

Los usos de los métodos cuantitativos en la investigación política

FIGURAS REVISTA ACADÉMICA
DE INVESTIGACIÓN
ISSN 2683-2917
Vol. 5, núm. 1,
noviembre 2023 - febrero 2024
[https://doi.org/10.22201/
fesa.26832917e.2023.5.1](https://doi.org/10.22201/fesa.26832917e.2023.5.1)



Esta obra está bajo una licencia
Creative Commons Atribución-
NoComercial-CompartirIgual
4.0 Internacional

The Application of Quantitative Methods in Political Research

<https://doi.org/10.22201/fesa.26832917e.2023.5.1.298>

Recibido: 3 de mayo de 2023

Revisado: 3 de julio de 2023

Aceptado: 25 de septiembre de 2023

 **Edwin Atilano-Robles**

Universidad Nacional Autónoma de México.

Facultad de Estudios Superiores Acatlán. México

893053@pcpuma.acatlan.unam.mx

Resumen: La caja de herramientas en la investigación política incluye los métodos cuantitativos; para poder realizar análisis empíricos es importante conocer cuáles son las técnicas apropiadas para describir, generalizar, identificar causalidad y para pronosticar. Sin embargo, la utilidad de los métodos cuantitativos puede perderse entre la complejidad de las técnicas, por lo que nuevas generaciones de estudiantes en programas de ciencia política pueden cuestionarse sobre los beneficios de hacer análisis empírico cuantitativo. Por lo tanto, el objetivo de este artículo es analizar las estrategias más comunes para utilizar métodos cuantitativos en el análisis político mediante diferentes ejemplos. La contribución de este artículo es acercar, por primera vez, al lector a la manera en la que se puede realizar investigación política a través de métodos cuantitativos.

Palabras clave: Métodos cuantitativos, ciencia política, modelos estadísticos, inferencia causal.

Abstract: A requirement in political research is to apply quantitative methods. In order to conduct empirical analysis, it is crucial to understand the appropriate techniques for describing, generalizing, identifying causality, and predicting. However, the utility of quantitative methods can become obscured amidst the intricacies of these techniques, leading new generations of students in political science programs to question the benefits of conducting quantitative empirical analysis. Therefore, this article aims to examine the most common strategies for employing quantitative methods in political analysis through various examples. The contribution of this text is to approach the reader to the manner in which political research can be developed through quantitative methods.

Keywords: Quantitative methods, political science, statistical models, causal inference.

—

Introducción

Los métodos cuantitativos son fundamentales para realizar análisis político empírico (Kellstedt y Whitten 2018; Huntington-Klein 2022; Salazar-Elena 2023). Sin embargo, su importancia se pierde en la complejidad de transmitir este tipo de conocimiento a nuevas generaciones de politólogos. Al hablar de métodos cuantitativos o de estadística aplicada a la política es común escuchar preguntas tales como ¿para qué me sirve esto?

Por lo tanto, la contribución de este artículo es señalar con claridad cuáles son los usos más frecuentes de los métodos cuantitativos en ciencia política. Salazar-Elena (2023) sugiere que son cuatro las principales estrategias que podemos seguir para utilizar correctamente los métodos cuantitativos: la descripción, la generalización, la identificación causal y la predicción. Por consiguiente, en este texto se reflexiona sobre cada una de ellas y se brindan ejemplos relacionados con la investigación política. En consecuencia, la estructura del artículo consta de una sección en la que se enmarca a los métodos cuantitativos como estudios observacionales para posteriormente analizar las cuatro estrategias antes señaladas. Por último, se establece un apartado de conclusiones en donde se reflexiona sobre la importancia de transmitir correctamente la utilidad de los métodos cuantitativos a estudiantes de ciencia política.

Los métodos cuantitativos como estudios observacionales

Los métodos cuantitativos forman parte de la caja de herramientas que se puede utilizar para hacer análisis político empírico y tratar de obtener resultados válidos; sin embargo, es importante entender que los métodos cuantitativos, al menos en el quehacer cotidiano de la ciencia política, son métodos observacionales. Esto implica que las personas que analizan fenómenos a través de estas herramientas no pueden controlar el proceso generador de datos (Keele 2020; Toshkov 2016) y tampoco existe la posibilidad de asignar de manera aleatoria el tratamiento (Huntington-Klein 2022; Kellstedt y Whitten 2018; Toshkov 2016); lo que conlleva que si utilizamos los conceptos *control* y *asignación aleatoria* para especificar una tipología, los métodos cuantitativos se encuentran en la casilla de los estudios observacionales, tal como puede observarse en la tabla 1. Por lo tanto, los estudios observacionales son una alternativa cuando no es posible realizar un estudio experimental.

Tabla 1.

		Asignación aleatoria	
		Sí	No
Control	Sí	Experimento tradicional	Cuasi experimento
	No	Experimento natural	Estudios observacionales

Fuente: Toshkov 2016.

