

# METODOLOGÍA DE LA INVESTIGACIÓN EN PSICOLOGÍA

**LEANDRO M. CASARI**  
(compilador)

**Colaboradores**

C. Arias	F. Ghio	L. Mariñelarena
S. Brussino	A. Giugno	Dondena
M. del Valle	J. C. Godoy	A. Marquez Terraza
F. Donadel	C. Greco	J. A. Mema
A. M. Elgier	M. del C. Hernández	V. Morán
A. Ferrandiz	Escalona	G. Morelato
L. G. Gago-Galvagno	M. S. Ison	M. Richard's
S. J. Garrido	H. Klappenbach	M. Valgañón
R. Gelpi-Trudo	E. L. Morales	S. Vázquez Ferrero
		E. Zamora

---

**METODOLOGÍA  
DE LA INVESTIGACIÓN  
EN PSICOLOGÍA**

**Objetivos, métodos y resultados**

**PAIDÓS**

# ÍNDICE

<b>Los autores.....</b>	12
<b>Los revisores.....</b>	13
<b>Introducción, Leandro Martín Casari .....</b>	15
PARTE 1	
<b>La investigación profesional: competencias, supervisión y contexto argentino</b>	
<b>Capítulo 1. Historia de la investigación en Psicología en la Argentina, Sebastián Vázquez Ferrero, Luciana Mariñelarena Dondena y Hugo Klappenbach .....</b>	
29	
La importancia de la investigación en la formación del psicólogo.....	30
Para qué investigar en el campo de la Psicología.....	33
<b>Capítulo 2. ¿Cómo ser un buen investigador y no morir en el intento?, Silvina Brussino y Juan Carlos Godoy.....</b>	
43	
¿Enseñar sobre métodos de investigación es enseñar a investigar? .....	45
¿Qué necesito saber para hacer una investigación? .....	47
La formación en investigación en el posgrado: la formación doctoral y los tipos de doctorado.....	50
Últimas consideraciones .....	54
<b>Capítulo 3. Encontrando a nuestro maestro Jedi: ¿cómo elegir a un director para una tesis?, Angel Elgier y Mery del Carmen Hernández Escalona .....</b>	
57	
Estilos de supervisión .....	58
Desafíos en la interacción director-tesista .....	59
Compatibilidad y expectativas, 60; Apoyo social y emocional del tesista, 61	
Conclusión y palabras finales.....	64

## PARTE 2

### **El planteo del Problema en investigación: rastreo bibliográfico, objetivos y preguntas de investigación, relevancia y financiamiento**

<b>Capítulo 4. No reinventarás la rueda: ¿cómo hacer el rastreo bibliográfico?, Leandro Martín Casari .....</b>	69
¿Cuándo ocurre o debe ocurrir el rastreo de antecedentes?.....	69
¿Dónde debemos realizar el rastreo de antecedentes? .....	70
¿Cómo hacer el rastreo bibliográfico?.....	73
¿Qué tipo de resultados necesitamos encontrar con nuestra búsqueda?... .....	76
¿Cómo escribir el estado actual del tema? .....	78
<b>Capítulo 5. ¿El Problema de investigación o la investigación en problemas? La relevancia del planteamiento del Problema, Mirta Susana Ison.....</b>	83
¿Cuáles son los elementos que debemos considerar para la fundamentación del problema? .....	86
¿Cuáles son los errores más frecuentes en la fundamentación del problema?, 88	
La pregunta de investigación .....	90
Los objetivos de la investigación .....	92
Conclusión .....	94
<b>Capítulo 6. “No hay plata”: investigaciones financiadas o investigaciones autogestionadas, Juan Carlos Godoy y Silvina Brussino.....</b>	97
Un poco de historia .....	97
La importancia de la factibilidad .....	100
Becas nacionales e internacionales para la investigación .....	104
Para finalizar (o empezar) .....	107

## PARTE 3

### **El método en la investigación: instrumentos, muestra y análisis de datos**

<b>Capítulo 7. Instrumentos cuantitativos de recolección de datos, Macarena del Valle, Rosario Gelpi-Trudo, Camila Arias y Eliana Zamora .....</b>	111
El concepto de medición en psicología y ciencias afines .....	111
Instrumentos de medición .....	112
Los tests de rendimiento o tareas de ejecución, 112; Las escalas de medición, 114; Cuestionarios y encuestas, 116; Otro tipo de mediciones utilizadas en psicología, 117	

