UNIVERSIDAD
TORCUATO DI TELLA

Tipo de documento: Tesis de Maestría

Departamento de Economía. *Maestría en Economía*

Paycheck Protection Program: Análisis de la Recuperación del Empleo en Compañías Públicas

Autoría: Maiorano, Romina Antonella
Año: 2024

¿Cómo citar este trabajo?
Maiorano, R. (2024) "*Paycheck Protection Program: Análisis de la Recuperación del Empleo en Compañías Públicas*". [Tesis de Maestría. Universidad Torcuato Di Tella]. Repositorio Digital Universidad Torcuato Di Tella
https://repositorio.utdt.edu/handle/20.500.13098/13220

El presente documento se encuentra alojado en el Repositorio Digital de la Universidad Torcuato Di Tella bajo una licencia Creative Commons Atribución-No Comercial-Compartir Igual 4.0 Argentina (CC BY-NC-SA 4.0 AR)
Dirección: https://repositorio.utdt.edu

Biblioteca Di Tella

Universidad Torcuato Di Tella

Departamento de Economía

Maestría en Economía

Paycheck Protection Program:

Análisis de la Recuperación del Empleo en Compañías Públicas

Autora: Romina Antonella Maiorano

Legajo: 20H1384

Tutor: Prof. Ph.D. Hernán Ruffo

Julio 3, 2024

Abstract

El objetivo de este trabajo es realizar una evaluación de impacto del programa "Paycheck Protection Program" o "Programa de Protección de Pagos" (*PPP* o *el Programa*). Este programa fue anunciado y promulgado durante el primer trimestre de 2020 por el gobierno de los Estados Unidos de América en respuesta a la crisis económica desencadenada por la pandemia de COVID-19. El programa tuvo como objetivo reducir el impacto negativo de la crisis sobre el nivel de empleo y sobre las nóminas de empresas estadounidenses pequeñas y medianas a través de líneas de crédito otorgadas por bancos privados estadounidenses. El análisis realizado en este trabajo descansa sobre el uso de métodos de diferencias en diferencias (DiD), que estima el efecto causal del programa al comparar los cambios en el nivel de empleo entre firmas potencialmente elegibles y firmas que accedieron a la línea de créditos, para diferentes períodos antes y después de la recepción de los fondos del PPP, permitiendo estimar de forma aislada el efecto causal del programa sobre el empleo en las compañías públicas. Para el análisis se utilizaron datos observacionales de compañías públicas estadounidenses elegibles para participar del programa. Los resultados encontrados indicarían un efecto de mediano plazo negativo sobre el nivel de empleo para las compañías públicas que accedieron al programa. En promedio, se estima una reducción de entre 5 y 15 empleados para los tres años subsiguientes a la aplicación al programa para las compañías que recibieron el programa.

Contenidos

1. Introducción 3

2. Metodología 11

2.1. Distribución de panel 12

2.2. Resultados potenciales 12

2.3. Parámetro de interés 14

2.4. Supuestos 15

2.5. Identificación de los estimadores 18

2.5.1. Estimador DiD Doblemente Robusto 18

2.5.2. Estimador DiD Doblemente Robusto para múltiples períodos 23

3. Identificación de unidades de observación 26

3.1. Compañías públicas potencialmente elegibles 26

3.2. Participación en M&A como fuente de heterogeneidad en el efecto de tratamiento 30

4. Aplicación y resultados 34

4.1. DRDiD: Estimación por Sant'Anna & Zhao (2020) 34

4.2. CSDiD: Estimación por Callaway & Sant'Anna (2021) 36

5. Conclusión 41

6. Bibliografía 43

1. Introducción

El 27 de marzo de 2020, el Presidente de los Estados Unidos de América firmó la *Ley de Ayuda, Alivio y Seguridad Económica del Coronavirus* (*Ley CARES, por sus siglas en inglés*) con el propósito de proporcionar asistencia de emergencia y respuesta sanitaria para individuos, familias y empresas afectadas por la pandemia de coronavirus. Como parte de este paquete de ayuda, la Administración de Pequeñas Empresas (*SBA, o Small Business Administration*) recibió fondos y autoridad para establecer un nuevo programa de préstamos destinado a ayudar a pequeñas empresas en todo el país, que se habían visto afectadas adversamente por la crisis económica desencadenada a partir de la pandemia de COVID-19. La Sección 1102 de la Ley CARES otorgó autoridad temporal a la SBA para distribuir préstamos bajo este nuevo programa titulado "*Programa de Protección de Pagos*" o "*Paycheck Protection Program*" (*PPP* o *el Programa*).

El PPP permitió que pequeñas empresas y otras organizaciones que cumplían con los requisitos establecidos por la SBA recibieran préstamos con un vencimiento de dos años y una tasa de interés del uno por ciento. Bajo el PPP, tanto el interés como el monto principal, serían completamente condonados por la SBA en caso de cumplirse todos los criterios de retención de empleados (*el empleador debía mantener o volver a contratar a sus empleados en caso de observar despidos, al mismo tiempo manteniendo los niveles salariales*) y en caso de que los fondos se utilizaran para gastos elegibles, tales como costos

salariales (al menos el 60 por ciento del monto condonado debía haber sido destinado a pagos de nómina), intereses de hipotecas, pagos de alquileres o servicios públicos. En el caso en el que la cantidad de empleados a tiempo completo se viera disminuida, o en caso de que los salarios y sueldos se vieran afectados negativamente, la condonación del préstamo se vería reducida.

De acuerdo con los objetivos delineados por la SBA, este programa fue diseñado para proveer un incentivo directo a pequeñas firmas a mantener sus empleados en nómina y minimizar la disrupción de sus puestos laborales. Los préstamos se administraron a través de la Small Business Administration (SBA) y se otorgaron a través de bancos y otras instituciones financieras participantes. Para incentivar la participación de los bancos, estos podían aplicar honorarios que ascendían al 5 por ciento del principal para préstamos de hasta $350,000 dólares, el tres por ciento en préstamos otorgados de entre $350,000 dólares y $2,000,000 de dólares, y el uno por ciento en préstamos desde $2,000,000 de dólares a $10,000,000 de dólares.

La discrecionalidad con la que este programa permitió operar a los bancos participantes generó ciertas inquietudes acerca del proceso de selección y prioritización de compañías seleccionadas a participar en el programa. La cantidad de préstamos aprobados durante 2020 alcanzó los 11,484,457 préstamos, los cuales representan un monto aprobado de $522 mil millones de dólares estadounidenses (Schweitzer & Guo, 2023).

Si bien se estima que el programa ayudó a preservar entre 2 y 3 millones de trabajos-por-año a lo largo de los 14 meses durante los cuales se aplicó el programa, solo entre el 23 y 34 por ciento de los fondos fueron percibidos directamente por trabajadores que, de otro modo, hubieran perdido sus empleos (Autor et al., 2022). A pesar de que el programa cumplió el objetivo de ser una fuente rápida de financiamiento ante una situación económica crítica e inmediata (Hubbard & Strain, 2020), diferentes estudios estiman en qué medida la falta de precisión a la hora de seleccionar a las firmas beneficiarias generó una incidencia altamente regresiva del programa en comparación con otros paquetes estímulo (Autor et al., 2022).

En cuanto a la literatura existente en cuanto a la evaluación del programa, podemos dividir los estudios disponibles en dos partes. En primer lugar, algunos estudios se enfocan en el proceso de asignación y obtención de las líneas de crédito. De acuerdo con los resultados presentados en Duchin et. al, (2021), la probabilidad de obtener un préstamo dentro del programa se veía aumentada entre un 8 y un 9.3 por ciento cuando existía una conexión personal entre profesionales de los bancos prestamistas y los representantes de las firmas prestatarias. Este efecto se ve debilitado en el caso de analizar firmas con mayor escrutinio o presencia pública o en los medios. En cuanto al carácter discrecional de otorgamiento de los préstamos, en Chernenko & Scharfstein, (2021), se encuentra que existe también un componente de discriminación racial al analizar la participación de

firmas pequeñas. Los autores analizan una muestra de restaurantes domiciliados en Florida, y estiman, a partir de datos administrativos y reseñas de los restaurantes, que restaurantes cuyos dueños pertenecen a la comunidad negra tenían un 25 por ciento menos de chances de recibir el préstamo por el programa de PPP (Chernenko & Scharfstein, 2021).