Ahora bien, los métodos cuantitativos, en tanto estudios observacionales tienen características que es necesario reconocer. Por ejemplo, la utilización de estos métodos es apropiada cuando se desea obtener patrones generales, tendencias o promedios. Esto implica que necesitaremos una “gran” cantidad¹ de observaciones. Por lo tanto, si queremos hacer análisis con estas características será indispensable conocer las herramientas que brindan la probabilidad y la estadística. En este sentido, se puede afirmar que las tres propiedades fundamentales de los métodos cuantitativos, en tanto estudios observacionales son la búsqueda de patrones, tendencias o promedios, la utilización de una gran cantidad de observaciones y el manejo de las herramientas de la probabilidad y la estadística.

Cabe destacar que pensar los métodos cuantitativos mediante estas tres propiedades deja fuera de manera intencionada a otros dos elementos con los que la

¹ Para poder cumplir con los supuestos del Teorema del Límite Central, una “gran” cantidad de observaciones tiende a ser de más de 30.

literatura tradicional tiende a definirlos y que causan confusión: la objetividad y la deducción (Hernández-Sampieri y Mendoza Torres 2018). No es posible afirmar que los métodos cuantitativos sean objetivos; esto porque la objetividad no es una característica que provenga de las personas desde lo individual ni por la utilización de un método en particular (Popper 2002). Podríamos pensar a la objetividad a través de la crítica intersubjetiva de explicaciones que son sometidas a prueba empírica en diferentes investigaciones. La crítica ocurre precisamente en el proceso de dictaminación o evaluación de investigaciones que aspiran a formar parte del cuerpo de conocimientos existente y, si dos o tres personas, que no conocen a quienes dictaminan, consideran que sus propuestas son lo suficientemente sólidas para ser parte de la literatura, entonces puede decirse que tiene mayor nivel de objetividad (Popper 2002), independientemente de si utilizó métodos cuantitativos o cualitativos.

Asimismo, los métodos cuantitativos no son necesariamente deductivos. Esto querría decir que sólo se utilizan para someter a prueba empírica a las hipótesis deducidas de una teoría. Si bien es cierto que, los métodos cuantitativos son completamente consistentes y apropiados para someter a prueba las hipótesis que se derivaron deductivamente, no quiere decir que no se puedan utilizar de otra forma. Además, la implicación de que los métodos cuantitativos son deductivos usualmente lleva consigo la afirmación de que los métodos cualitativos son inductivos (Hernández-Sampieri y Mendoza Torres 2018). Lo anterior no se observa en la realidad. Pueden presentarse casos en los que los métodos cuantitativos son una excelente estrategia para generar hipótesis de forma inductiva o bien para reducir dimensiones en un fenómeno complejo. De hecho, el análisis factorial exploratorio está pensado precisamente para eso. De la misma forma, hay investigaciones en las que métodos cualitativos tales como el rastreo de procesos y el análisis cualitativo comparado son utilizados para evaluar hipótesis que se derivaron de manera deductiva.

Los métodos cuantitativos como estrategia para describir fenómenos

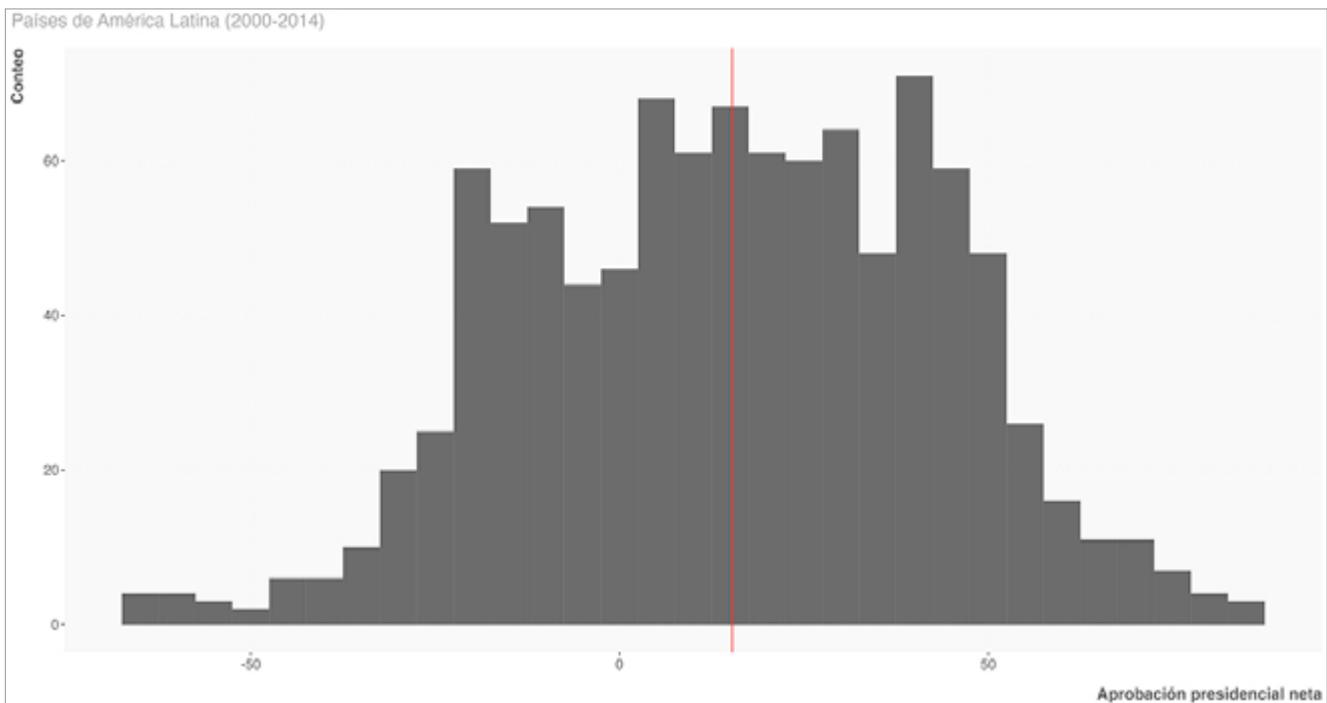
Posiblemente el primer uso de los métodos cuantitativos en la investigación política es el de responder a la pregunta ¿cómo? En otras palabras, para describir las propiedades más relevantes del comportamiento que tiene alguna variable. Esto se conoce usualmente como estadística descriptiva.

