

Banca de Desarrollo en tiempos de pandemia. Evaluación de impacto de créditos de capital de trabajo*

Alejandro Danon[†] Rafael Tessone[‡] Guido Zack[§]

August 31, 2021

Abstract

La pandemia demandó nuevas acciones a la banca de desarrollo. El BICE, tradicionalmente, especializado en créditos de comercio exterior e inversión de largo plazo, ofreció una línea de capital de trabajo con el objetivo de mitigar el impacto de este gran shock en el empleo de las firmas. No encontramos literatura previa que evalúe este tipo de programa y nuestro trabajo se propone hacerlo aplicando una metodología cuasi experimental, utilizando una amplia base de microdatos y combinando Propensity Score Matching y Efectos Fijos. Nuestros resultados indican un efecto positivo, superior al 6%, robusto a incorporar variables de control relacionadas a trayectorias previa de empleo, exportaciones, deuda y calificación crediticia. Un experimento falso sugiere una buena identificación a partir de la estrategia adoptada. Finalmente, resultados complementarios sugieren que el canal a través del cual se genera este efecto es el acceso a crédito, más que las características de esta línea (plazos y tasas de interés por debajo del mercado).

Keywords: Banca de Desarrollo, Evaluación de impacto, Acceso a crédito, Capital de Trabajo, Empleo.

JEL Codes: D22, J23, O1, G21, H81

*Los comentarios, errores y omisiones de este artículo corresponden a los autores y no a las autoridades del BICE. Agradecemos los comentarios de Carolina Farre y Evelyn Giuliani.

[†]BICE y LADPE-INVECO (Universidad Nacional de Tucumán). Email: ale.m.danon@gmail.com.

[‡]BICE. Email: rtessone@bice.com.ar.

[§]BICE, Universidad de Buenos Aires y Universidad Nacional de San Martín. Email: gzack@bice.com.ar.

1 Introducción

El Banco de Inversión y Comercio Exterior (BICE) es el banco de desarrollo público de la Argentina, especializado en préstamos de inversión de largo plazo y comercio exterior. Sin embargo, la crisis mundial del COVID-19 demandó nuevas acciones e instrumentos para complementar el sector financiero argentino. Así, por primera vez en sus casi 30 años de existencia, el BICE implementó una línea de préstamo, generada por un programa del Ministerio de Desarrollo Productivo, para cubrir necesidades de corto plazo de las empresas, principalmente salariales, y evitar la interrupción de la cadena de pagos. Uno de sus objetivos era proteger el empleo en lo que fue el segundo año de mayor caída de la actividad económica de los últimos 80 años.

Si bien la literatura económica se ocupa con cierta frecuencia del impacto de los programas de crédito de la banca de desarrollo, en su mayoría están relacionados a líneas para inversión a largo plazo (DeNegri et al. (2011)). Los préstamos para capital de trabajo tienen otros plazos, destino y finalidades. El objetivo de este trabajo es realizar una evaluación rigurosa del impacto del programa, en particular, si fue capaz de mitigar la caída en el empleo formal. Para ello, aplicamos una técnica cuasi-experimental, mediante una rica base de microdatos, conformada a partir de tres bases administrativas. Los microdatos de más de 600 mil empresas, incluyen datos históricos de empleo formal, además de otras características de las empresas (ubicación, antigüedad, sector de actividad), desempeño exportador y, particularmente interesante para construir un grupo de control robusto, historial de acceso a deuda bancaria y calificación crediticia. Esto nos permite aplicar Propensity Score Matching (PSM) y seleccionar un grupo de control con trayectorias previas similares al grupo de tratamiento, para luego estimar, mediante un modelo de efectos fijos, el impacto del programa en el empleo formal al finalizar el 2020.

El documento está organizado de la siguiente manera. La Sección 2 describe el préstamo de capital de trabajo del BICE y el contexto de aplicación de este programa en Argentina. La sección 3 presenta la revisión de literatura previa, donde queda de manifiesto la escasa

evaluación de este tipo de líneas de crédito implementadas por la Banca de Desarrollo y en contextos de shocks de esta magnitud. La sección 4 desarrolla la metodología, donde se describe la base de datos utilizada y la estrategia de identificación. La sección 5 presenta los principales resultados, proponiendo un canal a través del cual el impacto se genera y en la sección 6 se suma un experimento falso como señal de la correcta identificación del parámetro de interés. Finalmente, la sección 7 concluye.

2 El programa y el contexto


La Argentina, al momento en que la pandemia irrumpe, venía transitando un período de estancamiento económico. Desde 2011 a 2019, el crecimiento promedio anual del Producto Bruto Interno fue del 0,4%, con el agravante que en los dos últimos años el PBI acumuló una caída del 4,6%, la inflación se ubicó en torno al 50% y se iniciaba un proceso reestructuración de la deuda. En este contexto, la pandemia y las consecuentes medidas restrictivas a la movilidad de la población y a la actividad,¹ generó en el segundo trimestre del 2020 que el PBI sufra una contracción del 19% respecto a igual período del año anterior.