Siguiendo esta misma línea, utilizando información obtenida a través de encuestas realizadas a más de 14,000 pequeñas empresas, en Humphries et al., (2020) se encuentra evidencia que indicaría que las fricciones informativas que generó el diseño del programa jugaron un papel importante en la determinación del acceso diferencial a los recursos del PPP entre las empresas pequeñas en relación a las empresas grandes. Estas fricciones, relacionadas con que los fondos se asignarían por orden de llegada (*first come, first served basis*), son más restrictivas para las empresas pequeñas debido a un menor grado de sofisticación administrativa. Los resultados también muestran que la menor cantidad de tasas de solicitud, los tiempos de procesamiento más largos y, en última instancia, el menor acceso a los programas pueden haber tenido consecuencias negativas para las empresas de menor escala. La falta de acceso al PPP está asociada, además, con resultados de rendimiento sustancialmente peores para pequeñas más empresas. Algunos ejemplos son una mayor cantidad de despidos y una mayor probabilidad percibida de quiebra, y peores expectativas generales sobre la recuperación de sus negocios.

En segundo lugar, otros trabajos estiman el efecto de corto plazo de la política sobre

diferentes medidas de desempeño y recuperación de las firmas que accedieron al programa. En Bartik *et. al*, (2020) se encuentra que el acceso al PPP aumentó la probabilidad de supervivencia de las empresas, tal como lo perciben los representantes de estas firmas, en un rango de 14 a 30 puntos porcentuales. También observan que los bancos asignaron los fondos del PPP a empresas que reflejaron efectos de tratamiento del PPP más altos. Sin embargo, estas empresas también tenían más probabilidades de tener conexiones más fuertes con los bancos, mientras que las empresas con menos caja disponible tenían menos probabilidades ver sus solicitudes aprobadas. Los autores, finalmente, encuentran que el PPP tuvo un impacto positivo pero estadísticamente insignificante en el empleo (Bartik, 2020). Este resultado es consistente con los resultados obtenidos en el presente trabajo.

De acuerdo con lo expuesto en Granja, et. al, (2020), los autores encuentran evidencia de que el efecto del PPP sobre el empleo en los meses posteriores al lanzamiento del programa fue más bien modesto. Los autores teorizan que, si bien el programa puede haber tenido un rol importante en el mantenimiento de la estabilidad financiera de las compañías receptoras, los fondos podrían haber sido utilizados como ahorros precautorios ante la incertidumbre de la duración y magnitud de la crisis del COVID-19, en lugar de ser utilizados para mantener o incrementar el gasto en nóminas (Granja et al., 2020).

Estos resultados son consistentes con lo reportado en otros trabajos que utilizan métodos de identificación que explotan la heterogeneidad observada alrededor del umbral de 500

empleados para estudiar los efectos del programa sobre el nivel de empleo (Autor et al., 2022; Chetty et al., 2020; Hubbard & Strain, 2020). Una de las limitaciones mencionadas en Granja et. al (2020) al respecto de este tipo de análisis es que el resultado podría no ser representativo del efecto del programa sobre firmas que estén alejadas del umbral de los 500 empleados.

El presente trabajo se motiva con el objetivo principal de extender el análisis existente en la literatura (*primordialmente enfocado a compañías privadas, pequeñas, y al período inmediatamente posterior a la aplicación del programa*) a un enfoque de mediano plazo, para compañías que, a pesar de tener un alto nivel de escrutinio público, decidieron aplicar al programa en cuestión.

La contribución principal de este trabajo se puede resumir en tres puntos principales. En primer lugar, y a diferencia de otros estudios que se enfocan en el impacto inmediato tras la implementación del programa, este trabajo se centra en la evolución y recuperación del nivel de empleo en los años posteriores para las compañías que participaron en el programa en relación a las compañías que no participaron.

En segundo lugar, en este trabajo realizaremos una revisión de métodos de estimación novedosos que aprovechan la disponibilidad de una estructura de datos de panel para esta aplicación. El método de diferencias en diferencias (DiD) aplicado a estudios cuasi-experimentales ha sido ampliamente extendido en la literatura econométrica reciente.

Algunas de estas ampliaciones incluyen la extensión del modelo canónico de dos períodos, y dos grupos, al estudio de múltiples períodos temporales y la posterior agregación de dichas estimaciones (Callaway & Sant'Anna, 2021). Los métodos utilizados en este trabajo, bajo el cumplimiento de ciertos supuestos, identifican o estiman el efecto promedio de tratamiento sobre las unidades tratadas.

Por último, y relacionado con el segundo punto, a diferencia de los trabajos existentes sobre el resultado del Programa para compañías públicas (Cororaton & Rose, 2021), o compañías privadas, pequeñas (Fairlie et al., 2021; Rossi et al., 2021; Tasci, 2021), o específicos para ciertas industrias (Chernenko & Scharfstein, 2021), nuestro trabajo busca estudiar si existe evidencia sobre la persistencia del efecto del programa sobre el nivel de empleo en compañías públicas.

Este trabajo se estructura en 6 secciones principales. En la segunda sección del documento, se realizará una revisión del marco metodológico elegido para la evaluación de esta política, que consiste en una revisión sistemática del modelo canónico de diferencias en diferencias, los supuestos que subyacen al modelo y las extensiones que nos interesará analizar.

En la tercera sección, presentaremos una descripción del proceso de identificación de firmas que serán parte del dataset, junto con el método de eliminación de compañías que no califiquen dentro de los estándares propuestos por la SBA.

En el cuarto capítulo presentaremos los resultados obtenidos a partir de la aplicación de dos tipos principales de modelos: diferencias en diferencias a partir del enfoque de dos períodos de Sant'Anna & Zhao (2020), y a partir del enfoque de múltiples períodos de Callaway & Sant'Anna (2021). Los resultados y avances de este trabajo se presentarán de forma sintetizada en la quinta sección.

Finalmente, la sexta y última sección reúne las referencias bibliográficas consultadas para realizar el trabajo.

2. Metodología

En este trabajo se utilizará el método de diferencias en diferencias (DiD) para estimar el efecto del acceso al programa sobre el nivel de empleo en las compañías tratadas.

El método de diferencias en diferencias (DiD) en su forma canónica ofrece una técnica no experimental para estimar el efecto tratamiento promedio sobre los tratados (*ATT - Average Treatment Effect on the Treated*), al comparar la diferencia temporal del promedio de la variable de resultado entre el grupo de control y el grupo de tratamiento. Este método propone utilizar el cambio observado en la variable de interés para el grupo de control como una estimación del contrafáctico verdadero para el grupo de tratamiento. El método de DiD admite la inclusión de controles que incluyan tanto factores observables como no observables, - *estos últimos, siempre que sean constantes en el tiempo, y que sean comunes a ambos grupos (tratamiento y control)* -.

Diferentes extensiones al modelo canónico han sido desarrolladas en trabajos recientes con el objetivo de lograr estimadores más robustos y eficientes (Athey & Imbens, 2021; Callaway & Sant'Anna, 2021; Sant'Anna & Zhao, 2020). A continuación se explicarán las bases de los modelos a utilizar y los supuestos que proponen los autores referenciados para identificar el efecto del tratamiento.

2.1. Distribución de panel

El dataset de este trabajo se estructura como una colección de datos $\{Y_{it}, D_{it}, X_{it}\}_{i=1}^{n}$, $t = 2017,..., 2023$, donde Y_{it} identifica a la variable de interés (*cantidad de empleados de tiempo completo según lo reportado en el Balance Fiscal de cada compañia anualmente*). D_{it} es una variable que toma valor 1 cuando la compañía i es expuesta al tratamiento (*aplicó y recibió el préstamo*) en el período t. X_{it} es un conjunto de covariables cualitativas y cuantitativas, algunas de ellas periódicas y otras constantes en el tiempo, que son específicas para cada compañía o industria. Cada combinación $\{Y_{it}, D_{it}, X_{it}\}_{i=1}^{n}$, $t = 2017,..., 2023$ identifica a una firma que podría, potencialmente, haber aplicado y recibido el préstamo del programa.

2.2. Resultados potenciales

El modelo de resultados potenciales de Rubin, también conocido como el marco de resultados potenciales, es un enfoque fundamental para el análisis causal en estadística y econometría. Este modelo establece que el efecto causal de una intervención o tratamiento se define como la diferencia entre los resultados que se observarían si una unidad (*por ejemplo, una persona o empresa*) recibiera el tratamiento y los resultados que se observarían si no lo recibiera.

En Heckman et al., (1997), se retoma la discusión del modelo de resultados potenciales

presentado en trabajos previos (Rubin, 1974, 1978), y se explica que el problema de evaluación de es un problema, fundamentalmente, de datos faltantes. En cualquier momento, las unidades analizadas pueden estar en uno de dos estados potenciales: tratamiento y control, pero no en ambos. Los estados asociados con recibir tratamiento y no recibir tratamiento se denotan como "1" y "0" respectivamente.