En este sentido, podríamos comenzar a preguntarnos por algunas características relevantes del comportamiento o, mejor dicho, de la distribución de una variable

(Mendenhall, Beaver y Beaver 2010). Usualmente, las primeras características que se buscan son el centro y el ancho de la distribución; esto nos lleva a estimar resúmenes numéricos simples como las medidas de tendencia central y de dispersión. Al realizar este tipo de procedimientos, inmediatamente se pueden localizar los valores comunes, la dispersión promedio de las observaciones, así como localizar datos atípicos, si los hubiere. La investigación política tiene múltiples variables que nos permiten utilizar esta estrategia.

Por ejemplo, en la figura 1 se presenta un histograma que muestra la distribución de la aprobación presidencial neta para los países de América Latina del 2000 al 2014 (Urdinez y Cruz 2021). Se colocó una línea de referencia de color rojo para distinguir el promedio. Esta variable mide el porcentaje de aprobación que tienen los presidentes en el periodo de estudio menos el porcentaje de desaprobación.

Figura 1. Histograma de la aprobación presidencial neta.



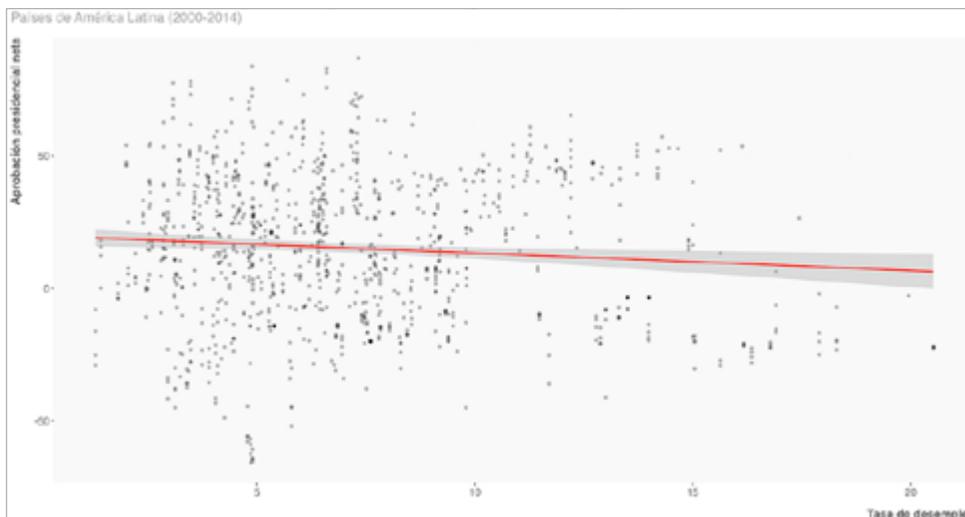
Fuente: elaboración propia con base en el paquete (politicalds) de Urdinez y Cruz (2020).

El promedio fue de 15.28, por lo que, la línea roja se encuentra precisamente en este valor. Se observa un comportamiento aproximadamente simétrico, sin menoscabo de las dos barras finales del lado izquierdo, las cuales indican un ligero incremento de presidentes con altos niveles de desaprobación. Se observa que hay una variación importante, ya que la desviación estándar es de 27.82, por lo que, en promedio, las observaciones se desvían en esta cantidad de la media que se encuentra en la línea roja.

De la misma forma, describir fenómenos de manera cuantitativa incluye la asociación entre variables. Por lo tanto, es posible evaluar el nivel en el que dos variables tienen variación conjunta. Existen diferentes técnicas para medir la variación conjunta entre dos variables. Por ejemplo, la correlación de Pearson, de Spearman, de Kendall o la prueba Chi cuadrada, por mencionar sólo algunas. La técnica apropiada dependerá del tipo de variables que se utilicen, así como de su distribución y del número de observaciones.

Si retomamos la variable de aprobación presidencial, podríamos argumentar que ésta se relaciona con el desempeño de los gobernantes. Una manera de evaluar el desempeño es a través de la creación de empleo, por lo que deberíamos esperar que, conforme aumente el desempleo, disminuya la aprobación presidencial. Por lo tanto, en la figura 2 se presenta un diagrama de dispersión en el que se analiza esta relación.