A su vez, el crédito al sector privado en Argentina históricamente representó menos del 15% del PBI² y tuvo un desempeño fuertemente procíclico. Así, como resultado de la caída en el nivel de actividad de 2018 y 2019, el crédito total al sector privado en términos reales acumulaba una caída del 40%. Nótese que la banca pública, al igual que el resto del sistema bancario, también se manifiesta un fuerte componente procíclico -ver Figura 1-. Sin embargo, existen fuertes argumentos acerca de la importancia de que estimular un comportamiento del sistema menos procíclico, que disminuya los efectos del ciclo económico en los costos de creación de empleos (Den Haan and Sedlacek (2014)). Es decir, facilitar el crédito en períodos recesivos, aunque siempre respetando los parámetros de selección de proyectos con

¹En el marco del Aislamiento Social Preventivo y Obligatorio (ASPO) adoptadas por el Gobierno Nacional.

²En el período 2002 -2019 el crédito al sector privado en Argentina representó, en promedio, el 12,8% del PBI.

Figure 1: Variación del PIB y crédito privado en Argentina (2003-2019)



razonable capacidad y voluntad de pago una vez que se supera la recesión.

En este contexto y con estos antecedentes, el Ministerio de Desarrollo Productivo de la Nación instrumentó una serie de medidas para mitigar el efecto de la pandemia en la producción y el empleo. El conjunto de medidas fue amplio, donde se destaca el Programa de Asistencia a la Producción y el Empleo (ATP)³, préstamos de largo plazo destinados a inversión productiva para MiPyMes y grandes empresas, préstamos de capital de trabajo e inversión para asistir a empresas, cooperativas e instituciones de investigación y desarrollo que contribuyan a la emergencia sanitaria, y se destacan otras dos medidas que involucran directamente al BICE. La primera fue el aporte de 30 mil millones de pesos al Fondo de Garantías Argentino (FOGAR)⁴, el cual es administrado por el BICE, y permitía avalar créditos de capital de trabajo que tomen las MiPyMEs por hasta 120.000 millones de pesos.⁵ Esta medida se combina con la segunda, que consistió en las líneas de préstamos de capital de trabajo, que incluyó líneas cuyo destino principal era el financiamiento del pago de sueldos. Todas consistían en una tasa fija máxima regulada no superior del 24%, con un plazo mínimo de 12 meses y con un periodo de gracia de al menos tres meses, a su vez cada

³Consistió en el pago parcial, a cargo del Estado Nacional, de salarios de empleados formales, monotributistas y autónomos, destinado a empresas de todos los tamaños y actividades.

⁴El Fondo de Garantías Argentino (FOGAR) es un fideicomiso público a través del cual el Gobierno facilita el acceso al crédito para las MiPyMEs, mediante el otorgamiento de garantías totales o parciales en respaldo de créditos otorgados por entidades financieras. BICE Fideicomisos S.A. ejerce el rol de fiduciario.

⁵Se trata de un aval del 100% del capital obtenido en el préstamo para los casos de micro, pequeñas empresas y monotributistas de todas las categorías; y del 25% del capital en los casos de las empresas medianas tramo 1 y 2.

Table 1: Línea Capital de Trabajo BICE

Destino	Pago de salarios, compra de insumos, materias prima, combustibles
Plazo	Hasta 12 y 18 meses, y hasta 3 meses de gracia
Tasa de interés	19% y 24%
Monto máximo	Pequeñas empresas: hasta \$30 millones Medianas empresas: hasta \$50 millones Grandes empresas: hasta \$80 millones
Empresas	495
Monto desembolsado	\$ 3.000 millones

entidad bancaria podía mejorar las condiciones crediticias. Una de estas líneas de capital de trabajo impulsadas por el Ministerio fue la que dispuso el BICE, que por primera vez en su historia implementó este tipo de préstamos para financiar a las empresas a corto plazo. Como antecedente, el BICE solamente realizó desembolsos de Capital de trabajo asociados a inversión (hasta 20% del monto desembolsado para inversión) y participó en el Mercado de Capitales para la compra de Cheques de Pago Diferido⁶. La línea tuvo una tasa del 19% anual fija en pesos para empresas con aval de Sociedades de Garantías Recíprocas (SGR) o del FOGAR y un plazo de hasta 12 meses con un máximo de 6 meses de gracia, o estaba la posibilidad de un plazo mayor, 18 meses a una tasa del 24%. El objetivo fue hacer frente a la disminución de ingresos originada por la pandemia y prevenir la destrucción de empresas y empleo.

3 Revisión de literatura

Diversos estudios teóricos y empíricos han demostrado que el acceso al financiamiento es un factor determinante del desempeño de las empresas (Beck et al. (2005)).

Si bien existen diversos motivos por los que las empresas enfrentan dificultades para acceder al crédito, el principal es la existencia de información asimétrica entre las empresas y los bancos o intermediarios financieros (Stiglitz and Weiss (1981)). Específicamente las empresas

⁶La participación del BICE en la compra de cheques de pago diferido en el Mercado de Capitales durante la crisis iniciada en el año 2018, tuvo como objetivo contener la suba de tasas que se había precipitado en el mercado.

que presentan un proyecto de inversión para solicitar un crédito tienen más información que los bancos, y como las pymes tienen un mayor riesgo, los bancos consideran a todas como si fueran de alto riesgo independientemente de sus características particulares. A su vez, este problema se agrava para las más pequeñas porque pueden no tener información contable o activos para ofrecer como garantía. Este proceso desemboca en una mayor tasa de interés o restricciones para acceder al crédito.