Para cada firma o unidad i, para cada período t, denotamos por $Y_{i,t}(0)$ al resultado potencial del periodo t en el caso de que la unidad i no sea tratada en ninguno de los períodos temporales, y por $Y_{i,t}(g)$ al resultado potencial que la unidad i experienciaría en el momento t, en el caso de pertenecer al grupo de tratamiento indicado por g. En la aplicación de este trabajo contamos con un único grupo de tratamiento y una única intensidad de tratamiento: aquellas compañías que recibieron el préstamo de PPP son consideradas parte del grupo $g = 2020$.

Como es habitual en este tipo de aplicaciones, podemos expresar al resultado observado $Y_{i,t}$ para la unidad i en términos de los resultados potenciales como:

$$Y_{i,t} = Y_{i,t}(0) + [\, Y_{i,t}(2020) - Y_{i,t}(0) \,]\, G_{i,2020} \qquad (1)$$

Donde $G_{i,2020}$ es una variable binaria que toma valor igual a 1 cuando la compañía pertenece al grupo de tratamiento, y 0 en caso contrario.

2.3. Parámetro de interés

El parámetro de interés en este tipo de aplicaciones es el efecto tratamiento promedio sobre los tratados. Este parámetro se define como:

$$ATT = \mathbb{E}\left[Y_{i1}(1) - Y_{i1}(0) \mid D_i = 1\right] = \mathbb{E}\left[Y_{i1}(1) \mid D_i = 1\right] - \mathbb{E}\left[Y_{i1}(0) \mid D_i = 1\right] \quad (2)$$

Asumiendo que las observaciones son independientes, idénticamente distribuidas, podemos re-expresar (2) como:

$$ATT = \mathbf{E}\left[Y_1(1) \mid D = 1\right] - \mathbf{E}\left[Y_1(0) \mid D = 1\right]$$

El desafío en este contexto consiste en computar $\mathbf{E}\left[Y_1(0) \mid D = 1\right]$ con la información disponible.

En Sant'Anna & Zhao, (2020) se desarrolla una estimación doblemente robusta para este estimador, para el caso en el que se cuentan con dos períodos de observación relevantes: pre y post tratamiento. En Callaway & Sant'Anna, (2021), se extiende el modelo canónico para considerar una generalización de este parámetro: el *group-time average treatment effect o* efecto tratamiento promedio por grupo. Este será el segundo efecto de interés en la aplicación del presente trabajo. Ambos tipos de estimadores serán desarrollados en la Sección 2.5.

2.4. Supuestos

Para la aplicación de los métodos a seguir en este trabajo debemos verificar el cumplimiento de una serie de supuestos habituales que permitirán la identificación del ATT por grupos. Seguiremos la propuesta de identificación indicada en (Callaway & Sant'Anna, 2021).

Supuesto 1 *Irreversibilidad de tratamiento*

$$D_{t-1} = 1 \textit{ implica que } D_t = 1 \tag{3}$$

Este supuesto expresa que una vez que una unidad es tratada, la misma unidad permanecerá bajo tratamiento en el período siguiente. Consideramos que este supuesto se cumple en nuestra aplicación ya que analizamos el caso de compañías que recibieron el préstamo y no han decidido devolverlo.

Supuesto 2 *No anticipación o anticipación limitada del tratamiento*

Existe $\delta \geqslant 0$ tal que:

$$\mathbb{E}\left[Y_t(g) \mid X,\ G_g = 1\right] = \mathbb{E}\left[Y_t(0) \mid X,\ G_g = 1\right] \tag{4}$$

$$\textit{para todo } g \in \mathcal{G},\ t \in \{2016,\ldots,2023\} \textit{ tal que } t < g - \delta$$

Este supuesto expresa que las unidades pueden anticiparse solo de forma limitada a la aplicación del tratamiento. En el caso analizado, el Paycheck Protection Program fue promulgado el 27 de Marzo de 2020, y el primer préstamo fue aprobado el 3 de Abril de 2020. Consideramos que este supuesto es válido dado que las compañías analizadas no podrían haber anticipado o modificado sus nóminas o estructuras salariales en vista del potencial acceso al programa.

Supuesto 3 *Tendencias paralelas, condicional en covariables*

$$\mathbb{E}\left[Y_1(0) - Y_0(0) \mid D = 1,\ X\right] = \mathbb{E}\left[Y_1(0) - Y_0(0) \mid D = 0,\ X\right] \tag{5}$$

El supuesto de tendencias paralelas indica que, en ausencia de tratamiento, el resultado promedio condicional del grupo de compañías tratadas debería evolucionar en paralelo al grupo de compañías no tratadas. Si bien este supuesto admite la presencia de tendencias condicionando en covariables, no permite la presencia de tendencias específicas para cada unidad observacional. Como veremos en las próximas secciones, este supuesto se cumple para el dataset analizado al condicionar en covariables cualitativas y cuantitativas de cada compañía.

Supuesto 4 - *Condición de superposición.*

Para cada $t \in \{2017, ..., 2023\}$, con $g \in \mathcal{G}$, existe algún $\varepsilon > 0$ tal que:

$$\varepsilon < \mathbb{P}(G_g = 1) \quad y \quad \mathbb{P}_{g,t}(X) < 1 - \varepsilon \tag{6}$$

El término de la izquierda indica que al menos una pequeña fracción de la población de interés se encuentra bajo tratamiento al formar parte del grupo $g \in \mathcal{G}$. El término de la derecha indica que, para cada posible combinación de las covariables incluidas en X, para todos los grupos de tratamiento $g \in \mathcal{G}$, el tratamiento no está identificado de forma exacta o segura.

2.5. Identificación de los estimadores

En este trabajo nos enfocaremos en dos especificaciones o modelos para la estimación. Cada uno de estos métodos descansa sobre un proceso de identificación en particular. A continuación describiremos ambos tipos de estimaciones.

2.5.1. Estimador DiD Doblemente Robusto

Considerando una población finita de N unidades, asumimos inicialmente que cada unidad es asociada a sus resultados potenciales: $Y_{it}(\cdot) := (Y_{it}(0),\ Y_{it}(1))$, que refieren respectivamente a la variable de resultado bajo pertenencia al grupo de control, y al grupo de tratamiento, en los períodos pre y post tratamiento: $t = 0, 1$.

El resultado observado para una compañía i entonces es:

$$Y_{it} \ = \ D_i\, Y_{it}(1) \ + \ (1 - D_i) \ \ Y_{it}\,(0)$$

Donde D_i refleja el estado de tratamiento de la unidad i. Tanto las N unidades como su colección de resultados potenciales $Y_i(\cdot) := \{Y_i : i = 1,..., N\}$ son fijas. La naturaleza estocástica de los datos proviene del vector de asignación al tratamiento.

Cada unidad se asigna independientemente al tratamiento de acuerdo a $D_i \ \sim \ Bernoulli\,(p_i)$ donde p_i es la probabilidad específica de ser asignada al tratamiento para cada compañía, y

desconocida para el/la investigador/a. Esta probabilidad puede estar relacionada de forma arbitraria a los resultados potenciales, o a otras covariables determinísticas.

Bajo el cumplimiento del Supuesto 1, Supuesto 2 y Supuesto 4, existen dos procedimientos de estimación relativamente flexibles para estimar el ATT, (Sant'Anna & Zhao, 2020): el enfoque de regresión sobre el resultado (*outcome regression* u *OR* por sus siglas en inglés), desarrollado en Heckman et al., (1997) y el enfoque de ponderación por inversa de probabilidad (*inverse probability weighting* o *IPW*, por sus siglas en inglés) (Abadie, 2005).

Bajo el enfoque OR, el ATT puede ser estimado según la siguiente expresión:

$$\widehat{ATT}^{OR} = \overline{Y}_{1,1} - \left[\overline{Y}_{1,0} + n_{treat}^{-1} \sum_{i \mid D_i=1} \left(\widehat{\mu}_{0,1}(X_i) - \widehat{\mu}_{0,0}(X_i) \right) \right] \quad (7)$$

Donde $\overline{Y}_{d,t} = \sum_{i \mid D_i=d, T_i=t} \frac{Y_{it}}{n_{d,t}}$ es el promedio muestral de la variable de resultado utilizando en el cálculo las $n_{d,t}$ unidades que se encuentran en tratamiento, por pertenecer al grupo d, en el momento t. Podemos ver que este estimador se define en términos de dos períodos relevantes en el análisis: pre y post tratamiento.