Figura 2. Gráfico de dispersión de la aprobación presidencial neta y la tasa de desempleo



Fuente: elaboración propia con base en el paquete (politicalds) de Urdinez y Cruz (2020).

Como puede observarse, existe una ligera relación negativa entre la aprobación presidencial y el desempleo, por lo que, si una aumenta, se espera que la otra disminuya, aunque no en los niveles que podríamos pensar intuitivamente. La correlación, aunque estadísticamente significativa ($p < 0.01$) es de -0.08 . Esto implica que la asociación lineal, medida a través de la correlación de Pearson podría resultar contraintuitiva. Esto ya es un hallazgo en sí mismo, ya que, a través de una visualización y una estimación sencillas, como son el gráfico de dispersión y la correlación, se puede comenzar a explorar la forma en la que dos o más variables se comportan juntas.

Los métodos cuantitativos como estrategia de generalización

Una vez que se tiene la información descriptiva sobre cómo se comporta un fenómeno, es posible que nos preguntemos qué tan generalizable es esa información. En otras palabras, nos podemos cuestionar si los patrones que se observan en una muestra son aplicables a una población. En este terreno, los métodos cuantitativos son de particular utilidad a través de la estadística inferencial.

Realizar una inferencia estadística implica medir la incertidumbre con la que analizamos datos muestrales. En consecuencia, se asume de manera explícita que, por ejemplo, un promedio obtenido en una muestra nos brinda poca información acerca del comportamiento de la población. Para corregir este problema, se incorpora la incertidumbre a partir de la medición del error estándar. De esta forma, podemos obtener límites al error de nuestras estimaciones, los cuales se conocen como intervalos de confianza (Scheaffer, Mendenhall y Ott 2007).

Los intervalos de confianza brindan un rango de valores en los que se encontrará el verdadero parámetro poblacional. Usualmente, el nivel de confianza aceptado ronda entre el 90 y el 99%, siendo el 95% el más utilizado. Esto quiere decir que, los métodos cuantitativos nos permiten realizar afirmaciones como la siguiente: si se asume muestreo repetido, el verdadero valor de una media poblacional se encontrará entre el límite inferior y el límite superior del intervalo con un cierto nivel de confianza (por ejemplo, 95%).

Además de medir la incertidumbre, los métodos cuantitativos nos ayudan a encontrar el nivel de evidencia a favor que posee determinada afirmación (Mendenhall, Beaver, y Beaver 2010). Esto es el terreno de las pruebas de hipótesis. En este sentido, una hipótesis es una afirmación que realizamos sobre el comportamiento de la población.

Por ejemplo, se podría declarar que, en promedio, la aprobación de las presidentas es diferente a la de los presidentes en América Latina entre el 2000 y el 2014. Esto nos llevaría a una prueba de hipótesis de diferencia de medias. De esta manera, es importante establecer cuál será la hipótesis nula y cuál la alternativa. En este caso, la hipótesis nula será que, en promedio, la aprobación presidencial es igual para ambos géneros y la alternativa será que la aprobación es diferente. Al utilizar los mismos datos que en el ejemplo previo, se encuentra que la aprobación promedio de las presidentas es de 8.93 y la de los presidentes es de 15.96. La conclusión es que se puede rechazar la hipótesis nula y se puede afirmar con un nivel de confianza del 99% ($p < 0.01$) que el nivel de aprobación es diferente

entre presidentes y presidentas y, de hecho, se observa que los presidentes tienen a ser mejor aprobados en promedio. En la tabla 2 se muestran estos resultados al utilizar R.

Tabla 2.

Test statistic	df	P value	Alternative hypothesis	mean of x	mean of y
2.764	128.8	0.006551 * *	two.sided	15.96	8.932

Fuente: elaboración propia con base en la librería de R (politicalds) de Urdinez y Cruz (2021).

Los métodos cuantitativos como estrategia de identificación causal

Una ventaja que presentan los métodos cuantitativos y, en general, cualquier aplicación matemática para el análisis político es que los supuestos de los que se parte son explícitos (King, Keohane, y Verba 1994). En este sentido podríamos hablar de dos supuestos fundamentales: la “señal” y el “ruido” en la información. Esto quiere decir que la información que se obtiene en el mundo empírico posee algún nivel de “estructura”, por lo que tomar la información de la unidad X podría ser de utilidad para entender a la unidad Y (Toshkov 2016).

Por ejemplo, se podrían tomar las características institucionales de algún país en América Latina, tales como el federalismo o el tipo de sistema electoral y analizar la manera en la que funciona en dichos contextos. De esta forma, se podría conocer un aproximado del comportamiento de estas características institucionales en países en los que se presenten, aunque dichos países no sean parte original de la muestra estudiada. Cuando se tiene una gran cantidad de observaciones en una población, la idea es que una muestra puede brindarnos información sobre lo que no observamos directamente en esa población. A esta estructura en los datos se le puede denominar la *señal*.