Además, la necesidad de acceder a crédito de capital de trabajo puede ser mayor en un contexto de caída en el nivel de actividad y su ausencia puede generar mayores costos sobre el empleo en el corto y largo plazo, como demuestran Den Haan and Sedlacek (2014). Por lo tanto, las políticas públicas de financiamiento, dentro de las que se enmarcan los bancos de desarrollo, que ayuden a mitigar las fallas de mercado, facilitando el acceso al crédito, pueden ser una alternativa efectiva para mejorar la performance de las MiPyMEs, y en particular en el empleo.

Kersten et al. (2017) realizan un estudio de meta-análisis acerca de evaluaciones de impacto del financiamiento a PyMEs en países de ingresos medios y bajos. Entre los quince estudios seleccionados, dentro de los más de mil preseleccionados, sólo tres utilizan como método de evaluación un experimento natural. El resto implementa métodos no experimentales, principalmente propensity score matching (PSM) con diferencias en diferencias (DID), para eliminar el sesgo de selección que suele aparecer debido a que la elegibilidad en los programas suele depender de un criterio administrativo del diseño de la política y de la decisión de las firmas. Los programas evaluados incluyen créditos subsidiados, créditos fiscales, programas de garantías o cambios regulatorios que otorgan prioridad de créditos. Los autores encuentran que las PyMEs que acceden a financiamiento tienen un efecto positivo y significativo en el empleo, al igual que en otras variables como inversión en capital, desempeño de las firmas (producción, ventas, ingresos), pero no fue significativo en salarios y productividad.

DeNegri et al. (2011) aplican PSM y DID para evaluar la efectividad de las líneas de

crédito público del Banco Nacional do Desenvolvimento (BNDES) y de Financiadora de Estudos e Projetos (FINEP). Los autores encuentran que el acceso de las firmas a la línea de crédito tiene un impacto positivo y significativo en el crecimiento del empleo y las exportaciones, pero no encuentran evidencia de un impacto significativo en su medida de productividad laboral.

Lopez-Acevedo and Tan (2010) evalúan varios programas de crédito a pequeñas y medianas empresas en México (Nafinsa, Bancomext, CONACyT, STPS y otros programas del Ministerio de Economía), Chile (SENCE, CORFO, PROCHILE, FONDEF), Colombia (FOMiPyME) y Perú (BONOPYME, PROMPYME, CITE). En los estudios también se utiliza la técnica de DID combinada con PSM, y encuentran un efecto positivo en ventas, productividad laboral y el empleo en Chile, y mayores ventas, exportaciones y empleo en México. Los autores resaltan la importancia de que además de controlar por sesgo de selección, también es importante considerar los rezagos de tiempo necesarios para estimar correctamente los efectos de los programas de crédito.

Eslava et al. (2012) evalúan el impacto de los préstamos otorgados por el Bancoldex, el banco de desarrollo de segundo piso de Colombia, en el desempeño de empresas industriales con más de 10 empleados. Utilizan una base de datos de panel que surge de la combinación de datos sobre los préstamos otorgados por el Bancoldex y una encuesta anual industrial que contiene información sobre característica de las firmas y su desempeño. Aprovechando la estructura de panel, los autores también combinan técnicas de matching con regresiones de efectos fijos para dar tratamiento a los posibles sesgos de selección. Los autores encuentran efectos positivos y significativos en el empleo y la productividad, también encuentran impacto positivo en producción e inversión.

Brown and Earle (2013) evalúan el efecto de los préstamos de la Small Business Administration (SBA) exclusivamente en el empleo. Con tal fin los autores combinan los datos de los créditos otorgados por la SBA con los datos anuales de empleo de las firmas de Estados Unidos para el período 1976-2010. Utilizando la técnica de matching con regresiones

de efectos fijos, encuentran efectos positivos y significativos en el empleo en las firmas que recibieron un préstamo.

Encontramos pocas evaluaciones de impacto de líneas de crédito asociadas a capital de trabajo. En relación a esto Arráiz et al. (2012) estudian el impacto de un programa de garantías parciales para créditos respaldada por el gobierno de Colombia, con la intención de atender empresas con restricciones crediticias producto de su falta de colateral. Utilizando datos de características de la empresa y su performance, generan un grupo de control (a través de técnicas de PSM) y luego aplican DID. Los autores encuentran que empresas que obtienen acceso al crédito respaldado pueden crecer tanto en términos de producción como de empleo. Sin embargo, no encuentran ningún efecto sobre la productividad, los salarios o la inversión. Estos resultados, a su criterio, sugieren que el principal canal del efecto del programa es por capital de trabajo, las empresas utilizan los nuevos fondos para compra de insumos, en lugar de invertir en nuevos bienes de capital.

Giuliodori et al. (2018) evalúan tres programas de financiamiento dirigidos a Pymes en Argentina: una línea de crédito directa del gobierno con tasa subsidiada (FONAPYME), un subsidio de tasa a créditos de la banca pública y privada (RBT) y un programa de otorgamiento de Garantías (SGR). Los autores utilizan una base de datos similar a la nuestra (generada a partir de datos administrativos de organismos nacionales) y combinan método de PSM con Efectos fijos. Los resultados muestran un aumento en el acceso a crédito de las empresas y, mediante este canal, un efecto en empleo, salarios medio y, algo menor, desempeño exportador. El programa de RBT presenta el mayor impacto.