Por otro lado, $\widehat{\mu}_{d,t}(X_i)$ es un estimador de $m_{d,t} \equiv \mathbb{E}[Y_t | D = d, X = x]$, que identifica la regresión de resultado u *outcome regression* "verdadera" (Heckman et al., 1997).

La consistencia del estimador de *outcome regression* depende de la correcta especificación de los estimadores de $m_{d,t}$: $\widehat{\mu}_{d,t}(X_i)$. En resumen, este estimador ajusta un modelo de regresión al resultado, controlando por covariables, y utiliza los valores predichos para estimar el efecto del tratamiento.

Por otra parte, bajo el enfoque IPW podemos reexpresar el ATT como sigue:

$$ATT^{IPW} = \frac{1}{\mathbb{E}[D]} \mathbb{E}\left[\frac{D - p(X)}{1 - p(X)} (Y_1 - Y_0) \right] \tag{8}$$

En este caso, la consistencia de este estimador descansa sobre la correcta especificación de $p(X) \equiv \mathbb{P}(D = 1 \mid X)$, que representa el verdadero puntaje de propensión o *propensity score* (Abadie, 2005). Bajo esta especificación, el estimador propuesto puede reescribirse como:

$$\widehat{ATT}^{IPW} = \frac{1}{\mathbb{E}[D]} \mathbb{E}\left[\frac{D - \widehat{\pi}(X)}{1 - \widehat{\pi}(X)} (Y_1 - Y_0) \right] \tag{9}$$

Donde $\widehat{\pi}(X)$ es un estimador del puntaje de propensión. El estimador IPW utiliza ponderaciones inversas basadas en la puntuación de propensión para equilibrar las distribuciones de covariables entre los grupos tratados y de control. También se puede definir el estimador IPW Estandarizado, que ajusta las ponderaciones de acuerdo al tamaño de la muestra.

Basándose en estos dos métodos principales, Sant'Anna & Zhao, (2020) construyen un estimador de diferencias en diferencias doblemente robusto (DRDiD). El estimador expresado en (10) es doblemente-robusto en el sentido de que se identifica el ATT consistentemente si el modelo de propensión o el modelo de resultado están especificados correctamente.

$$ATT^{DR} = \mathbb{E}\left[\left(w_1(D) - w_0(D, X; \pi)\right) \left(\Delta Y - \mu_{0,\Delta}(X)\right) \right] \tag{10}$$

Donde, $\Delta Y = Y_1 - Y_0$ y definimos $\mu_{d,\Delta}(X) \equiv \mu_{d,0}(X) - \mu_{d,0}(X)$, con $d = 0, 1$, siendo $\mu_{d,0}(X)$ un modelo para la *outcome regression* verdadera: $m_{d,t}(x) \equiv \mathbb{E}\left[Y_t \mid D = d,\ X = x\right]$, y donde, para un g genérico:

$$w_1(D) = \frac{D}{\mathbb{E}[D]} \quad y \quad w_0(D, X; \pi) = \frac{\frac{g(X)\,(1-D)}{1-g(X)}}{\mathbb{E}\left[\frac{g(X)\,(1-D)}{1-g(X)}\right]}$$

Para identificar este efecto se propone una estrategia de dos pasos. En el primer paso, se estima $p(\cdot)$ a partir de algún modelo para $\pi(\cdot)$, y $m_{d,t}(\cdot)$ usando $\mu_{d,t}(\cdot)$, con $d, t = 0, 1$. En el segundo paso se utilizan los valores ajustados para las estimaciones de $p(\cdot)$ y $m_{d,t}(\cdot)$ en el análogo muestral:

$$\widehat{ATT}^{DR} = \mathbb{E}_n\left[\left(\widehat{w}_1(D) - \widehat{w}_0(D, X; \widehat{\gamma})\right)\left(\Delta Y - \mu^p_{0,\Delta}(X; \widehat{\beta}_{0,0}, \widehat{\beta}_{0,1})\right) \right], \tag{11}$$

donde

$$\widehat{w}_1(D) = \frac{D}{\mathbb{E}_n[D]}, \quad \text{and} \quad \widehat{w}_0(D, X; \gamma) = \frac{\pi(X;\gamma)(1-D)}{1-\pi(X;\gamma)} \Big/ \mathbb{E}_n\left[\frac{\pi(X;\gamma)(1-D)}{1-\pi(X;\gamma)}\right],$$

Para estas expresiones consideramos $\widehat{\gamma}$ como un estimador para el pseudoverdadero γ^*, $\widehat{\beta_{0,t}}$ es un estimador para el pseudoverdadero $\beta^*_{0,t}$. Además, para β_0, β_1 genéricos:

$\mu_{0,\Delta}(\cdot\,;\beta_0,\beta_1) = \mu_{0,1}(\cdot\,;\beta_1) - \mu_{0,0}(\cdot\,;\beta_0)$

Los autores mencionan que puede se puede mejorar la eficiencia del estimador al considerar los siguientes modelos para los *nuisance functions* mencionadas:

$$\pi(X,\gamma) \equiv \frac{exp(X'\gamma)}{1+exp(X'\gamma)} \quad y \quad \mu_{0,\Delta}(X;\beta_0,\beta_1) = X'\beta_{0,\Delta}$$

Teniendo en cuenta esta especificación, el estimador propuesto es el denominado estimador doblemente-robusto mejorado (*improved*) que está dado entonces por el siguiente estimador de tres pasos:

$$\widehat{ATT}^{DR}_{IMP} = \mathbb{E}_n\left[\left(\widehat{w}_1(D) - \widehat{w}_0\left(D, X; \widehat{\gamma}^{ipt}\right)\right)\left(\Delta Y - \overset{\text{lin}}{\mu}_{0,\Delta}\left(X; \widehat{\beta}^{wls}_{0,\Delta}\right)\right)\right], \tag{12}$$

Donde los primeros dos pasos consisten en estimar:

$$\widehat{\gamma}^{ipt} = \arg\max_{\gamma \in \Gamma} \mathbb{E}_n \left[DX'\gamma - (1-D)\exp\left(X'\gamma\right) \right],$$

$$\widehat{\beta}_{0,\Delta}^{wlsp} = \arg\min_{b \in \Theta} \mathbb{E}_n \left[\frac{\Lambda\left(X'\widehat{\gamma}^{ipt}\right)}{1-\Lambda\left(X'\widehat{\gamma}^{ipt}\right)} \left(\Delta Y - X'b\right)^2 \right],$$

siendo $\widehat{\gamma}^{ipt}$ el estimador por probabilidad inversa propuesto por Graham (2012), y $\widehat{\beta}_{0,\Delta}^{wls}$ un estimador por mínimos cuadrados ponderados.

En lo que sigue del trabajo nos referiremos a los estimadores que surgen del procedimiento propuesto en Sant'Anna & Zhao, (2020) como estimadores DRDiD.

2.5.2. Estimador DiD Doblemente Robusto para múltiples períodos

Para explotar la disponibilidad de información para múltiples períodos previos y posteriores a la aplicación del programa, redefinimos la disponiblidad de datos como una muestra aleatoria:

$$\{(Y_{i,1}, Y_{i,2}, ..., Y_{i,\mathrm{T}}, D_{i,1}, D_{i,2}, ..., D_{i,\mathrm{T}}, X_i)\}_{i=1}^{n} \quad , con\ \mathrm{T} = 8$$

Denotamos, además, por $D_{i,t}$ a una variable binaria que toma valor 1 si la unidad i ya fue tratada en el momento t, y 0 en cualquier otro caso. Asumimos el cumplimiento del supuesto de irreversibilidad del tratamiento.

Definimos con la variable *groupyear* al período temporal en el que una unidad es tratada

por primera vez. Por el supuesto de irreversibilidad del tratamiento, esta variable define grupos de pertenencia para cada unidad según qué tan temprano empiezan a participar en el tratamiento. En el caso a analizar en el presente trabajo todas las compañías obtienen el primer préstamo durante el año 2020. Por lo tanto, consideramos $groupyear_{2020}$ como el único grupo que determina cuándo y si se recibe el tratamiento. Una posible alternativa o extensión a esta especificación sería considerar información diaria o mensual para la generación de grupos. Sin embargo, la métrica que mide la variable de interés (*cantidad de empleados*) se reporta en base anual en la mayoría de las compañías a analizar. Por otra parte, se considera también la variable *control*, que toma valor 1 para las unidades que no son tratadas en ningún momento (never-treated group), y valor 0 en caso contrario.

En el caso en que las covariables juegan un rol importante en la identificación del efecto de diferencias en diferencias, y las unidades asociadas al grupo de control son unidades nunca tratadas, Callaway & Sant'Anna, (2021) mencionan la posibilidad de utilizar los métodos de estimación previamente mencionados: OR, IPW o DRDiD. (Callaway & Sant'Anna, 2021). Dada la robustez del estimador DRDiD, los autores extienden este método para incorporar información para múltiples períodos, pre y post tratamiento.