Sin embargo, la señal que brindan los datos puede ser difusa. Si no fuera el caso, bastaría con el análisis de una sola unidad para entender la totalidad de la población. Esto conllevaría a la carencia de variación. En consecuencia, la señal que brindan los datos, y que será analizada a través de métodos cuantitativos tiene que considerar que habrá *ruido* en los datos. Por lo tanto, en una investigación que utilice métodos cuantitativos, se tiene que saber que se asume la existencia de señal –la estructura de los datos– y la existencia del ruido –datos difusos–, y entonces será necesario el análisis de múltiples observaciones. Además, el tener una cantidad

importante de observaciones le permitirá a la persona que realiza la investigación estar en posibilidad de diferenciar los patrones generales de procesos que sean aleatorios (Huntington-Klein 2022).

Ahora bien, al separar el componente sistemático del aleatorio en los datos entraremos en un proceso de identificación de causalidad. Esto quiere decir que los métodos cuantitativos pueden estimar en qué medida una variable de tratamiento puede ser una causa de una variable de resultado. En este sentido, es importante señalar que la causalidad entre las variables no es una característica observable en el mundo empírico, por lo tanto, tenemos que realizar una inferencia particular: una inferencia causal (Huntington-Klein 2022; King, Keohane, y Verba 1994; Morgan y Winship 2014).

Posiblemente, la perspectiva sobre identificación causal más aceptada por la ciencia política en este momento es el modelo contrafactual (Morgan y Winship 2014; Salazar-Elena 2021). Esta perspectiva propone una definición de causalidad en la que una causa “es algo que produce una diferencia, y que la diferencia que produce debe ser una diferencia con respecto a lo que habría ocurrido sin ella” (Lewis 1973, 557). Esto quiere decir que una variable de tratamiento es causal si y sólo si, al modificarla, se modifica también el resultado, manteniendo todos los demás factores controlados (Toshkov 2016).

Al entender la causalidad a través del modelo contrafactual, es indispensable plantear dos estados potenciales del mundo: el estado de tratamiento y el estado de control (Morgan y Winship 2014). En consecuencia, para identificar el efecto causal se tendría que calcular un valor de la variable de resultado en ambos estados del mundo: en presencia y en ausencia de la variable de tratamiento. Esto implica que, al realizar una resta simple entre los dos valores de la variable de resultado podríamos identificar si hubo cambios que se atribuyan a la variable de tratamiento y, por consiguiente, estaríamos en posibilidad de hablar de un efecto causal.

Sin embargo, esta perspectiva plantea también un problema de imposibilidad en términos empíricos, ya que, por definición, uno de los dos estados potenciales es hipotético; no se observa en el mundo empírico. Esto se conoce como el problema fundamental de la inferencia causal (Toshkov 2016; Huntington-Klein 2022; Morgan y Winship 2014; Salazar-Elena 2021). El problema fundamental de la inferencia causal es evidente en un ejemplo: imaginemos que estamos interesados en identificar el efecto causal que tiene el otorgar una beca de estudios a una persona en su desempeño académico. De conformidad con la definición de causalidad planteada, necesitaríamos observar a la misma persona con y sin beca para poder comparar los cambios en el desempeño académico en ambos estados del mundo.

No obstante, resulta imposible observar a la misma persona con y sin beca al mismo tiempo y mantener constantes todos los demás factores.

En este sentido, se podría caer en errores al tratar de manejar el problema fundamental de la inferencia causal. Si mantenemos el mismo ejemplo, alguien podría sugerir que bastaría con hacer una medición de las calificaciones de la persona antes y después de tener beca. Si bien es cierto, esta estrategia podría acercarnos a la identificación del efecto causal, por sí misma no resuelve necesariamente el problema. Veamos las razones.

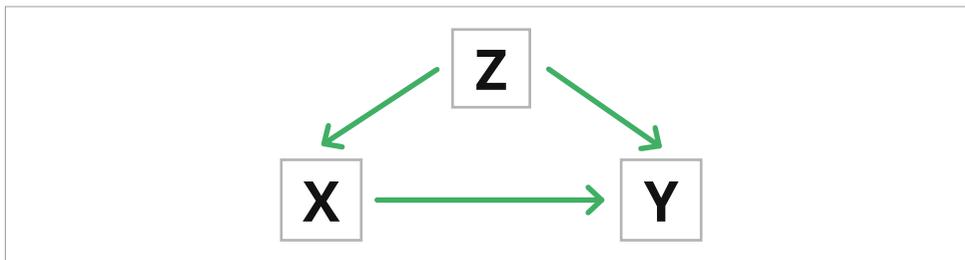
Imaginemos que tomamos la medición del desempeño académico de la persona antes y después de otorgar la beca y hacemos una comparación en la que el resultado sugiere que las notas se incrementaron con respecto al periodo sin beca. Aunque esto podría parecer una buena noticia, sería ingenuo pensar que se debe a la beca, o al menos únicamente a la beca. Esto es así porque más de una variable pudo modificarse al mismo tiempo en el que se pasó de no tener beca a tenerla y pudo afectar tanto a la posibilidad de tener beca como al desempeño académico.

Por ejemplo, imaginemos que la madre de la persona a la que le otorgamos la beca consigue un empleo en el que su ingreso se vuelve cuatro veces más alto: ¡el mundo perfecto! Frente a esta situación sería posible argumentar que el aumento en las notas se debe a que la madre de la persona tiene más recursos para invertir en la educación de la persona a la becamos. Por lo tanto, la beca no tendría el efecto que se anticipaba, ya que, en el mejor de los casos, no sería el único factor causal y estaríamos confundiendo su efecto con el que tuvo otra variable que “se movió” al mismo tiempo.