Criterios psicométricos .....	118
Objetividad, validez y confiabilidad, <b>118</b> ; Problemas adicionales con las mediciones, <b>120</b>	
Seleccionando un test para una investigación.....	121
¿Dónde buscar test psicométricos?, <b>121</b> ; ¿Cómo elegir entre distintos instrumentos disponibles?, <b>123</b> ; ¿Qué información debo colocar en la descripción de un instrumento psicométrico?, <b>124</b>	
Comentarios finales .....	126
<b>Capítulo 8. Muestra y análisis cuantitativo de datos,</b> <i>Lucas Gago-Galvagno</i> .....	131
Acerca del muestreo.....	131
Tipos de muestreo, <b>133</b> ; Acerca del tamaño muestral, <b>135</b>	
Preprocesamiento y tipos de análisis de datos .....	138
Tipos de software para el análisis de datos, <b>141</b> ; Interpretación de los resultados y consideraciones éticas, <b>142</b>	
Conclusión .....	143
<b>Capítulo 9. Instrumentos cualitativos de indagación de datos,</b> <i>Carolina Greco y Gabriela Morelato</i> .....	147
La observación.....	149
La entrevista .....	151
Entrevista en profundidad, <b>152</b> ; Grupos focales, <b>155</b>	
Documentos .....	160
Materiales audiovisuales .....	160
Bitácora de campo.....	161
Reflexiones finales .....	162
<b>Capítulo 10. Muestra y análisis cualitativo de datos,</b> <i>Emilse Lucero Morales y Ana Marquez Terraza</i> .....	165
¿Qué es el muestreo?.....	167
Tipos de muestreo .....	169
Incidental o azaroso, <b>169</b> ; Intencionado o determinado (teórico), <b>172</b> ; Bola de nieve o encadenado (avalancha/ combinado/ en cadena), <b>175</b> ; Proceso de muestreo, <b>179</b>	
Saturación teórica .....	180
Consideraciones claves sobre la saturación teórica en un muestreo cualitativo, <b>181</b>	
Análisis cualitativo de datos: ¿qué es? .....	182
¿Qué y cómo analizo?, <b>184</b> ; Softwares: ¿cuáles y para qué?, <b>186</b>	
Conclusiones.....	187

## PARTE 4

**El método en la investigación: diseño y procedimiento**

<b>Capítulo 11. Los diseños cuantitativos de investigación y la pirámide de la evidencia, Leandro Martín Casari .....</b>	193
Diseños de caso único.....	195
Diseños transversales .....	196
Diseños longitudinales.....	199
Diseños experimentales .....	201
Metaanálisis y revisiones sistemáticas.....	204
Conclusiones.....	206
<b>Capítulo 12. Diseños cualitativos de investigación, Ana Márquez Terraza y Emilse Lucero Morales .....</b>	209
¿Para qué un diseño? .....	210
Elementos del diseño .....	212
Mapeo, <b>214</b> ; Elección de los participantes, <b>216</b> ; Temporalidad, <b>217</b> ; Fuentes de datos, <b>219</b>	
Método .....	220
Método narrativo, <b>221</b> ; Método fenomenológico, <b>222</b> ; Método de investigación-acción participante, <b>222</b> ; Método de teoría fundamentada, <b>223</b> ; Método de estudio de caso, <b>224</b> ; Método etnográfico, <b>225</b>	
No es una elección: es una construcción, y es permanente .....	227
<b>Capítulo 13. ¿Cuali-Cuanti o Cuanti-Cuali? Contribuciones para la investigación desde los enfoques mixtos, Gabriela Morelato, Franco Donadel, Agustina Ferrandiz y Mónica Valgañón .....</b>	231
Algunas características generales acerca de los métodos mixtos .....	231
Caminar en lo mixto. Una propuesta para dar los primeros pasos.....	237
Las decisiones metodológicas para la aplicación de métodos mixtos .....	241
Conclusiones.....	246
<b>Capítulo 14. Recolección de datos y devolución de los resultados, José Antonio Mema y Antonella Giugno .....</b>	249
Ética en la investigación.....	249
Consentimiento Informado (CI), <b>250</b> ; Comités de Ética de Investigación (CEI), <b>254</b>	
Recolección de datos.....	256
Métodos de recolección de datos: <i>online</i> vs. tradicionales, <b>256</b>	
Devolución de los resultados .....	263

Aspectos para considerar en la devolución de los resultados, <b>264</b>	
Conclusiones.....	265
 <b>PARTE 5</b>	
<b>La etapa final de la investigación: la Discusión de los Resultados y estrategias para la difusión científica</b>	
 <b>Capítulo 15. De la teoría a la práctica: estrategias y desafíos en la escritura de la Discusión, Eliana Zamora, Camila Arias, Macarena del Valle y María Richard's.....</b>	
	271
El orden de los factores sí altera el producto.....	272
Escribir con estilo: la redacción de la Discusión científica.....	275
Desafíos de la Discusión .....	278
Estrategias para superar los desafíos, <b>281</b>	
Conclusiones.....	284
 <b>Capítulo 16. La ciencia a la vuelta de la esquina: ¿cómo comunicar nuestros resultados en medios científicos?, Valeria Morán, Sebastián Garrido y Fernanda Ghio.....</b>	
	287
Pero... ¿realmente la ciencia está a la vuelta de la esquina? .....	289
El artículo científico: no hay rosa sin espinas .....	290
Selección de la revista, <b>291</b> ; Adaptación del manuscrito a las normas de la revista, <b>295</b> ; Envío del manuscrito, <b>298</b> ; Proceso de revisión, <b>299</b> ; PrePrint, <b>301</b>	
¡Brilla en el escenario! Presentaciones en eventos científicos .....	302
Postulación sin sorpresas: ¿Qué considerar antes de enviar las presentaciones?, <b>303</b> ; De la idea al <i>abstract</i> : ¿Qué presentar y cómo preparar el envío de un trabajo a un congreso científico?, <b>304</b>	
Cerrando el telón.....	307
Fuentes de consulta para investigadores .....	307