Para el caso a analizar en este trabajo, el estimador relevante o novedoso de Callaway & Sant'Anna (2021) se expresa de la siguiente forma:

$$\widehat{ATT}_{dr}^{nev} = \mathbb{E}\left[\left(\widehat{w}_g^{treat} - \widehat{w}_g^{nev} \right) \left(Y_t - Y_{g-\delta-1} - \widehat{m}_{g,t,\delta}^{nev}\left(X\,;\, \widehat{\beta}_{g,t,\delta}^{nev} \right) \right) \right] \tag{13}$$

Donde

$$\widehat{w}_g^{treat} = \frac{G_g}{\mathbb{E}_n[G_g]} \quad , \quad \widehat{w}_g^{nev} = \frac{\widehat{p}_g(X;\widehat{\pi}_g)\, C}{1-\widehat{p}_g(X;\widehat{\pi}_g)} \Big/ \mathbb{E}_n\left[\frac{\widehat{p}_g(X;\widehat{\pi}_g)\, C}{1-\widehat{p}_g(X;\widehat{\pi}_g)} \right],$$

En estas expresiones, $\widehat{p}_g(X;\widehat{\pi}_g)$, $\widehat{m}_{g,t,\delta}^{nev}\left(X\,;\, \widehat{\beta}_{g,t,\delta}^{nev} \right)$ son estimadores paramétricos de $p_g(\cdot)$, $m_{g,t,\delta}^{nev}(\cdot)$.

Este estimador extiende el alcance de los estimadores doblemente robustos de Sant'Anna & Zhao (2020), al permitir la estimación de efectos de tratamiento en estudios con múltiples períodos (Frios-Avila, n.d.)[1]. La agregación del parámetro sigue la siguiente estructura:

$$AGGTT = \frac{\sum (w_{g,t} * ATT(g,t))}{\sum (w_{g,t})}$$

donde $w_{g,t}$ es la ponderación asignada según cuánta información del dataset se utiliza para estimar $ATT(g,t)$. Estimadores con mayor incidencia de información y, por lo tanto, más precisos, recibirán un mayor peso en la agregación.

[1] Frios-Avila, J. (n.d.). Playing with Stata: Main DRDID. Retrieved June 25, 2024, disponible en https://friosavila.github.io/playingwithstata/main_drdid.html

3. Identificación de unidades de observación

En este trabajo la población de interés consiste en compañías públicas, domiciliadas en Estados Unidos, potencialmente elegibles para participar del PPP. En los próximos apartados se detallará el criterio de elección de las compañías, tanto para construir el listado de compañías potencialmente elegibles, como para construir el listado de compañías que recibieron el préstamo.

3.1. Compañías públicas potencialmente elegibles

Para obtener la lista de compañías públicas que serán parte del dataset nos enfocamos en incluir compañías que cotizaban en mercados públicos en Estados Unidos durante el primer trimestre del año 2020. Además, se recolectó información financiera, de mercado y características cualitativas y cuantitativas, invariantes en el tiempo, para cada compañía. El detalle de las métricas principales utilizadas y sus definiciones se encuentran en el Apéndice 1.

En este trabajo se utilizan dos fuentes principales para crear la lista de compañías. En

primer lugar, utilizando la plataforma S&P Capital IQ Pro[2], se identifica un listado inicial de compañías que cotizaban en mercados públicos durante los meses de Enero, Febrero y Marzo de 2020, y que cumplen con el criterio de estar domiciliadas en Estados Unidos. Obtenemos un listado de 7160 empresas. Adicionalmente, utilizaremos criterios de disponibilidad de información para eliminar compañías que no sean requeridas a informar su desempeño financiero. Mantenemos en el dataset a aquellas compañías que cumplen los siguientes criterios:

- Activos Totales (Total Assets) disponibles para el período 2017-2020.
- Ingresos Netos (Net Income) disponibles para el período 2017-2020.
- Número de empleados de tiempo completo disponibles para el período 2017-2020.

Por otro lado, utilizaremos la base de datos de la Small Business Administration (SBA)[3] para validar la información disponible a nivel de préstamos solicitados y que no han sido devueltos. Utilizando este dataset y la información de S&P Capital IQ Pro mantendremos en el dataset a aquellas firmas que cumplan con los estándares de tamaño establecidos por la SBA. Estos estándares se pueden aplicar según características de cantidad de empleados,

[2] Las opiniones, resultados y comentarios acerca de este trabajo no están relacionadas ni influenciadas, ni reflejan la opinión de S&P Global Market Intelligence o ninguna de sus subsidiarias o compañías afiliadas.

[3] Disponible en https://www.sba.gov/funding-programs/loans/covid-19-relief-options/paycheck-protection-program/ppp-data

tamaño de la firma en términos de valuación neta o ingresos netos. En particular, mantendremos en el análisis a compañías que cumplan los siguientes criterios:

- Poseen menos de 500 empleados reportados en el balance fiscal del año 2019 o
- Están evaluadas en términos de valuación neta en no más de 15 millones de dólares estadounidenses y tuvieron ingresos netos por no más de 5 millones de dólares estadounidenses, en promedio, durante los últimos dos años fiscales.
  - La medición de valuación neta representa el monto total de activos totales menos el monto total de deuda total para el fin del año fiscal 2019.
- No pertenecen a la industria denotada por el código NAICS 52.

Bajo estos criterios identificamos 1064 compañías, de las cuales 170 recibieron el préstamo. En la Tabla 1 se adjunta el detalle de la cantidad de compañías públicas, potencialmente elegibles, desglosadas por industria.

Podemos observar que el acceso al programa fue relativamente variado en términos de industrias que participaron. Sólo se excluyó del análisis a la categoría ``Utilities'' por no tener en nuestro dataset ninguna compañía tratada clasificada dentro de esta categoría.

Industria	No-PPP	PPP
Communication Services	42	7
Consumer Discretionary	38	10
Consumer Staples	49	9
Energy	61	10
Financials	5	1
Health Care	364	53
Industrials	75	18
Information Technology	124	48
Materials	42	9
Real Estate	94	5
Total	894	170

Tabla 1: Distribución de tratamiento por industria.

3.2. Participación en M&A como fuente de heterogeneidad en el efecto de tratamiento

Si bien existen diferentes métricas de desempeño financiero y de mercado que se pueden utilizar, a nivel compañía y a nivel industria, para explicar los cambios en el nivel de empleo, en este trabajo utilizaremos una clasificación adicional para dar cuenta de una potencial presencia de heterogeneidad en el efecto de tratamiento: la participación en transacciones (fusiones o adquisiciones).

Para ilustrar esta idea, clasificaremos en cuatro grupos a las compañías analizadas. Estos grupos serán definidos por la variable "*intensity*" y se definen como sigue:

	Grupo 1 $N_1 = 633$	Grupo 2 $N_2 = 261$	Grupo 3 $N_1 = 129$	Grupo 4 $N_1 = 41$
Obtuvo un préstamo dentro del PPP	No	No	Si	Si
Participó como compradora/inversora de (al menos) una fusión o adquisición	No	Si	No	Si

En el Gráfico 1 se reportan los promedios observados para el cambio porcentual del nivel de empleo, medido de forma anual, desagregado por grupos. Por ejemplo: para el año t, se utiliza el cálculo: $empgrowth_t = \frac{employees_t - employees_t}{employees_{t-1}} * 100$ dentro de cada grupo.

Podemos observar que los grupos 2 y 4, es decir, los grupos que completaron transacciones durante los años 2020-2021, experimentan un pico en el año 2021 en crecimiento de número de empleados. Esto es razonable considerando que, tras la unificación de operaciones de dos compañías que se fusionan, o tras la incorporación de compañías adquiridas, el nivel de trabajadores reportados bajo la compañía *"que sobrevive"* aumentaría según el tamaño de la operación incorporada. Por la naturaleza endógena de la decisión de involucrarse en una fusión o adquisición estas compañías no serán consideradas en el análisis.