4 Metodología

4.1 Data

Nuestra base de microdatos se construye utilizando tres fuentes administrativas diferentes. Los datos sobre características generales de la firma como antigüedad, ubicación ⁷, actividad económica (codificación de la Administración Federal de Ingresos Públicos, AFIP) y el tamaño de la empresa, se obtienen del Registro PyMe que elabora el Ministerio de Desarrollo Productivo de Argentina. Los datos de empleo formal⁸ y exportaciones⁹ también son provistos por el Ministerio de Desarrollo Productivo de Argentina, a partir de la Administración Nacional de la Seguridad Social (ANSES) y AFIP. Por último, la información histórica del nivel de deuda y calificación crediticia se obtiene a partir de la Central Nacional de Deudores del Sistema Financiero (CENDEU) del Banco Central de la República Argentina (BCRA).

Esta base de datos incluye más de 1 millón de personas físicas y jurídicas, a la cual se le aplica un primer filtro para generar un conjunto de empresas similar al grupo de beneficiarias del programa del BICE. Se excluyen las personas físicas (97% de los clientes BICE son personas jurídicas), empresas con menos de 4 y más de 500 empleados (la línea fue diseñada principalmente para Pymes) y las actividades económicas no frecuentemente atendidas por esta línea (e.g. empresas de servicios públicos, financieros, personales, entre otros). A partir de esto, se genera una submuestra de 120 mil empresas, con datos entre 2017 y 2020, un tamaño, a priori, suficiente para proceder a la selección del grupo de control y lograr un set de firmas, ex ante, similares al grupo de tratamiento.

⁷la jurisdicción donde está registrada la empresa

⁸Los datos de empleo surgen del Sistema Integrado Previsional Argentino (SIPA) y son provistos a la Oficina del Economista Jefe (OEJ) del BICE en rangos de 2 a empleados para las empresas con menos de 500 empleados y para empresas con más de 500 empleados los rangos van de a 100 empleados.

⁹En el caso de las exportaciones, son provistas con frecuencia mensual en rangos de USD 200.000 hasta los USD 10 millones y un último rango con aquellas empresas con una exportación mensual superior a los USD 10 millones, luego en la OEJ se hace el acumulado anual de las mismas.

Table 2: Estadísticas descriptivas Base total y Clientes BICE

	Media	Mediana	Min	Max	SD	Observaciones
Capital de Trabajo BICE						
Antigüedad	21	17	2	96	15	424
Número de empleados (2019)	61	34	4	470	74	495
Deuda >0 (2019)	98%					
Deuda, si >0 (2019)	37,198,901	5,517,000	1,000	3,393,258,000	167,810,364	484
Calificación crediticia (2019)	94%					456
Exportaciones >0 (2019)	25%					
Exportaciones (USD) , si >0 (2019)	2,422,400	1,200,000	200,000	19,800,000	3,256,578	125
Resto de las empresas						
Antigüedad	17	14	2	118	14	97,740
Número de empleados (2019)	23	10	4	498	44	116,346
Deuda >0 (2019)	68%					
Deuda, si >0 (2019)	7,022,936	238,000	1,000	6,614,134,000	68,959,533	79,439
Calificación crediticia (2019)	95%					75,216
Exportaciones >0 (2019)	6%					
Exportaciones (USD) , si >0 (2019)	2,430,513	800,000	200,000	120,000,016	6,766,057	6,902

4.2 Estrategia de identificación

Nuestro parámetro de interés es el impacto, promedio, de acceder a esta línea de crédito en las empresas clientas de esta línea. Es decir, cómo les hubiese ido a estas empresas de no haber logrado acceder a esta línea de capital de trabajo. Lo que se conoce en la literatura, en lenguaje del Modelo Causal de Rubin, como ATOT ($E[Y_{iT} - Y_{iC}/T = 1]$) -Angrist and Pischke (2008)-.

El desafío de identificar este parámetro, es que si bien la performance de las firmas (tratadas) con acceso a la línea de capital de trabajo (tratamiento) es observable, el outcome de estas empresas de no haber accedido a este programa no lo es. Este contra factual se intenta estimar a partir de la performance de las empresas que no accedieron al programa.

Sin embargo, la línea del BICE no fue asignada en forma aleatoria. Existen problemas de autoselección y selección por parte del BICE. Las firmas que aplican a esta línea son claramente diferentes al promedio del mercado - ver Tabla 2-. Como ejemplo de lo mencionado, la encuesta de Observatorio Pyme (2019) para Pymes Industriales indica que más del 82% de las empresas que solicita crédito bancario lo obtiene, pero hay más de un 65% de empresas que identifican el acceso a crédito entre sus principales problemas. Además, el BICE, entre otras cuestiones, cuenta con un departamento de riesgo que evalúa la empresa y aprueba los

desembolsos.

La estrategia que adoptamos para identificar esta performance contra factual es la recomendada por Heckman and Todd (2009), relevada como la más frecuentemente utilizada en este tipo de evaluaciones según DeNegri et al. (2011) y Kersten et al. (2017), y similar a la adoptada por Arráiz et al. (2012), Castillo et al. (2014) y Giuliadori et al. (2018). Consiste en seleccionar un grupo de control con características observables similares, ex ante, entre ambos grupos. Esto se realiza mediante algoritmos de matcheo, en particular Propensity Score Mathcing. La similitud entre el grupo de tratamiento y el de control está basada en compartir la misma probabilidad (estimada) en acceder al crédito del BICE (tratamiento) -Khandker et al, 2010-.