Para que este efecto de “confusión” de los efectos sea más evidente imaginemos la siguiente situación: la persona que recibió la beca y cuya madre cuadruplicó los ingresos familiares comienza a darse cuenta de que el nuevo empleo de su madre está causándole a ésta problemas de salud al incrementar el estrés. De igual forma, sería relativamente sencillo argumentar que los problemas de salud de familiares cercanos tienen un efecto en el desempeño académico. Por lo tanto, si observamos que la persona con beca (y con una madre con problemas de salud) comienza a tener notas que disminuyen, ¿podríamos afirmar que la beca tuvo un efecto causal para disminuir las calificaciones? La respuesta evidente es que no, ya que las razones tienen que ver con la otra variable que afectó el resultado. Las variables que tienen este comportamiento en el que afectan al mismo tiempo a la variable de tratamiento y a la de resultado, se denominan variables confusoras y tienen una estructura como la que se observa en la figura 3. En dicha figura se presenta un diagrama de configuración causal con una variable confusora.

Este diagrama se encuentra en su mínima expresión y representa una estructura causal con la que necesitamos tener precaución, ya que una variable confusora necesita ser controlada a partir de su incorporación en un modelo estadístico.

Figura 3.



Fuente: elaboración propia.

Por lo tanto, queda de manifiesto que para tener un mejor manejo del problema fundamental de la inferencia causal y realizar inferencias causales que sean válidas, se necesita un diseño de investigación apropiado. En este sentido, los métodos cuantitativos podrían seguir una estrategia en la que se “controle” a las variables confusoras. Esta estrategia se conoce como condicionamiento (Toshkov 2016).

La estrategia de condicionamiento permite que se incorporen variables de control y se tome en consideración el principio *ceteris paribus* para intentar aproximarse en la medida de lo posible a un escenario contrafactual en el que las variables que se controlan explícitamente –las variables confusoras– en un modelo estadístico permanecen constantes. De esta forma estaremos en mejores posibilidades de aislar el efecto de interés (Kellstedt y Whitten 2018). Asimismo, esta estrategia es posiblemente la más común al utilizar métodos cuantitativos (Toshkov 2016), ya que permite aproximarse a los dos estados potenciales en promedio. Sin embargo, la incertidumbre será irreductible en el sentido de que es probable que existan variables confusoras que no son observables o que simplemente no conocemos, por lo que resulta imposible saber con seguridad si se han controlado por todos los factores relevantes. En consecuencia, la posibilidad de incurrir en sesgo de variable omitida siempre estará presente (Wooldridge 2012).

Algunos de los diseños que se utilizan en la investigación política para tratar de identificar efectos causales a través de la estrategia de condicionamiento son la incorporación de datos panel, las estimaciones de diferencia en diferencias, las variables instrumentales, el *matching* y la regresión discontinua. El diseño de datos panel requiere que las unidades de análisis se repitan en el tiempo para tener,

por lo menos, dos puntos temporales (Wooldridge 2001). De esta forma se pueden controlar variables confusoras que son inobservables. Por ejemplo, los modelos con efectos fijos, al estimar interceptos para cada unidad estudiada en un modelo, controlan por variables inobservables que no cambian a lo largo del tiempo pero que sí lo hacen entre las propias unidades (Clark y Linzer 2015).

Por su parte, el diseño de diferencia en diferencias también necesita que las observaciones tengan dos puntos temporales –antes y después del tratamiento– y, además, se requiere de una variable que agrupe observaciones en las que fueron tratadas y las que permanecieron en estado de control (Keele 2020). De esta forma, se pueden descontar –algunos– de los efectos de variables inobservables que variaron al mismo tiempo. Es una operación sencilla en la que se realizan tres restas:

tratamiento después – tratamiento antes – control después – control antes.

El modelo de variables instrumentales asume la existencia de una variable que sólo se relaciona con la variable de resultado a través de la variable de tratamiento y no es afectada por ninguna variable confusora (Toshkov 2016; Lind 2020). Si existe dicha variable, se considera como un instrumento de la variable de tratamiento y se genera un modelo en dos etapas. En la primera etapa se utiliza la variable instrumental para explicar la variación de la variable de tratamiento original y se guardan los valores predichos. Esto permite descontar toda la variación de la variable de tratamiento que no depende del instrumento. El segundo paso consiste en utilizar los valores predichos de la primera etapa como una nueva variable de tratamiento para explicar a la variable de resultado. Esto permite aislar el efecto de interés al eliminar el efecto de las variables confusoras.

El diseño de *matching* o emparejamiento parte de la idea de comparar observaciones relativamente semejantes. Esto quiere decir que se seleccionarán observaciones en el grupo de tratamiento y se compararán con aquellas observaciones más similares en el grupo de control (King y Nielsen 2019). De esta forma se trata de estimar efectos promedio del tratamiento al hacer comparaciones que sean válidas. Este tipo de diseño es particularmente útil para realizar estimaciones de impacto de políticas públicas (Van Gameren y Enciso 2022).