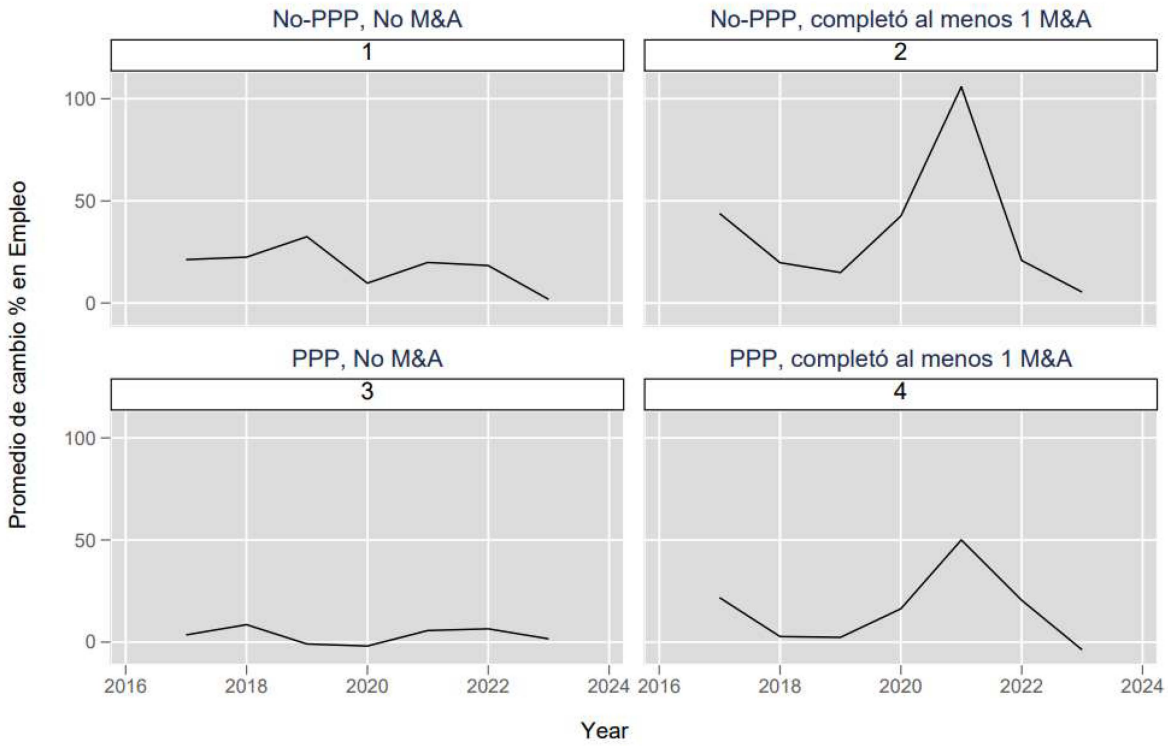


Gráfico 1: Cambio porcentual en nivel de empleo, por grupos.

En las secciones subsiguientes nos referiremos por grupo de tratamiento a compañías públicas, elegibles, que accedieron al préstamo dentro del marco del Paycheck Protection Program. Por otro lado, nos referimos a grupo de control, a compañías públicas, elegibles, que no accedieron al préstamo. En todos los casos, ninguna de las compañías analizadas completó una transacción como compradoras de otras firmas. De esta manera, contamos con un total de 129 firmas públicas que recibieron el tratamiento, y 619 firmas como parte del grupo de control.

Apéndice 1 Detalle de variables

Variable	**Definición**
entityid	Indicador de panel que identifica de forma unívoca a las compañías en el dataset.
sp_entity_name	Nombre actual de la compañía según lo reportado en S&P Capital IQ Pro.
industrymi	Industria según clasificación de sector primaria de S&P Capital IQ Pro.
naicsfull	Código de industria NAICS con su definición.
state	Estado donde se incorporó la firma.
avgnetincome	Promedio de ingresos netos durante los años 2018 y 2019.
netincome	Ingresos netos al final del periodo fiscal.
employees	Cantidad de empleados de tiempo completo al final del año fiscal, según lo reportado en la hoja de balance. Esta variable es la variable dependiente en las regresiones reportadas.
liabtoassets	Ratio que representa la cantidad total de pasivos dividido por la cantidad de activos al final del periodo fiscal, según lo reportado en la hoja de balance.
marketcap	Capitalización de mercado al final del año calendario para cada año.
empgrowth	Cambio porcentual anual en la cantidad de empleados al final del periodo fiscal, según lo reportado en la hoja de balance.

maindicator	Variable binaria que indica participación en una fusión o adquisición completada durante los años 2020 y 2021, en el rol de compradores o inversores.
treated	Variable binaria que indica participación en el Paycheck Protection Program.

4. Aplicación y resultados

4.1. DRDiD: Estimación por Sant'Anna & Zhao (2020)

En este apartado revisaremos los resultados obtenidos a partir del estimador doblemente robusto de Sant'Anna & Zhao (2020). A través del programa "*drdid*" en Stata se puede estimar la forma canónica del modelo de diferencias en diferencias de dos períodos. Para esta aplicación consideramos como el período "pre-tratamiento" el año fiscal 2019, y como el período "post-tratamiento" el año fiscal 2020.

En la Tabla 2 se reportan los resultados para los 6 métodos de estimación disponibles para el estimador identificado por las ecuaciones (7)-(12). Podemos observar que el efecto estimado es negativo y significativo en todos los modelos, situandose en torno a los 6-8 empleados de diferencia entre el período pre y post tratamiento. Es interesante notar que los modelos denotados por las columnas (2) y (3) permiten entender el rol de las covariables, no solo a la hora de explicar la variable de resultado, sino también a la hora de diferenciar los 6 tipos de estimadores computados.

Tabla 2: Efectos del PPP sobre el empleo, estimación DiD de dos períodos.

	Sant'Anna & Zhao (2020)		
	(1) Sin covariables	(2) Covariables ind.	(3) Cov. ind. y por industria
Doubly Robust IPW	-8.900**	-7.857*	-6.761*
	(3.201)	*(3.422)*	*(3.287)*
Doubly Robust Improved	-8.900**	-7.893*	-6.714*
	(3.201)	*(3.408)*	*(3.291)*
Outcome regression	-8.900**	-8.017*	-6.742*
	(3.201)	*(3.290)*	*(3.220)*
Abadie(2005) IPW	-8.900**	-7.743*	-6.683*
	(3.201)	*(3.431)*	*(3.290)*
Standardized IPW	-8.900**	-7.742*	-6.683*
	(3.201)	*(3.428)*	*(3.290)*
IPW and Regression adjustment	-8.900**	-7.896*	-6.715*
	(3.201)	*(3.407)*	*(3.291)*

Nota: La tabla representa el resultado del método de DiD para dos períodos basado en Sant'Anna & Zhao (2020). En todos los modelos la variable dependiente es el nivel de empleo, medido como la cantidad de empleados reportados al final del año fiscal.

Errores estándar en paréntesis - * p<0.05, ** p<0.01, *** p<0.001

4.2. CSDiD: Estimación por Callaway & Sant'Anna (2021)

En esta sección consideraremos el análisis del efecto del tratamiento utilizando como grupo de tratamiento al grupo 3, y como grupo de control relevante al grupo 1. Recordamos que estos grupos comparten la característica de no haber participado en fusiones o adquisiciones completadas durante los años 2020 y 2021.

En la Tabla 3 se adjuntan los resultados obtenidos para tres especificaciones de modelos estimados utilizando estimadores doblemente robustos, extendidos a múltiples períodos (Callaway & Sant'Anna, 2021). Se incluye la representación gráfica de estos resultados en los siguientes gráficos: Gráfico 2, Gráfico 3, Gráfico 4. Los modelos tienen como variable dependiente la cantidad de empleados reportados al final del año fiscal por cada compañía, y difieren según si incluyen o no covariables en la ecuación de nivel de empleo.

La primera columna corresponde a un modelo que no incluye covariables. La segunda columna corresponde a un modelo que incluye covariables específicas de cada empresa como ingresos netos, ratio de pasivos sobre activos, capitalización bursátil y crecimiento de empleo en períodos anteriores. La tercera columna corresponde al modelo que adiciona covariables específicas de empresa mencionadas anteriormente y los promedios por industria correspondiente a cada caso. Observamos que la hipótesis de tendencias paralelas se cumple de forma condicional en las variables explicativas en los modelos (2) y (3).

Tabla 3: Efectos del PPP sobre el empleo. Estimación CSDiD de múltiples períodos.