La consistencia de este método está basada en dos condiciones:

1. **Conditional independence:** $(Y_{iC}) \perp T_i / P(T_i = 1/X_i)$
2. **Sizable common support in propensity scores:** $0 < P(T_i = 1/X_i) < 1$

Nótese, que entendemos que debido a que el método de selección por parte del BICE se realiza en base a observables, creemos que el supuesto 1 (no observable) puede cumplirse con cierto grado de razonabilidad. En la sección 6 realizaremos un experimento falso (*fake test*) para convencernos al respecto.

Para definir el modelo PSM, consideramos las recomendaciones de Heckman, Ichimura y Todd (1998) y utilizamos variables que están presentes y hayan sido generadas por la misma fuente de información para ambos grupos (tratamiento y control). En nuestro caso utilizamos solamente datos administrativos, no información interna del BICE, lo cual nos asegura que se miden de manera similar.

El método de PSM utilizado, es el método del vecino más cercano (*Nearst Neighborhood Estimator*), usado con mayor frecuencia en la literatura (Thoemmes and Kim (2011); Zakrisson et al. (2018)) y estudiado ampliamente mediante simulaciones. Además, aprovechando el tamaño de nuestra base de datos, seleccionamos solamente un vecino más cercano para

construir el grupo de control, lo cual es más exigente pero lo hace más robusto.

La estimación del PSM, se realiza mediante una regresión logit, en variables de características de las firmas fijas en el tiempo y datos previos al tratamiento (2020), para los años 2018 y 2019. En particular, ubicación (provincia), sector de actividad (a 1 dígito), antigüedad, exportaciones, nivel de deuda y calificación crediticia y empleo. Lamentablemente, no contamos con datos de variables asociadas al valor (bruto o neto) producido, ventas, salarios, stock de capital o inversión. Sin embargo, sí podemos captar la dinámica previa en nuestra variable outcome de interés (empleo) y controlar por niveles de deuda y calificación crediticia, los cuales indican empresas en algún sentido similar.

La Tabla 7 del apéndice indica las variables asociadas al acceso a esta línea de capital de trabajo. Nótese que estimamos tres modelos, en donde sumamos progresivamente variables explicativas, ya que algunas variables implican pérdidas de observaciones en ambos grupos (control y tratamiento). En particular, incluir antigüedad y calificación crediticia implica pérdida de observaciones debido a que nuestra base no tienen antigüedad para todas empresas y que las empresas sin deuda previa no tienen calificación crediticia.

Los resultados son los esperados. Las variables de empleo y niveles de deuda son significativas. También resultan significativas (al 1%), en forma conjunta, las variables dummies asociadas al sector de actividad y provincia ¹⁰. No resulta significativo la calificación crediticia, lo cual se explica por la poca variabilidad en esta variable (más del 95% de las empresas con calificación tienen calificación buena). Tampoco resulta significativa el nivel de exportaciones, lo cual puede estar asociado a que es una línea destinada a capital de trabajo y también a la escasa cantidad de firmas con exportaciones. Finalmente, la ausencia de correlación con antigüedad ha sido estudiada por la literatura previa, encontrando evidencia mixta al respecto (Peñaloza (2015), Bebczuk (2010)).

A partir de la estimación de los modelos PSM y la selección de un grupo de control realizamos un conjunto de chequeos para verificar que ambos grupos tienen características

¹⁰Realizamos LRT test de significancia conjunta para ambas variables categóricas, por separado.

Table 3: Performance del Matching. Modelo 3

Variable	Base completa			Muestra seleccionada con PSM Modelo 3		
	Tratadas	Resto de las firmas	p-value (diferencia de medias)	Tratadas	Control	p-value (diferencia de medias)
Distancia	0.030	0.006	0.000	0.030	0.030	0.983
Empleo (2018)-en logs-	3.602	2.606	0.000	3.602	3.661	0.510
Empleo (2019)-en logs-	3.683	2.659	0.000	3.683	3.751	0.417
Calificación crediticia 1 (2018)	0.954	0.951	0.787	0.954	0.946	0.623
Calificación crediticia 1 (2019)	0.938	0.938	0.965	0.938	0.923	0.398
Deuda (2018)-en logs-	15.402	12.546	0.000	15.402	15.458	0.756
Deuda (2019)-en logs-	15.423	12.560	0.000	15.423	15.441	0.921
Exportaciones (2018)-en logs-	3.993	1.237	0.000	3.993	3.829	0.721
Exportaciones (2019)-en logs-	4.204	1.249	0.000	4.204	3.969	0.612
Antigüedad -en logs-	2.802	2.634	0.000	2.802	2.776	0.651
Factor (Actividad)*			0.000			0.888
Factor (Provincia)*			0.000			0.997

* La Comparación entre grupos se realiza mediante Xi2 test

similares (Rosenbaum and Rubin (1983), Arráiz et al. (2012)). En primer lugar testeamos que las medias de las variables de interés (outcome y control) previas a la intervención (y fijas en el tiempo) entre el grupo de tratamiento y control sean similares. La Tabla 3 presenta estos resultados para el total de la muestra de empresas (aproximadamente 112 mil firmas), el grupo de tratamiento y el grupo de control (seleccionado con el modelo 3, el más exigente en término de controles). A excepción de la calificación crediticia, previo al matcheo todas las variables mostraban medias significativamente diferentes al 1%, mientras que después del matcheo el test de igualdad de medias de ninguna variable puede ser rechazado. En segundo lugar, la correlación de estas variables, en forma conjunta, con el estatus de tratamiento disminuye a valores no significativos¹¹. Finalmente, la distribución de los PSM después del matcheo muestra distribuciones muy similares, no pudiendo rechazarse la hipótesis nula de distribuciones iguales (Kolmogorov-Smirnov test) -ver Figura 2-.