## Capítulo 8

# MUESTRA Y ANÁLISIS CUANTITATIVO DE DATOS

*Lucas Gago-Galvagno*

Como se abordó en capítulos anteriores, la selección del tema de investigación, el marco teórico y los objetivos son cruciales para poder comenzar con el proceso del diseño metodológico (Sabino, 1987). Además, estos pasos previos delimitarán la población objetivo de nuestro estudio y el tipo de análisis de datos que llevaremos a cabo, tema del presente capítulo. Se hará una revisión narrativa sobre los principales conceptos que se asocian con el proceso de muestreo y de análisis de datos en metodología cuantitativa; se proveerán algunas conceptualizaciones en torno a la temática y se brindarán consideraciones prácticas para investigadores mediante ejemplos o bien explicitando tipos de tomas de decisiones durante estos procesos de selección de la muestra y de análisis de datos. De esta manera, se pretende que este capítulo pueda facilitar la toma de decisiones de dos procesos cruciales durante la ejecución de cualquier proyecto de investigación: el muestreo y el análisis de datos cuantitativos.

Se comenzará describiendo el proceso de muestreo dentro de un proyecto, los tipos que existen, en qué momento se emplea cada uno de ellos, el cálculo del tamaño muestral y algunas técnicas específicas. Además, se enumerarán los diferentes tipos de análisis de datos de la metodología cuantitativa, los distintos softwares para análisis de datos y sus principales características y ventajas; también haremos consideraciones éticas y de interpretación de los datos.

### ACERCA DEL MUESTREO

Cuando en Psicología nos referimos a la población, se hace referencia al conjunto de todos los sujetos que comparten ciertas carac-

terísticas similares. Debido a la dificultad de acceso a una población (generalmente por su tamaño), es que empleamos muestras, que son un subconjunto de individuos que conforman esa población. Nosotros como investigadores debemos conocer de la mejor manera posible cuáles son esas características de la población objetivo de nuestro estudio, de modo de reclutar una muestra que sea lo más equivalente posible a esta. El propósito es poder generalizar con el menor grado de error factible los resultados que obtengamos de nuestra muestra, a esa población. La validez externa se refiere precisamente a si nuestras conclusiones pueden extrapolarse de la muestra a la población (Hernández-Sampieri y Mendoza Torres, 2018; León-García y Montero García-Celay, 2003).

Para reclutar posibles participantes en una muestra debemos llevar a cabo un procedimiento llamado *muestreo*, que consiste en el proceso de seleccionar una parte lo más representativa posible de esa población. Este procedimiento es muy importante porque en él va a descansar gran parte de la validez externa. Esto no solo se debe al grado de probabilidad de generalizar nuestros resultados, sino también influyen otros factores: a) al error de muestreo, que es el nivel de error que existe entre el cálculo estadístico que hacemos con nuestra muestra y los parámetros reales de la población, y que podemos minimizar con un muestreo adecuado, b) el grado de control de nuestro estudio (llamado validez interna), ya que un muestreo inadecuado puede producir variables no controladas, c) la fiabilidad de los resultados, debido a que un muestreo inadecuado no permitiría que nuestros resultados sean estables a lo largo del tiempo y en diferentes contextos (Creswell y Creswell, 2022).

Además de que el proceso de muestreo es fundamental, se debe tener en cuenta a la hora de pensar en la factibilidad del estudio (i.e., qué tan posible es llevar a cabo la investigación que me propongo), su duración y el nivel de generalización que se va a tener de los resultados. Con respecto a la factibilidad, se podría afirmar que gran parte de esta en un estudio se asocia con la posibilidad de acceder a la muestra objetivo. Por ende, es fundamental que el equipo de investigación planifique la recopilación de datos en terreno o laboratorio de antemano, asegurándose de tener los permisos necesarios para realizar el análisis y poder evaluar a todos los participantes que se dispuso. Esto podrá variar en función de:

- el tipo de muestra (e.g., animal o humano),

- el rango etario de los participantes (e.g., el lector imaginará que no es lo mismo evaluar a estudiantes universitarios del instituto en donde trabaja que a neonatos),
- los permisos de ética e institucionales,
- el tipo de contactos que haya establecido, y
- la cantidad de criterios de inclusión y exclusión derivados de los objetivos de investigación (Creswell y Creswell, 2022; Sabino, 1987).

Por ejemplo, si quisiéramos evaluar una muestra de cuidadores primarios de infantes de 0 a 3 años, deberíamos tener en primer lugar permisos por parte de la universidad o instituto de investigaciones donde nos desempeñamos (junto al certificado de comité de ética que así lo homologue), de los directivos de la escuela y de los padres que participarán junto a ellos durante las evaluaciones. En los artículos de investigación siempre está explicitado este proceso de recolección y selección de la muestra, que es crucial para que el estudio pueda ser replicado y conocer de qué tipo de participantes se derivarán los resultados (Gago-Galvagno *et al.*, 2024a; Hicks, 2023).