	(1) Sin covariables	(2) Covariables individuales	(3) Cov. ind. y por industria
Promedio Pre-Tratamiento	-4.694*	-5.002**	-3.628*
	(1.836)	(1.788)	*(1.620)*
Promedio Post-Tratamiento	-13.86	-14.70*	-13.25*
	(7.195)	(6.671)	(5.974)
T - 2 (2018)	-2.602	-2.984	-1.788
	(2.591)	(2.505)	(2.440)
T - 1 (2019)	-6.787	-7.020	-5.468
	(3.831)	(3.823)	(3.391)
T (2020)	-8.900*	-8.673*	-7.719*
	(4.024)	(3.654)	(3.588)
T + 1 (2021)	-20.11***	-20.42***	-19.30***
	(5.044)	(4.218)	(3.935)
T + 2 (2022)	-13.41	-14.86	-14.09
	(8.838)	(8.725)	(8.078)
T + 3 (2023)	-13.02	-14.83	-12.43
	(12.64)	(12.28)	(12.35)

Nota: La tabla representa el resultado del método de DiD para múltiples períodos basado en Callaway & Sant'Anna (2021). En todos los modelos la variable dependiente es el nivel de empleo, medido como la cantidad de empleados reportados al final del año fiscal.

Errores estándar en paréntesis - * p<0.05, ** p<0.01, *** p<0.001

En cuanto al efecto tratamiento estimado, para la subpoblación analizada, encontramos que para el año fiscal 2020, el efecto estimado es negativo y significativo en todos los modelos. Se estima en promedio una disminución en la cantidad de empleados reportada en entre 7.7 y 8.8 empleados. Estos resultados son consistentes con lo estimado en otros trabajos contemporáneos a la aplicación del programa que miden el impacto inmediato para el año fiscal que siguió a la aplicación del préstamo.

También observamos que los tres modelos estiman un efecto negativo y significativo según valores tradicionales para el nivel de empleo para el año fiscal posterior a la aplicación del programa, 2021, donde se estima una caída de aproximadamente 19 a 20 empleados en promedio para las observaciones tratadas. La magnitud del efecto se atenúa levemente en los modelos que incluyen controles por covariables, pero el efecto sigue siendo significativo a valores tradicionales. Para los años 2022 y 2023 el efecto tratamiento promedio estimado es negativo pero no significativo en todas las especificaciones. En promedio, encontramos que el efecto de tratamiento promedio sobre los tratados para el período de tres años luego de la aplicación del programa es de una caída de entre 12.85 y 13.86 empleados de tiempo completo en el nivel reportado por las compañías.

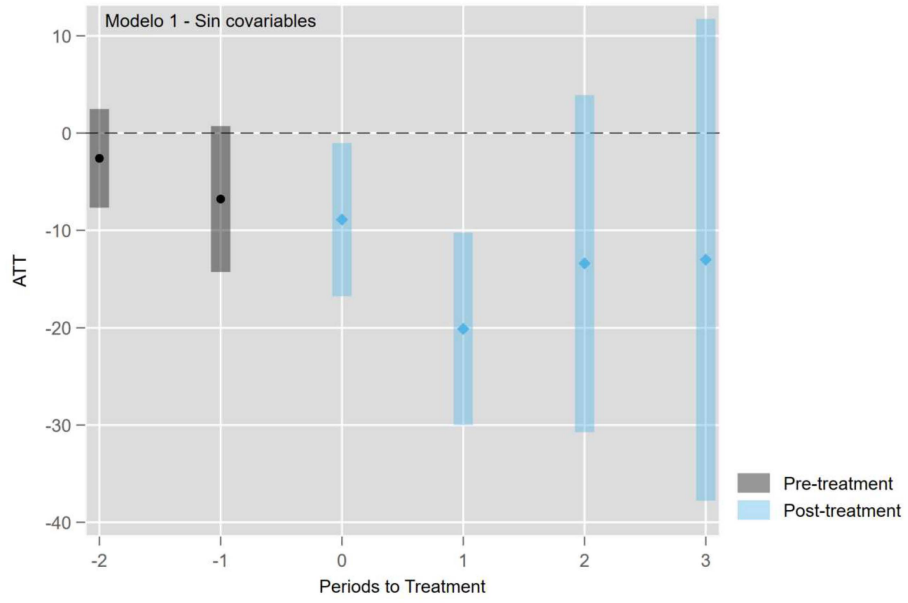


Gráfico 2: CSDiD: Corresponde al Modelo (1), donde se estima el ATT sobre la cantidad de empleados reportados al final del año fiscal, sin control por covariables.

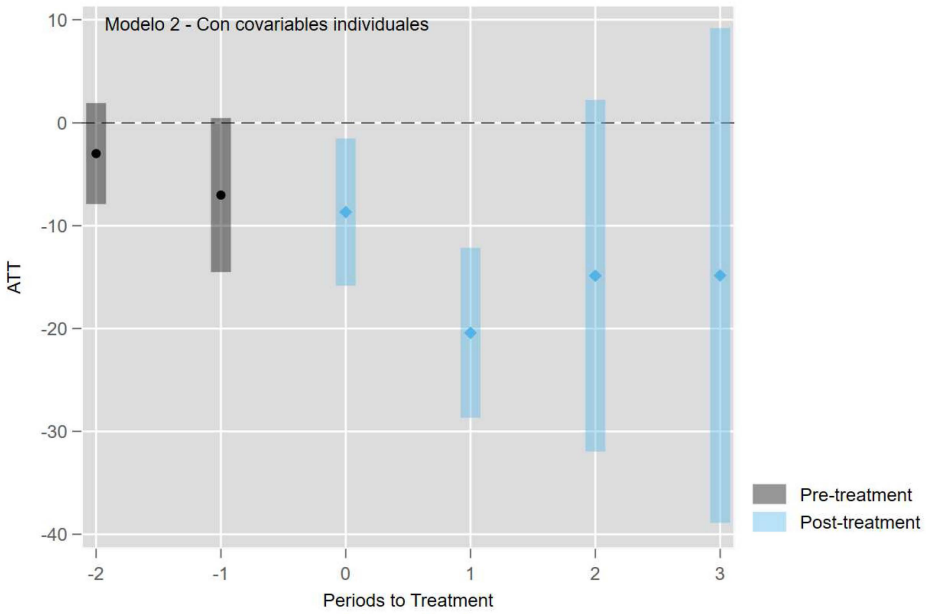


Gráfico 3: CSDiD: Corresponde al Modelo (2), donde se estima el ATT sobre la cantidad de empleados reportados al final del año fiscal, controlando por ingresos netos y ratio de pasivos sobre activos, a nivel individual.

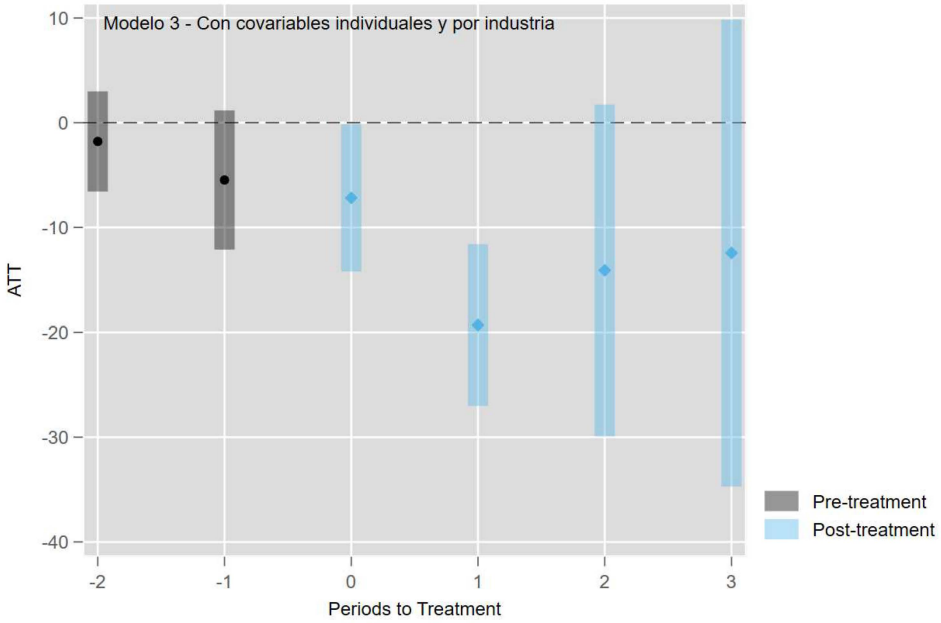


Gráfico 4: CSDiD: Corresponde al Modelo (3), donde se estima el ATT sobre la cantidad de empleados reportados al final del año fiscal, controlando por ingresos netos y ratio de pasivos sobre activos, a nivel individual, y controlando por el promedio de industria de ingresos netos, ratio de pasivos sobre activos y capitalización bursátil.

5. Conclusión

En este trabajo se buscó analizar el efecto de una política pública bajo el caso de presencia de heterogeneidad de efectos de tratamiento por grupos, y considerando disponibilidad de información histórica para diferentes períodos pre y post tratamiento.