Una vez seleccionado el grupo de control a partir del matcheo calculamos el impacto del programa mediante el siguiente modelo, estimado con el método de efectos fijos:

$$y_{it} = \theta T_{it} + \mu_t * factor(actividad) + \mu_t * factor(provincia) + c_i + \epsilon_{it}(1) \quad (1)$$

donde y_{it} , nuestra variable outcome de interés, es el empleo formal de la empresa i en el

¹¹desde un R2 (Pseudo, Mc Fadden) de 0.15 a 0.0135 y el test de significancia indica un p value de 0.99 versus 0 en la muestra total

Figure 2: Distribución Score PSM



periodo t , T_{it} es la variable indicativa de recibir el crédito en el año t , y, por lo tanto θ es nuestro parámetro de interés y refleja el impacto en el empleo formal de recibir el crédito. μ_t es un set de variables dummies para los años 2018, 2019 y 2020 que interactúan con variables dummies de sector de actividad y provincia y, por lo tanto, permiten tendencias diferenciadas en el empleo formal según el sector de actividad y provincia. Finalmente c_i representa el efecto de las variables no observables, omitidas, que afectan al empleo pero en forma constante a lo largo del tiempo, mientras que ϵ_{it} representa shocks no correlacionados con la asignación del tratamiento.

5 Resultados

Los resultados muestran que las empresas asistidas por el BICE tuvieron un mejor comportamiento en términos de empleo que el grupo de control. La Tabla 4 presenta los resultados de la estimación del modelo expresado en la ecuación 1, mediante efecto fijos, y a través de los 3 modelos de PSM aplicados. Los resultados indican que la línea de crédito del BICE tuvo un impacto positivo y significativo en el empleo, entre un 6% y 8%, en los modelos estimados. Si sumamos al análisis la estimación de la dummy 2020, el modelo describe una caída en el empleo en el grupo de control (entre 4% y 8%) como resultado del shock 2020, que se ve atenuado en el caso de las empresas asistidas por la línea de capital de trabajo del

BICE.

Table 4: Impacto de la línea de crédito en el empleo formal de la firma

	<i>Dependent variable:</i>		
	Model 1	Employment(in logs) Model 2	Model 3
Treatment	0.080** (0.034)	0.061** (0.027)	0.065* (0.034)
factor(year)2019	0.099** (0.048)	0.013 (0.046)	0.016 (0.047)
factor(year)2020	-0.040 (0.108)	-0.065 (0.068)	-0.078 (0.082)
Observations	2,922	2,922	2,334
R ²	0.075	0.082	0.062
Adjusted R ²	-0.428	-0.417	-0.458
Variables in PSM			
Employment 2018-2019	<i>yes</i>	<i>yes</i>	<i>yes</i>
Debt level	<i>no</i>	<i>yes</i>	<i>yes</i>
Exports 2018-2019	<i>no</i>	<i>yes</i>	<i>yes</i>
Credit qualification	<i>no</i>	<i>no</i>	<i>yes</i>
Seniority	<i>no</i>	<i>no</i>	<i>yes</i>

Note:

*p<0.1; **p<0.05; ***p<0.01

All regressions include firm level fixed effects
and interacting year dummies with Activity and State.

All PSM includes State and Activity Dummies.

Clustered at the firm standard errors.

Naturalmente una pregunta clave es por qué las empresas que acceden a esta línea de financiamiento logran atenuar la caída en el nivel de empleo. Entre las posibles respuestas surgen el acceso a financiamiento en un contexto de emergencia económica y restricciones financieras y las mejores condiciones de las líneas del BICE respecto al mercado (principalmente en cuanto a tasas y plazos). Si bien no podemos testear esta segunda hipótesis, sí podemos testear la primera en forma indirecta.

Para eso realizamos dos ejercicios. En primer lugar construimos un grupo de control con

empresas que, además de todas las características incluidas en el PSM original, tienen un nivel de deuda similar en 2020 (además de 2018 y 2019) que las empresas asistidas por el BICE, de esta manera actúa como un proxy de acceso similar al financiamiento bancario y por lo tanto se controla por esta variable en el PSM. Nótese entonces que estamos controlando por un posible canal a través del cual la línea ayuda a la empresa. En segundo lugar, construimos un grupo de control con empresas con niveles de deuda menores al menos en un 20% a las empresas que acceden al crédito BICE. En ambos casos mantenemos el resto de las variables de control en el PSM y la estimación de efectos fijos para controlar por variables no observables y fijas en el tiempo.

Los resultados (Tabla 5) indican que el impacto de la línea de crédito en el empleo deja de ser significativamente diferente a cero cuando se controla por deuda 2020, mientras que el impacto estimado aumenta cuando comparamos con empresas que tuvieron un acceso a crédito menor que las empresas del BICE (en promedio). Estos resultados resultan consistentes con la explicación de que el principal canal a través del cual el programa impacta en el empleo es el acceso a fondos y no necesariamente las características ventajosas del mismo.