### Tipos de muestreo

Básicamente en investigación hay dos tipos de muestreo, el probabilístico/aleatorio y el no probabilístico/no aleatorio. El probabilístico suele seguir el principio de equiprobabilidad, que afirma que todos los sujetos tienen la misma probabilidad de ser escogidos para formar parte de una muestra, siendo en consecuencia la selección de estos necesariamente por azar. En cambio, en los muestreos no probabilísticos, los participantes no tienen una probabilidad conocida de ser incluidos en la muestra, y se recluta a la misma por conveniencia o juicio de los investigadores, siendo este tipo de muestreo más económico y rápido, pero a la vez cuenta con menor validez externa (Creswell y Creswell, 2022; Hernández Sampieri y Mendoza Torres, 2018; León García y Montero García-Celay, 2003).

Existen varios subtipos de muestreos (ver Tabla 8.1). Dentro de los *probabilísticos*, están el *aleatorio simple* (i.e., se seleccionan al azar a los sujetos sin un criterio establecido), *sistemático* (i.e., se selecciona una constante numérica como punto de partida y luego se seleccionan elementos de la población a intervalos regulares), *por conglomerados* (i.e., se seleccionan al azar por zona geográfica) y

*estratificado* (i.e., selección aleatoria de diferentes estratos o características de la muestra). En cuanto a los *no probabilísticos*, se encuentran el *intencional/por conveniencia* (i.e., el investigador escoge a los participantes por conveniencia y en función de los objetivos de la investigación), *por cuotas* (i.e., se seleccionan a los participantes en función de ciertas características y como estas se distribuyen a nivel poblacional), *accidental* (se selecciona la muestra disponible desde un lugar geográfico específico) y *por bola de nieve* (en donde los mismos participantes refieren el contacto con otros participantes) (Hernández-Sampieri y Mendoza Torres, 2018; Lohr, 2022).

**Tabla 8.1.** Tipos de muestreos cuantitativos.

Probabilísticos	No probabilísticos
Aleatorio simple	Intencional o por conveniencia
Sistemático	Por cuotas
Por conglomerados	Accidental
Estratificado	Por bola de nieve

Como regla general para la toma de decisiones en investigación, se emplean *muestreos no probabilísticos* cuando:

- a) las muestras son de difícil acceso, ya sea porque están dispersas en diferentes zonas, o tienen características atípicas, o están cautivas en lugares específicos,
- b) se dispone de pocos recursos (temporales y económicos) para llevar a cabo la investigación,
- c) se quiere emplear un acercamiento exploratorio o descriptivo a una muestra determinada (Lohr, 2022).

Por otro lado, los *muestreos probabilísticos* se suelen emplear en los casos donde se desea poder generalizar los resultados de la muestra que será evaluada a la población objetivo (aumentando así la validez externa del estudio, es decir, la probabilidad de poder generalizar los resultados de la muestra a la población), y por ende tener mayor grado de certeza de que lo que concluya se pueda extrapolar a la población que se busca representar (León García y Montero García-Celay, 2003).

Independientemente del proceso de muestreo que se decida emplear, es fundamental que se registre pormenorizadamente el proceso de reclutamiento y evaluación de los participantes, así como los criterios de inclusión y exclusión, y otros posibles sesgos potenciales del tipo de participantes (por ejemplo, zona geográfica o nivel socioeconómico) que puedan atentar potencialmente con la validez de los resultados. Esto es crucial para aumentar la probabilidad de poder replicar el estudio, y conocer los posibles factores relativos a las características del diseño muestral y de los participantes que podrían estar contribuyendo a los resultados de forma diferencial. Esto se puede observar en muchos estudios transculturales o metaanálisis, en donde ciertas características de la muestra pueden influir hasta de forma contraria en los resultados principales encontrados (e.g., Lee *et al.*, 2024; Miller *et al.*, 2023).

### Acerca del tamaño muestral

Otra cuestión de importancia es la relativa al tamaño muestral. En la medida de lo posible, los investigadores deberían definir en sus proyectos de investigación la cantidad de sujetos que evaluarán *a priori*. Calcular el tamaño de una muestra es indispensable para saber en qué medida se pueden generalizar los resultados del testeo al resto de la población; también para conocer cuál es el poder estadístico de la muestra y si es capaz de detectar efectos significativos en los resultados. Para ello, se debe determinar el nivel de confianza deseado (en ciencias sociales suele establecerse en 95%), el nivel de significancia en una prueba de hipótesis ( $\alpha$ , que suele ser de .05 en nuestras disciplinas), el poder del estudio (la probabilidad de detectar un efecto cuando este realmente existe,  $1 - \beta$ , que suele establecerse en .80 o .90) y el tamaño del efecto esperado, que puede obtenerse analizando los tamaños del efecto previos obtenidos en los antecedentes sobre la temática (Lohr, 2022; Verma y Verma, 2020).

Para realizar el cálculo del tamaño muestral *a priori* se puede emplear el software estadístico G\*Power, calculadoras en línea, o los mismos softwares estadísticos que serán presentados en el presente capítulo, ya que cuentan con esta función. Cuando se apliquen pruebas de significación, deben incluirse el tamaño del efecto deseado para que se establezca cuál es el tamaño muestral mínimo para poder encontrar los efectos esperados (Liu, 2013; Verma y Verma, 2020). Es primordial considerar, además:

- a) la variabilidad de los datos, ya que a mayor variabilidad las muestras deberían ser más grandes,
- b) el tipo de análisis estadístico a realizar (e.g., una prueba de comparación de grupos requiere mayor cantidad muestral que una prueba de correlación),
- c) la posible pérdida muestral a la hora de la evaluación, que suele ser común en estudios longitudinales, de cohorte o con muestras de difícil acceso (Creswell y Creswell, 2022; Lee *et al.*, 2024).