De acuerdo al análisis realizado, los resultados sugieren que la aplicación del programa no alcanzó a contrarrestar los efectos negativos sobre el número de empleados en compañías públicas que no estuvieran en vías de completar una transacción de fusión o adquisición. Con un efecto negativo promedio post-tratamiento de entre 5 y 15 empleados, según el modelo, no encontramos signos de la relevancia del programa en la recuperación de la cantidad de empleados a mediano y largo plazo.

Particularmente, encontramos que todos los modelos son consistentes en cuanto al efecto inmediato post-tratamiento: Para las compañías tratadas vemos que durante el año 2020, el nivel de empleo cambia de forma negativa, significativamente. Al observar los períodos posteriores, y comparar con el grupo no tratado, vemos que la diferencia en el número de empleados es significativa y negativa para las compañías que habían accedido al préstamo en el caso de los modelos de múltiples períodos en el año 2021. Luego, aunque sigue siendo negativo, el efecto se atenúa y deja de ser significativo para los años 2022 y 2023.

Es importante mencionar que en este trabajo no estamos caracterizando el proceso de

acceso al programa. De acuerdo a lo revisado en literatura reciente, el proceso de aplicación fue diferenciado para compañías que no tuvieran antecedentes comerciales con un banco aprobado por la Small Business Administration, es decir, compañías que podrían utilizar ese vínculo comercial para obtener financiamiento con otras fuentes.

El acceso al programa de compañías públicas con capacidad de recurrir al mercado de capitales da cuenta, además, de una decisión de comportamiento del directorio de estas compañías, que elige hacer uso de formas de financiación de "*salvataje*", en lugar de recurrir a otras fuentes de financiación típicas como emisión de acciones o deuda pública, o financiación por capital privado. Este comportamiento puede ser percibido por los actores del mercado de forma negativa y podría impactar en el desempeño de la compañía en diferentes niveles.

En conclusión, este análisis presenta una contribución novedosa en el área de estudio, ya que, tras una exhaustiva revisión de la literatura, no se ha encontrado evidencia de investigaciones previas que aborden específicamente la evaluación del Paycheck Protection Program sobre compañías públicas, utilizando métodos recientemente desarrollados en el campo de la Microeconometría. La falta de estudios previos en esta área resalta la originalidad de esta investigación y subraya la importancia de los resultados obtenidos para el avance del conocimiento en este campo.

6. Bibliografía

Abadie, A. (2005). Semiparametric Difference-in-Differences Estimators. *The Review of Economic Studies*, *72*(1), 1-19. https://doi.org/10.1111/0034-6527.00321

Abadie, A., Athey, S., & Wooldridge, J. (2020). *Sampling-based versus design-based uncertainty in regression discontinuity designs* (N.º 48584340). National Bureau of Economic Research.

Athey, S., & Imbens, G. W. (2021). Design-based analysis in difference-in-differences settings with staggered adoption. *Journal of Econometrics*.

Autor, D., Cho, D., Crane, L., & Goldar, M. (2021). *Evaluation Using Administrative Payroll Data: Insights from the Paycheck Protection Program* (N.º w29972). National Bureau of Economic Research.

Autor, D., Cho, D., Crane, L., Goldar, M., Lutz, B., Montes, J., Peterman, W., Ratner, D., Vallenas, D. V., & Yildirmaz, A. (2022). *The $800 Billion Paycheck Protection Program: Where Did the Money Go and Why Did it Go There?* National Bureau of Economic Research. https://doi.org/10.3386/w29669

Balyuk, T., Prabhala, N., & Puri, M. (2020). *Indirect Costs of Government Aid and Intermediary Supply Effects* (N.º w28114). National Bureau of Economic Research.

Bartik, et al., A. (2020). The Targeting and Impact of Paycheck Protection Program Loans to Small Businesses. *National Bureau of Economic Research*.

Baumeister, C., León, A. C., & Sims, E. (2020). *Weekly State-Level Economic Conditions: COVID-19 and Beyond* (N.º w29003). National Bureau of Economic Research.

Beggs, A. (2021). Fraud and abuse in investment advisory firms. *Journal of Financial Economics*.

Callaway, B., & Sant'Anna, P. H. C. (2021). *Difference-in-Differences with Multiple Time Periods*. National Bureau of Economic Research.

Campello, M., Kankanhalli, G., & Muthukrishnan, P. (2020). *Corporate Hiring under COVID-19: Labor Market Concentration, Downskilling, and Income Inequality* (N.º w27208). National Bureau of Economic Research.

Chernenko, S., & Scharfstein, D. (2021). *Racial Disparities in the Paycheck Protection Program* (N.º w29748). National Bureau of Economic Research.

Chetty, R., Friedman, J. N., Hendren, N., & Stepner, M. (2020). How Did COVID-19 and Stabilization Policies Affect Spending and Employment? A New Real-Time Economic Tracker Based on Private Sector Data. *National Bureau of Economic Research*.

Cororaton, A., & Rose, J. (2021). Public Firm Borrowers of the US Paycheck Protection Program. *Journal of Financial Intermediation*.

Crump, R. K., Hotz, V. J., Imbens, G. W., & Mitnik, O. A. (2009). Dealing with limited overlap in estimation of average treatment effects. *Biometrika*, *96*(1), 187-199.

Duchin, R., Farre-Mensa, J., Platt, J., & Ruan, T. (2021). *Concierge Treatment from Banks: Evidence from the Paycheck Protection Program*. National Bureau of Economic Research.

Fairlie, R. W., Fossen, F. M., Johnsen, D., & Droboniku, R. (2021). *Were Small Businesses More Likely to Permanently Close during the COVID-19 Pandemic?* (N.º w30285). National Bureau of Economic Research.

Graham, B., Pinto, C., & Egel, D. (2012). Inverse Probability Tilting for Moment Condition Models with Missing Data. *The Review of Economic Studies*, *79*(3), 1053-1079.

Granja, J., Makridis, C., Yannelis, C., & Zwick, E. (2020). *Did the Paycheck Protection Program Hit the Target?* (N.º w27095). National Bureau of Economic Research.

Guo, S., Culhane, J., & King, K. (2021). Basic Facts on the Coverage of the Paycheck Protection Program. *Economic Policy Review*.

Heckman, J. J., Ichimura, H., & Todd, P. E. (1997). Matching As An Econometric Evaluation Estimator: Evidence from Evaluating a Job Training Programme. *The Review of Economic Studies*, *64*(4), 605-654. https://doi.org/10.2307/2971733

Hubbard, R. G., & Strain, M. R. (2020). *Has the Paycheck Protection Program Succeeded?* (N.º w28032). National Bureau of Economic Research.

Humphries, J. E., Neilson, C. A., & Ulyssea, G. (2020). *Information Frictions and Access to the Paycheck Protection Program*. National Bureau of Economic Research.

King, G., & Nielsen, R. (2020). Why Propensity Scores Should Not Be Used for Matching. *Political Analysis*, *27*(4), 435-454.

Li, L., Strahan, P. E., & Zhang, S. (2020). *Banks as Lenders of First Resort: Evidence from the COVID-19 Crisis* (N.º w27256). National Bureau of Economic Research.

Neilson, C. A., Humphries, J. E., & Ulyssea, G. (2020). *Information Frictions and Access to the Paycheck Protection Program* (N.º w27624). National Bureau of Economic Research.

Rambachan, A., & Roth, J. (2020). Design-based Uncertainty for Quasi-experiments. *arXiv preprint arXiv:2008.00602v6*.

Rossi, B., Barraza, C., & Yeager, Z. (2021). Short-term Effect of the Paycheck Protection Program. *Economics Letters*.

Rubin, D. B. (1974). Estimating causal effects of treatments in randomized and nonrandomized studies. *Journal of Educational Psychology*, *66*(5), 688-701. https://doi.org/10.1037/h0037350

Rubin, D. B. (1978). Bayesian Inference for Causal Effects: The Role of Randomization. *The Annals of Statistics*, *6*(1), 34-58.

Sant'Anna, P. H. C., & Zhao, J. (2020). Doubly Robust Difference-in-Differences Estimators. *Journal of Econometrics*.

Schweitzer, M. E., & Guo, A. (2023). Basic Facts on the Coverage of the Paycheck Protection Program. En *Working paper (Federal Reserve Bank of Cleveland)*. Federal Reserve Bank of Cleveland. https://doi.org/10.26509/frbc-wp-202324

Tasci, M. (2021). *PPP Loans and State-Level Employment Growth*. National Bureau of Economic Research.

Wooldridge, J. M. (2021). *Econometric Analysis of Cross Section and Panel Data. 3906345*.