6 Experimento falso

La clave en la estrategia de identificación adoptada es que, en la ausencia del programa, las empresas que accedieron a la línea de crédito (grupo de tratamiento) hubiesen tenido el mismo comportamiento en su nivel de empleo respecto del grupo de control. Por supuesto, esto no puede ser testeado directamente por ser no observable este contrafactual. Tampoco podemos testear la similitud de tendencias previas, ya que nuestro método se “asegura” de que las mismas sean similares (Tabla 3).

Sin embargo, es posible realizar un experimento falso (fake test), el cual es similar a dar un placebo a un grupo de firmas. En particular, tomamos el grupo de control como si hubiese recibido la línea de crédito (placebo) y seleccionamos para este, utilizando la misma

Table 5: Impacto con Control Deuda 2020 y Grupo de Control con caída deuda mayor al 20% respecto a BICE

	<i>Dependent variable:</i>					
	Employment(in logs)					
	Model 2	Model 2 Control Deuda	Model 2 Caída Deuda Control>BICE	Model 3	Model 3 Control Deuda	Model 3 Caída Deuda Control>BICE
Treatment	0.061** (0.027)	0.001 (0.025)	0.091*** (0.032)	0.065* (0.034)	-0.014 (0.027)	0.099** (0.039)
factor(year)2019	0.013 (0.046)	0.033 (0.048)	0.078 (0.059)	0.016 (0.047)	0.046 (0.036)	0.003 (0.073)
factor(year)2020	-0.065 (0.068)	0.077 (0.057)	0.039 (0.075)	-0.078 (0.082)	0.024 (0.048)	-0.191 (0.200)
Observations	2,922	2,922	2,922	2,334	2,334	2,334
R ²	0.082	0.082	0.073	0.062	0.090	0.075
Adjusted R ²	-0.417	-0.417	-0.430	-0.458	-0.414	-0.438
Variables in PSM						
Debt level 2020	<i>no</i>	<i>yes</i>	<i>no</i>	<i>no</i>	<i>yes</i>	<i>no</i>
Debt level 2018-2019	<i>yes</i>	<i>yes</i>	<i>yes</i>	<i>yes</i>	<i>yes</i>	<i>yes</i>
Exports 2018-2019	<i>yes</i>	<i>yes</i>	<i>yes</i>	<i>yes</i>	<i>yes</i>	<i>yes</i>
Credit qualification	<i>no</i>	<i>no</i>	<i>no</i>	<i>yes</i>	<i>yes</i>	<i>yes</i>
Seniority	<i>no</i>	<i>no</i>	<i>no</i>	<i>yes</i>	<i>yes</i>	<i>yes</i>

Note:

*p<0.1; **p<0.05; ***p<0.01

All regressions include firm level fixed effects
and interacting year dummies with Activity and State.
All PSM includes State and Activity Dummies.
Clustered at the firm standard errors.

metodología que en la sección anterior, un nuevo grupo de control. Por supuesto, encontrar un comportamiento diferente para 2020 entre ambos grupos es una mala señal para nuestra estrategia de identificación. La Tabla 6 presenta los resultados de este test para el modelo 3, por ser el modelo más exigente. Nótese que la variable de tratamiento resulta no significativa, apoyando la validez de nuestra estrategia de identificación.

7 Conclusiones

La crisis económica debido a la pandemia demandó nuevas acciones e instrumentos para complementar el sector financiero argentino. En este contexto, el Ministerio de Desarrollo Productivo de la Nación impulsó un programa de créditos para capital de trabajo que abarcó a todos los bancos comerciales y del cual el BICE participó. Esto le implicó que por primera vez en sus casi 30 años de existencia, el BICE tuvo que generar una línea de capital de trabajo con el objetivo de atender las necesidades urgentes de sectores críticos y disminuir el efecto

Table 6: Experimento Falso. Grupo de Tratamiento = Grupo de control original

	<i>Dependent variable:</i>
	Employment(in logs)
Fake_Treatment	−0.033 (0.039)
factor(year)2019	0.028 (0.047)
factor(year)2020	−0.052 (0.084)
Observations	2,334
R ²	0.043
Adjusted R ²	−0.485
Variables in PSM	
Debt level 2020	<i>yes</i>
Debt level 2018-2019	<i>yes</i>
Exports 2018-2019	<i>yes</i>
Credit qualification	<i>yes</i>
Seniority	<i>yes</i>

Note: *p<0.1; **p<0.05; ***p<0.01

Regression include firm level fixed effects,
and interacting year dummies with Activity and State.
Clustered at the firm standard errors

en el empleo formal. El objetivo de este trabajo es evaluar el impacto de esta línea de crédito en el empleo formal en 2020 mediante una evaluación de impacto cuasiexperimental. Para ello contamos con una extensa base de microdatos, más de 600 mil empresas, y aplicamos una estrategia de identificación que combina el método de PSM con efectos fijos, una metodología similar a la utilizada en la literatura de evaluación de impacto de programas de créditos a empresas (Kersten et al. (2017)).

Nuestros resultados indican un efecto positivo del acceso a crédito de capital de trabajo de aproximadamente un 6%. Este resultado es robusto a incorporar variables de control relacionadas a trayectoria de empleo, deuda y exportaciones previas (2018 y 2019), calificación crediticia y antigüedad. Además los modelos de efectos fijos permiten identificar tendencias diferenciadas en el empleo formal según el sector de actividad y provincia.