Sin embargo, en los casos en que las muestras sean de difícil acceso, algunos autores pueden sugerir emplear estrategias *a posteriori*. Tal como su nombre lo indica, se realizan después de que se ha recogido y analizado un conjunto de datos. Al igual que el análisis *a priori* antes descripto evalúa si el tamaño de la muestra (en este caso, el que ya fue evaluado y se utilizará para el estudio) es suficiente para detectar un efecto de interés con la potencia deseada. En este análisis *a posteriori*, el procedimiento es similar, pero en vez de incluir el valor del poder del estudio (i.e.,  $1 - \beta$ ), se calculará el mismo a partir del tamaño muestral, el nivel de significancia, el tamaño del efecto observado, e información sobre la distribución de los datos, como media y desviación estándar. Si el poder es menor a .80, entonces la muestra empleada sería insuficiente para detectar el efecto esperado, y si es mayor a este valor, se podría deducir que el tamaño muestral es adecuado (Dziak *et al.*, 2020; Verma y Verma, 2020).

Si bien el análisis *a posteriori* de cálculo muestral es útil, muchos autores critican su uso (e.g., Dziak *et al.*, 2020; Gaskill y Garner, 2020), debido a que el valor de poder obtenido depende del tamaño del efecto observado en la muestra particular que fue evaluada, que puede variar en función del tipo de muestreo empleado. Además, cuando no se encuentra poder estadístico suficiente, puede que no sea porque la muestra es insuficiente, sino porque el verdadero efecto es pequeño o indetectable, lo cual sesga el resultado del poder estadístico. Por último, otros autores argumentan que el cálculo *a posteriori* implica una circularidad (e.g., Gaskill y Garner, 2020), ya que emplean los mismos datos que fueron medidos para justificar si estos son apropiados para justificar el tamaño muestral. En el artículo de Gago-Galvagno *et al.* (2022) se puede observar cómo varía el poder estadístico en función de un rango específico de tamaños del efecto, y es adecuado para una muestra de 75 participantes para un estudio

asociativo (Gago-Galvagno *et al.*, 2024b). Es necesario resaltar, en este ejemplo, que los tamaños del efecto y el poder estadístico pueden variar en función del alto grado de variabilidad comportamental que hay en esta muestra de infantes tempranos (Domínguez-Lara, 2018).

Es muy importante remarcar que *el tamaño de la muestra no asegura que los resultados puedan generalizarse a la población*. Aquí hay que diferenciar el tamaño muestral con el *tipo de muestreo empleado*. Tal como se explicó anteriormente, los muestreos probabilísticos permiten no caer en sesgos de selección de la muestra (al seguir el requisito de que las probabilidades sean conocidas) y además emplean principios estadísticos para estimar el grado de confianza y precisión de la generalización de los resultados. Sin embargo, un gran tamaño muestral no asegura la validez externa, aunque aumente la potencia estadística. Si bien aumentaría la probabilidad de generalizar los resultados de la muestra a la población, ya que aumenta la precisión estadística y reduce los sesgos de selección, esto no garantizaría la representatividad y generalización de los resultados, ya que el tipo de diseño empleado (en cuanto al tipo de estudio, muestreo y validez y confiabilidad de las técnicas de recolección de datos) es otro factor que se relaciona con la calidad de la investigación (Creswell y Creswell, 2022; Dziak *et al.*, 2020; Hernández-Sampieri y Mendoza Torres, 2018).

Una forma artificial de aumentar el tamaño muestral mediante la repetición de una serie de datos en distintas muestras es aplicando una técnica estadística llamada *bootstrapping*, que permite calcular un estadístico en muchas muestras generadas artificialmente llamadas muestras *bootstrap*, mediante remuestreo o *resampling*. Esta técnica es útil cuando se necesita una estimación más robusta de la variabilidad de un estadístico (Rousselet *et al.*, 2023). Es necesario resaltar igualmente que, aunque se generan muchas nuevas muestras de reemplazo, estas no son muestras reales que se suman a la evaluada, sino repeticiones de la original, que pueden ser convenientes en el caso de que sea costoso o inaccesible el acceder a un mayor número de participantes. El *bootstrapping* simularía la variabilidad que podría observarse si se tuvieran muchas muestras adicionales, pero con la limitación de su dependencia a la muestra original. Por ende, si la muestra inicial no es representativa de la población, las muestras *bootstrap* tampoco lo serán (Rousselet *et al.*, 2021, 2023). Finalmente, como se puede observar en el siguiente artículo de nuestro equipo de investigación (Gago-Galvagno *et al.*, 2023), antes de aplicar *bootstrapping*, es necesario especificar el método de muestreo,

el número de muestras y el índice y tipo de intervalo de confianza a emplear.

