments: A Brief Introduction. *American Economic Association Papers and Proceedings*, 473-476. <http://hdl.handle.net/1721.1/120171>

- Chae, S. W., y Lee, S. H. (2022). Sharing emotion while spectating video game play: Exploring Twitch users' emotional change after the outbreak of the COVID-19 pandemic. *Computers in Human Behavior*, 131, 1-11. <https://doi.org/10.1016/j.chb.2022.107211>
- Cusumano, M., Gawer, A., y Yoffie, D. (2021). Can Self-Regulation Save Digital Platforms? *Industrial and Corporate Change*, 1-36. <https://doi.org/10.2139/ssrn.3900137>
- Ferrarelli, M. (2016). Henry Jenkins, Sam Ford y Joshua Green, *Cultura transmedia: La creación de contenido y valor en una cultura en red*, Madrid, Gedisa, (2015). *Perspectivas Metodológicas*, 16(17), 161-162. <https://doi.org/10.18294/pm.2016.1064>
- Gawer, A. (2021). *Online Platforms: Societal Implications of the New Dominant Business Models of the Digital Economy*. Berlin: Hertie School. <https://digitalage.berlin/>
- Giertz, J. N., Weiger, W. H., Törhönen, M., y Hamari, J. (2022). Content versus community focus in live streaming services: how to drive engagement in synchronous social media. *Journal of Service Management*, 33(1), 33-58. <https://doi.org/10.1108/JOSM-12-2020-0439>
- Gómez-Carmona, D., Cano Tenorio, R., y Marín Dueñas, P. (2022). El efecto de la COVID-19 en la aceptación de uso de Twitch. En S. Olivero Guidobono, *El camino hacia las sociedades inclusivas* (págs. 1062-1083). Madrid: Dykinson. <https://dialnet.unirioja.es/servlet/articulo?codigo=8772332>
- Hamilton, W. A., Garretson, O., y Kerne, A. (2014). Streaming on Twitch: Fostering Participatory Communities of Play within Live Mixed Media. *CHI 14: Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (págs. 1315-1324). Toronto: CHI 14. <https://doi.org/10.1145/2556288.2557048>
- Hilvert-Bruce, Z., Neill, J. T., y Hamari, J. (2018). Social motivations of live-streaming viewer engagement on Twitch. *Computers in Human Behavior*, 58-67. <https://doi.org/10.1016/j.chb.2018.02.013>
- Johnson, M. R., y Woodcock, J. (2018). The impacts of live streaming and Twitch.tv on the video game industry. *Media, Culture and Society*, 1-28. <https://doi.org/10.1177/0163443718818363>
- Laming, C. (20 de diciembre de 2020). *El efecto de COVID-19 en Twitch y qué juegos son los mejores para transmitir*. <https://charleslaming.github.io/covid-and-twitch/>
- Matei, A. (2022). Streaming Wars. La nueva televisión [Reseña]. *Revista Mediterránea de Comunicación*, 1(12), 1-3. <https://doi.org/10.14198/MEDCOM.21152>
- Organización Mundial de la Salud (OMS). (29 de junio de 2020). *COVID-19: cronología de la actuación de la OMS*. Recuperado el 18 de septiembre del 2023 de <https://www.who.int/es/news/item/29-06-2020-covid-timeline>

- Padilla Molina, A., y Navarro, C. (2022). Audiencias y streamers en Twitch: patrones de consumo y producción en el ámbito hispanohablante. *Quaderns del CAC*, 25(48), 67-77. <https://www.cac.cat/es/documentacio/comunicacion-riesgos-crisis-y-conflictos>
- Pineiro-Chousa, J., Lopez-Cabarcos, M., Pérez-Pico, A. M., & Caby, J. (2023). The influence of Twitch and sustainability on the stock returns of video game companies: Before and after COVID-19. *Journal of Business Research*, 1-10. <https://doi.org/10.1016/j.jbusres.2022.113620>
- Scerbakov, A., Pirker, J., y Kappe, F. (2022). When a Pandemic Enters the Game: The Initial and Prolonged Impact of the COVID-19 Pandemic on Live-Stream Broadcasters on Twitch. *Proceedings of the 55th Hawaii International Conference on System Sciences*, 1-10. <http://hdl.handle.net/10125/79725>
- Sjöblom, M., y Hamari, J. (2016). Why Do People Watch Others Play Video Games? An Empirical Study on the Motivations of Twitch Users. <https://doi.org/10.2139/ssrn.2779543>
- Zhao, K., Yuheng, H., Hong, Y., y Westland, J. C. (2020). Understanding Characteristics of Popular Streamers on Live Streaming Platforms: Evidence from Twitch.tv. *Journal of the Association for Information Systems*, 22(4), 1-45. <https://doi.org/10.17705/1jais.00689>

## RESUMEN BIOGRÁFICO

### Nicolás Alvarez

Licenciado en Economía por la Universidad Nacional de Misiones y Especialista en Tecnologías de Información para Gobierno Digital por la Universidad Nacional del Sur. Actualmente Becario doctoral en el Instituto de Investigaciones Económicas y Sociales del Sur (IIESS CONICET-UNS).