Por último, el diseño de regresión discontinúa asume la existencia de un umbral especificado en los datos de manera arbitraria, de tal forma que se separen en grupos de control y de tratamiento. Al ser una separación arbitraria, el diseño de regresión discontinua sugiere que las observaciones que se encuentran en el límite del umbral en ambos grupos no son sustantivamente diferentes, por lo que podría realizarse una comparación entre ellas para estimar efectos causales (Imbens

y Lemieux 2008; Marshall 2022). Por ejemplo, si se reparte una beca a estudiantes que obtuvieron 8 de promedio general, se podría pensar que quienes obtuvieron 7.9 no son personas sustantivamente diferentes de quienes obtuvieron 8, pero las primeras no obtuvieron la beca y las segundas sí, por lo que lo “único” que se modificó fue tener o no la beca, razón por la cual se podría establecer una comparación e identificar efectos causales.

Los métodos cuantitativos como estrategia de pronóstico

Para finalizar, los métodos cuantitativos pueden ser de particular utilidad para pronosticar, con determinado nivel de probabilidad, el resultado de ciertos fenómenos. Es importante señalar que no se trata de “adivinar” lo que ocurrirá, sino que, a través de algún modelo o algoritmo, estimar la probabilidad de ocurrencia de los diferentes resultados. Un gran ejemplo de esto, así como de sus problemas, es la estimación que realizó la página *FiveThirtyEight* sobre los resultados electorales presidenciales de 2016 en Estados Unidos.

En dicho portal, el estadístico Nate Silver, a través de un modelo que toma en consideración las encuestas de opinión, así como el comportamiento de la economía y datos históricos, pronosticó que Hillary Clinton tenía una probabilidad de 71.8% de ganar, mientras que el cálculo de Donald Trump fue de 28.2% (Silver 2016). En este momento, ya es sabido por todo el mundo el resultado electoral del 8 de noviembre de 2016: Donald Trump ganó. Por lo tanto, se podría pensar que Silver cometió algún error, sin embargo, no es necesariamente el caso.

Si pensamos en la probabilidad de ganar de Trump, que es poco menos de 30%, en realidad, su triunfo no era tan improbable. Esto es especialmente claro si recordamos que, al interpretar p-valores aceptados por la comunidad, tendemos a rechazar las hipótesis nulas cuando la probabilidad es menor al 10, 5 o 1%. Por lo que, si en cualquier prueba de hipótesis se observara una probabilidad de 28.2%, no se podría rechazar la hipótesis nula. Por ejemplo, si la hipótesis nula fuera que Trump obtendría más asientos en el Colegio Electoral que Clinton y el p-valor resultante fuera de 0.282, no habría manera de rechazarla y no se podría descartar el triunfo de Trump. Eso es exactamente lo que pasó. Si bien es cierto que era más probable el triunfo de Clinton, no se podía descartar que Trump ganara. Por esta razón es que los pronósticos que se desarrollan en los métodos cuantitativos son probabilísticos. Se mide la incertidumbre y la probabilidad de ocurrencia. De esta manera, corresponde a las personas realizar una correcta interpretación de las probabilidades.

Conclusiones

La utilización de los métodos cuantitativos en la investigación política es un campo abierto y fértil, ya que las herramientas estadísticas brindan un amplio abanico de posibilidades para realizar ciencia política empírica. Como conclusión, quisiera cerrar con dos ventajas que presentan los métodos cuantitativos para quien desee utilizarlos en una investigación.

En primer lugar, aunque parezca una verdad de Perogrullo, la medición de efectos es un elemento relevante al realizar investigaciones empíricas. Al teorizar la relación entre dos variables, usualmente se habla de si existirá una relación positiva o negativa, pero también es posible preguntarnos cuál es la magnitud del efecto de nuestra variable de tratamiento sobre nuestra variable de resultado. La identificación de un efecto que sea medible y comparable en términos de su magnitud permite que podamos recabar evidencia sólida, verificable y con mayor nivel de validez. En segundo lugar, quisiera destacar la replicabilidad. Que una investigación sea replicable aumenta la transparencia en el proceso de producción del conocimiento. De esta forma, es posible analizar no solamente los resultados, sino cada paso dentro del proceso de obtención de los hallazgos. En este sentido, la forma en la que se desarrolla la evidencia empírica a través de métodos cuantitativos permite de manera natural que se registren bitácoras en donde se observe la secuencia de código, de funciones o comandos que se siguieron para llegar a un hallazgo. Esto permite una evaluación más rigurosa de la evidencia y minimiza la posibilidad de fabricar evidencia.

En consecuencia, las personas que realicen investigación política empírica necesitan tener claridad no sólo de las diferentes técnicas, sino de cómo utilizarlas en su quehacer profesional. Por razón, este artículo presenta diferentes formas en las que se pueden emplear los métodos cuantitativos para el análisis de fenómenos políticos. Mi idea es ampliar la discusión y acercar a nuevo público este tipo de herramientas.