En cuanto al cuidado del tamaño muestral, la potencia estadística refiere a la capacidad de un estudio de poder identificar un efecto significativo cuando este realmente existe. El incremento de la potencia estadística reduciría la probabilidad de cometer error de tipo II (i.e.,  $\beta$ , probabilidad de no rechazar la hipótesis nula cuando esta es falsa), pero a su vez aumenta la probabilidad de que los resultados sean estadísticamente significativos, aumentando la probabilidad de cometer error de tipo I (probabilidad de rechazar la hipótesis nula cuando esta es verdadera). En este sentido, el equilibrio entre el poder estadístico y el nivel de significación (o nivel de confianza) nos puede ayudar a encontrar un tamaño muestral adecuado (ni demasiado grande al punto de imposibilitar la investigación, dado su costo; ni demasiado pequeño, que no consiga detectar el efecto existente) en un contexto específico. La preferencia por adoptar muestras grandes deviene de la posibilidad de controlar simultáneamente las probabilidades de ambos tipos de error (Creswell y Creswell, 2022; Hernández Sampieri y Mendoza Torres, 2018).

## PREPROCESAMIENTO Y TIPOS DE ANÁLISIS DE DATOS

Antes de empezar con el análisis de datos propiamente dicho, se realiza un preprocesamiento de estos. Una forma de hacerlo es mediante el análisis exploratorio de los datos (EDA), que incluye estadísticas de visualización y descripción de los datos. También, puede recurrirse exclusivamente a gráficos (e.g., histogramas y gráficos de cajas y bigotes) para analizar tendencias y anomalías en las bases de datos. Aquí también es importante realizar la prueba de normalidad y observar su respectivo gráfico, ya que nos permite identificar cómo se distribuyen los datos alrededor de la media y si existen datos extremos, junto con el tipo de forma de las variables evaluadas a través del índice de asimetría y curtosis (Botella Ausina *et al.*, 2012; Dabas, 2024).

En consonancia con lo anterior, hay que asegurarse de que la base de datos esté “ limpia” y organizada, es decir, establecer qué tipo de gestión se realizará con los datos perdidos (y explicitarla en el artículo de investigación), *outliers* (datos extremos que podrían perjudicar los resultados finales), y la integridad de los datos (puede ser

que haya datos mal pasados o respuestas inventadas derivadas de problemas con los participantes o los instrumentos). La limpieza de la base de datos es el proceso dentro del análisis de datos que más tiempo puede tomar al equipo de investigación y aún más cuando las bases de datos poseen múltiples variables y gran cantidad de sujetos (Botella Ausina *et al.*, 2012; Mannering *et al.*, 2020). Sin embargo, si el primer paso de procesamiento de los datos está bien realizado, hay mayor seguridad de que el análisis posterior de los datos demore menor cantidad de tiempo.

Una vez que se recolectaron los datos de la muestra propuesta es fundamental que los análisis que propongamos se ajusten a los objetivos de investigación, y que haya una coherencia interna entre los estadísticos que proponemos analizar y las preguntas de investigación que buscamos responder. Por otro lado, es importante conocer que el análisis de datos que se aplica (tal como se explicó con respecto al tamaño muestral en el apartado anterior) no garantiza la calidad metodológica o el alcance del estudio. Actualmente existen una diversidad de análisis de datos, siendo algunos de ellos muy sofisticados, pues toman múltiples variables simultáneamente en modelos estadísticos complejos. Sin embargo, esto no se relaciona directamente con el tipo de alcance de la investigación o su validez y confiabilidad. Este aspecto, nuevamente, está asociado con el tipo de diseño que se lleva a cabo (Dabas, 2024; Hernández-Sampieri y Mendoza Torres, 2018; Mannering *et al.*, 2020).

En metodología cuantitativa en ciencias sociales, el análisis de los datos puede dividirse en *análisis descriptivos* e *inferenciales* (Dabas, 2024). Con respecto al primero, se emplea para describir un conjunto de datos en cuanto a su frecuencia, medidas de tendencia central, medidas de dispersión, medidas de posición, forma de la distribución, y el empleo de distintos tipos de gráficos. Este tipo de análisis generalmente recae en variables de forma individual, por eso se los suele llamar *análisis univariados*. Todos ellos nos permiten resumir, organizar y visualizar la información para que aquellos que deseen revisar nuestras investigaciones puedan tener un rápido pantallazo de cómo se comportan las variables medidas en nuestra muestra (Botella Ausina *et al.*, 2012; Dabas, 2024; Hernández-Sampieri y Mendoza Torres, 2018).

Asimismo, en la estadística inferencial, y tal como vimos en el apartado de muestreo, se busca inferir con el menor grado de error posible de nuestra muestra evaluada a la población objetivo que queremos conocer. Aquí se emplean análisis entre dos variables, también

llamados *análisis bivariados*, que pueden ser relaciones correlacionales o causales (si se aplica un diseño experimental). Cabe aclarar que lo que define la causalidad de un estudio es el tipo de diseño que se propone, y no la técnica estadística empleada.