Asimismo, cuando controlamos por nivel de deuda en 2020, el efecto del tratamiento se hace no significativo y cuando seleccionamos un grupo de control con menor acceso a crédito en 2020 respecto de las empresas asistidas por el BICE, el efecto del tratamiento se hace mayor. Ambos elementos nos sugieren que estamos identificando el efecto del programa y que el canal es el acceso a deuda, más que las características particulares de la línea.

Finalmente, realizamos un experimento falso tomando el grupo de control como si hubiese recibido la línea de crédito (placebo) y seleccionamos para este, utilizando los mismos modelos y métodos, un nuevo grupo de control. Los resultados no son significativos, nuevamente sugiriendo una buena identificación por parte de nuestro método.

En cuanto a las recomendaciones de política, nuestros resultados sugieren, en primer lugar, la relevancia de contar con líneas de capital de trabajo para disminuir el impacto en el empleo formal ante un fuerte shock negativo. En segundo lugar, que la clave, más que las características del crédito es contar con acceso al financiamiento.

References

- Angrist, J. D. and Pischke, J.-S. (2008). *Mostly harmless econometrics: An empiricist's companion*. Princeton university press.
- Arráiz, I., Meléndez, M., Stucchi, R., et al. (2012). Partial credit guarantees and firm performance: Evidence from the colombian national guarantee fund. *Inter-American Development Bank, OVE Working Papers*, 212.
- Bebczuk, R. N. (2010). *Acceso al financiamiento de las PyMEs en Argentina: estado de situación y propuestas de política*. CEPAL.
- Beck, T., Demirgüç-Kunt, A., and Maksimovic, V. (2005). Financial and legal constraints to growth: does firm size matter? *The journal of finance*, 60(1):137–177.
- Brown, J. D. and Earle, J. S. (2013). Do sba loans create jobs?
- Castillo, V., Maffioli, A., Rojo, S., and Stucchi, R. (2014). The effect of innovation policy on smes' employment and wages in argentina. *Small Business Economics*, 42(2):387–406.
- Den Haan, W. J. and Sedlacek, P. (2014). Inefficient continuation decisions, job creation costs, and the cost of business cycles. *Quantitative Economics*, 5(2):297–349.
- DeNegri, J. A., Maffioli, A., and Rodriguez, C. M. (2011). The impact of public credit programs on brazilian firms.
- Eslava, M., Maffioli, A., and Meléndez, M. (2012). Second-tier government banks and access to credit micro-evidence from colombia. Technical report, IDB Working Paper Series.
- Giuliodori, D., Guinazú, S., Correa, J. M., Butler, I., Rodriguez, A., and Tacsir, E. (2018). Finance programs for smes, access to credit and performance of firms: Evidence from argentina.
- Heckman, J. J. and Todd, P. E. (2009). A note on adapting propensity score matching and selection models to choice based samples. *The econometrics journal*, 12(suppl_1):S230–S234.

- Kersten, R., Harms, J., Liket, K., and Maas, K. (2017). Small firms, large impact? a systematic review of the sme finance literature. *World Development*, 97:330–348.
- Lopez-Acevedo, G. and Tan, H. W. (2010). Impact evaluation of sme programs in latin america and caribbean. Technical report, The World Bank.
- Peñaloza, H. A. B. (2015). Determinantes del acceso al crédito de las pymes en colombia. *Ensayos de economía*, 25(46):135–156.
- Rosenbaum, P. R. and Rubin, D. B. (1983). The central role of the propensity score in observational studies for causal effects. *Biometrika*, 70(1):41–55.
- Stiglitz, J. E. and Weiss, A. (1981). Credit rationing in markets with imperfect information. *The American economic review*, 71(3):393–410.
- Thoemmes, F. J. and Kim, E. S. (2011). A systematic review of propensity score methods in the social sciences. *Multivariate behavioral research*, 46(1):90–118.
- Zakrison, T., Austin, P., and McCredie, V. (2018). A systematic review of propensity score methods in the acute care surgery literature: avoiding the pitfalls and proposing a set of reporting guidelines. *European Journal of Trauma and Emergency Surgery*, 44(3):385–395.

Apéndice

Table A1: PSM Logistic Regression Model

	<i>Dependent variable:</i>		
	Model 1	Treatment Model 2	Model 3
log(Empleo.2018)	0.015 (0.115)	-0.116 (0.114)	-0.209* (0.126)
log(Empleo.2019)	0.760*** (0.120)	0.487*** (0.119)	0.471*** (0.133)
log(deuda_tot.2018 + 1)		0.043** (0.022)	0.183*** (0.042)
log(deuda_tot.2019 + 1)		0.164*** (0.028)	0.213*** (0.041)
Calif_crediticia.2018			0.178 (0.308)
Calif_crediticia.2019			0.408 (0.277)
log(exports.2018 + 1)		-0.003 (0.019)	-0.015 (0.019)
log(exports.2019 + 1)		0.026 (0.019)	0.025 (0.019)
log(antiguedad_final)			-0.283*** (0.079)
Constant	-8.327*** (0.224)	-9.999*** (0.327)	-12.271*** (0.588)
Observations	113,018	113,018	59,794
Log Likelihood	-2,820.822	-2,678.657	-1,995.113
Akaike Inf. Crit.	5,709.644	5,433.315	4,072.226

Note:

*p<0.1; **p<0.05; ***p<0.01

All regressions include State and Activity Dummies
Clustered at the firm standard errors