En virtud de que los métodos cuantitativos conllevan intrínsecamente una preparación en estadística, se podrían pensar como una disciplina alejada de la política. No obstante, queda de manifiesto que no es así, por lo que resulta importante que desde las aulas se muestre la utilidad de estos métodos. En consecuencia, utilizar ejemplos relacionados con la disciplina es labor de profesoras y profesores de métodos cuantitativos en programas de ciencia política. Los ejemplos de libro de texto son útiles, pero es importante transitar hacia la utilización de variables políticas. De esta forma se puede mostrar cómo los politólogos pueden tener mejores posibilidades en el mundo laboral al realizar investigación empírica sólida a través de los métodos cuantitativos. —

Referencias

- Clark, Tom S., y Drew A. Linzer. 2015. "Should I Use Fixed or Random Effects?" *Political Science Research and Methods* 3 (2): 399–408. <https://doi.org/10.1017/psrm.2014.32>
- Van Gameren, Edwin & Níobe Enciso. 2023. "The Impact of Seguro Popular on the Progression of Disabilities Among Older Adults With Chronic Degenerative Diseases in Mexico." *Research on Aging* 45 (9–10): 599–608. <https://doi.org/10.1177/01640275221146283>
- Hernández-Sampieri, Roberto, y Christian Paulina Mendoza Torres. 2018. *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta*. México: McGraw Hill– education.
- Huntington-Klein, Nick. 2022. *The Effect: An Introduction to Research Design and Causality*. Boca Raton: Routledge.
- Imbens, Guido W., y Thomas Lemieux. 2008. "Regression Discontinuity Designs: A Guide to Practice." *Journal of Econometrics*, The regression discontinuity design: Theory and applications, 142 (2): 615–635. <https://doi.org/10.1016/j.jeconom.2007.05.001>
- Keele, Luke. 2020. "Differences-in-Differences: Neither Natural nor an Experiment". En *The SAGE Handbook of Research Methods in Political Science and International Relations*, editado por Luigi Curini y Robert Franzese, 822–834. SAGE Publications Ltd. <https://doi.org/10.4135/9781526486387>
- Kellstedt, Paul M., y Guy D. Whitten. 2018. *The Fundamentals of Political Science Research*. 3a ed. Cambridge: Cambridge University Press. <https://doi.org/10.1017/9781108131704>
- King, Gary, Robert O. Keohane, y Sidney Verba. 1994. *Designing Social Inquiry. Scientific Inference in Qualitative Research*. New Jersey: Princeton University Press.
- King, Gary, y Richard Nielsen. 2019. "Why Propensity Scores Should Not Be Used for Matching". *Political Analysis* 27 (4): 435–454. <https://doi.org/10.1017/pan.2019.11>
- Lewis, David. 1973. "Causation". *The Journal of Philosophy* 70 (17): 556–567. <https://doi.org/10.2307/2025310>
- Lind, Jo Thori. 2020. "Rainy Day Politics. An Instrumental Variables Approach to the Effect of Parties on Political Outcomes." *European Journal of Political Economy* 61 (enero): 101821. <https://doi.org/10.1016/j.ejpoleco.2019.101821>
- Marshall, John. 2022. "Can Close Election Regression Discontinuity Designs Identify Effects of Winning Politician Characteristics?" *American Journal of Political Science* 00 (00): 1–17. <https://doi.org/10.1111/ajps.12741>
- Mendenhall, William, Robert J. Beaver, y Barbara M. Beaver. 2010. *Introducción a la probabilidad y estadística*. México: Cengage Learning.
- Morgan, Stephen L., y Christopher Winship. 2014. *Counterfactuals and Causal Inference. Methods and Principles for Social Research*. 2a ed. (Analytical Methods for Social Research). Cambridge: Cambridge University Press. <https://doi.org/10.1017/CBO9781107587991>
- Popper, Karl. 2002. *The Logic of Scientific Discovery*. London, New York: Routledge Classics.
- Salazar-Elena, Rodrigo. 2021. "El modelo contrafáctico de la inferencia causal ¿Por qué la correlación no implica causalidad? (Breviarios digitales)." Facultad Latinoamericana de Ciencias Sociales. https://drive.google.com/file/d/1OZpY_wHbBH96IFLSfRFbwA05-KBnIVZn/view.
- Salazar-Elena, Rodrigo. 2023. "Relevancia de la estadística y los métodos cuantitativos para la ciencia política [Conferencia]". Presentada en Tercer ciclo de métodos y técnicas de investigación social, Facultad de Estudios Superiores Acatlán UNAM, febrero 22.
- Scheaffer, Richard L., William Mendenhall III y R. Lyman Ott. 2007. *Elementos de muestreo*. Madrid: Paraninfo.
- Silver, Nate. 2016. "2016 Election Forecast". FiveThirtyEight. Revisado el 29 de junio, 2016. <https://projects.fivethirtyeight.com/2016-election-forecast/>
- Toshkov, Dimitar. 2016. *Research Design in Political Science*. London: Palgrave Macmillan.
- Urdinez, Francisco y Andrés Cruz. 2021. *R for Political Data Science. A Practical Guide*. Florida: Taylor & Francis Group.
- Wooldridge, Jeffrey M. 2012. *Introductory econometrics: a modern approach*, 5th edition. Ohio: South-Western Cengage Learning.
- Wooldridge, Jeffrey M. 2001. *Econometric Analysis of Cross Section and Panel Data*. Massachusetts: MIT Press.