En los análisis bivariados tenemos los análisis de correlación, regresión lineal, y tablas de contingencia. Además, podemos analizar más de dos variables simultáneamente. A este tipo de análisis se lo denomina *multivariados*, y los principales representantes son el análisis factorial, la regresión múltiple, el análisis de componentes principales (PCA), y el análisis de varianza (ANOVA) (Creswell y Creswell, 2022; Preuss *et al.*, 2024; Sampieri *et al.*, 2018).

Se debe destacar que estos análisis descriptivos e inferenciales se realizarán en función de y en respuesta del tipo de objetivos propuestos en nuestro trabajo de investigación. Por ende, se recomienda fuertemente que las preguntas de investigación estén formuladas de forma clara y precisa, que se haya realizado la debida limpieza (como ya se explicó, descartando posibles *outliers* y tratando los valores perdidos) y transformación de los datos (transformación de tipo de variables, puntajes inversos, y puntajes Z si fuera necesario), y la validación de supuestos (a pesar de que son varios y en algunos casos dependen del tipo de estadístico que apliquemos, los principales son de normalidad, de homocedasticidad, de independencia, de linealidad y no colinealidad, de distribución de los errores, y de análisis factorial), que decantará en el tipo de análisis de datos que realicemos (Dabas, 2024; Preuss *et al.*, 2024).

Otro tipo de análisis de datos muy empleado actualmente es la estadística bayesiana. A diferencia de la estadística frecuentista en donde se estima la probabilidad de que los resultados hallados se deban al azar; en este tipo de estadística se utiliza el teorema de Bayes para ir actualizando la probabilidad de los resultados a medida que se va obteniendo nueva información. Básicamente, el investigador incorpora información previa (conocimientos previos o suposiciones), llamada “prior”, y esta información se actualiza con los datos observados. Aquí los parámetros son considerados variables aleatorias (por ejemplo, conocer la probabilidad de que se concluya una tarea con demanda cognitiva en determinado rango etario) (Martin *et al.*, 2024). Siempre es necesario establecer el valor *a priori* de probabilidad, el modelo de probabilidad, y el tipo de prueba de bayes (e.g., Gago-Galvagno *et al.*, 2021).

## Tipos de software para el análisis de datos

En cuanto a los softwares para análisis estadístico, es crucial conocer aquellas herramientas de análisis de datos que sean adecuadas para el tipo de datos que vamos a analizar y para el nivel de experiencia del equipo de investigación. Actualmente RStudio y Python son lenguajes de programación populares, gratuitos y de libre acceso, son flexibles y ofrecen una amplia gama de análisis de datos debido a la posibilidad que genera la codificación de comandos específicos y variados. Ambos lenguajes son adecuados para análisis estadísticos más avanzados y técnicas de modelado complejo, como *machine learning*, series temporales, aprendizaje automático, big data y minería de datos. Además, tienen una gran cantidad de recursos en línea, como foros, tutoriales y recursos educativos, lo que genera una comunidad de aprendizaje que facilita su uso. Sin embargo, es necesario tener en cuenta que en un principio la curva de aprendizaje para estos lenguajes de programación puede ser bastante elevada, y para sacar su máximo potencial es necesario algo de conocimiento en programación (Abbasnasab Sardareh *et al.*, 2021; Masuadi *et al.*, 2021).

Por otro lado, existen opciones pagas como SPSS o Stata. Ambos tienen una interfaz accesible y fácil de usar, y es altamente recomendado para aquellos que se inician en el análisis de los datos. Sin embargo, es un software costoso y esto puede reducir la accesibilidad al mismo. Además, es más limitado para realizar los análisis de datos más complejos que se mencionaron para RStudio y Python (Masuadi *et al.*, 2021). Un punto medio a estas dos propuestas serían JAMOVI y JASP, que también son accesibles y sencillos en su uso, pero cuentan además con interfaz con RStudio, son gratuitos y se actualizan constantemente a través de la amplia comunidad que los sostiene (Masuadi *et al.*, 2021).

Por último, si bien con los mencionados anteriormente se pueden realizar gráficos o tablas de muy buena calidad, otras opciones de softwares para este fin, dentro de las ciencias sociales, son Power BI y Tableau, que tienen una gran facilidad de uso, son intuitivas, ofrecen una gran variedad de gráficos, se pueden conectar con varias fuentes de datos diversas (como Excel y SQL) y son interactivas y dinámicas en cuanto permiten incluir variables en momento real y analizar cómo se modifican los datos de forma actualizada (Town y Thabtah, 2019).

En resumen, la elección del *software* más adecuado para realizar el análisis de datos dependerá de la familiaridad que el investigador

tenga con el mismo, el conocimiento que tenga sobre análisis de datos cuantitativos, las preferencias personales sobre el grado de usabilidad que percibe del programa y el tipo de análisis de datos que se deberán realizar.

### **Interpretación de los resultados y consideraciones éticas**

Una vez que poseemos los datos, es fundamental saber interpretarlos de forma adecuada y especialmente con cautela. Los resultados derivados de los análisis estadísticos deben ser pensados en el contexto del problema de investigación que se está proponiendo, y a la luz de las características de la muestra que fue evaluada y el tipo de instrumentos de recolección de datos utilizados. En este sentido, se deben evaluar los posibles sesgos o errores derivados de la metodología empleada, y a su vez realizar un proceso iterativo basándose en los hallazgos iniciales y los antecedentes de investigación. Aquí es donde el investigador plantea direcciones futuras, en las cuales se puede sugerir modificar alguna cuestión relativa al método, la muestra o los instrumentos, y así reajustar los resultados obtenidos, o analizarlos desde otra perspectiva (Botella Ausina *et al.*, 2012; Preuss *et al.*, 2024).

A su vez, los resultados deben ser presentados de manera clara y concisa, utilizando gráficos, visualizaciones y lenguaje adaptado para el público objetivo. Así se garantiza la comprensión de estos, y se atiene a una de las características fundamentales del conocimiento científico que refiere a su plausibilidad de ser comunicado (Botella Ausina *et al.*, 2012).

Además, es necesario resaltar la importancia de manejar los datos de forma ética, respetando la privacidad y confidencialidad de la información, cumpliendo con las leyes y regulaciones relacionadas con las formas de recopilar y utilizar los datos. En este sentido, los datos deben tener el respectivo consentimiento informado por parte de los participantes, deben estar almacenados de forma segura para protegerlos contra accesos no autorizados, y tiene que haber transparencia sobre la recopilación y uso de datos (Brown, 2023). Con respecto a este último punto, actualmente existen plataformas para compartir las bases de datos como Open Science Framework (OSF), Zenodo, Figshare y GitHub, entre otras. Compartir las bases de datos promueve la transparencia, permite que otros investigadores revisen el material, lo cual es fundamental para la integridad científica, y

la replicabilidad, ya que se puede observar con mayor detalle cómo fueron operacionalizadas las variables y qué rangos de respuesta se obtuvieron (Brown, 2023; Ramachandran *et al.*, 2021).

Asimismo, se produce mayor equidad de la información, porque está abierto a países en donde quizás hay mayor dificultad económica para producir datos. Esto es fundamental en el ámbito científico, ya que abre la posibilidad de una ciencia al servicio de la comunidad (ver Ciencia Ciudadana, Ramachandran *et al.*, 2021). Es necesario destacar que el compartir datos lleva también a generar alianzas entre investigadores, potenciando los resultados de investigaciones y expandiendo el alcance de las preguntas. También se pueden hacer pre-registros de artículos antes de ser enviados, en los cuales el equipo de investigación destaca los objetivos e hipótesis del estudio, el tipo de muestreo, los instrumentos y el procedimiento que se llevará a cabo.

Tanto compartir los datos como realizar pre-registros de los estudios puede disminuir la probabilidad de distintas prácticas antiéticas de análisis de datos, como manipulación deliberada de los datos, *p-hacking/fishing* (donde se realizan múltiples análisis y pruebas estadísticas hasta encontrar resultados que parecen significativos), ocultar resultados negativos, *cherry-picking* o selección sesgada de los datos, engaños en la visualización de los datos (e.g., exagerar las escalas de los gráficos en pos de la dirección de la hipótesis de investigación), plagio de datos y uso de modelos estadísticos sesgados o que no cumplen con los supuestos previos de modo de aumentar la probabilidad de un falso positivo (Andrade, 2021; Kline, 2023).

En síntesis, es fundamental llevar a cabo un proceso crítico de análisis de los datos para poder interpretarlos de forma cauta y realista, y así seguir generando líneas futuras de investigación que permitan continuar respondiendo preguntas. Además, es necesario que este proceso de análisis de datos sea realizado desde una perspectiva ética, siguiendo los principios del consentimiento informado, y compartir los datos, en caso de ser posible, en plataformas especializadas, de forma de reducir la posibilidad de ellos sean tratados de forma contraria a la ética.

## CONCLUSIÓN

El objetivo del capítulo fue reflexionar y generar consideraciones prácticas sobre los distintos tipos de muestreo y análisis de

datos, definiendo algunos de los conceptos principales y brindando ejemplos específicos y aplicaciones desde una revisión narrativa. Se destacaron cuestiones centrales para estos procesos como la selección de la muestra, los análisis *a priori* y *posteriori* para el cálculo del tamaño muestral, los distintos tipos de muestreo, el preprocesamiento de análisis de datos, los distintos métodos de análisis de datos, los softwares disponibles y la ética en manejo de los datos.

El muestreo sería esencial entonces para garantizar que los resultados que tenemos de nuestras investigaciones sean lo más representativos posibles teniendo en cuenta la población objetivo. Esto permitiría aumentar la validez externa de nuestro estudio, y a la vez parte de la validez interna o de control, ya que disminuiría las posibles variables contaminadoras del estudio. Sin embargo, en ocasiones tenemos que sacrificar un muestreo sofisticado en favor de tener un diseño factible, cuando no se cuentan con los recursos temporales y económicos para afrontar muestreos aleatorios. En este sentido, es necesario que los investigadores documenten todos los pasos de decisión que llevaron a cabo para recolectar la muestra, y los fundamentos por los cuales lo realizaron de esa manera y no de otra.

Por otro lado, existen técnicas de análisis de datos para describir e inferir. Las mismas serán empleadas en función del tipo de preguntas de investigación y los objetivos que tengamos. Tenemos tanto análisis univariados, bivariados y multivariados en función de la cantidad y la forma de evaluar las diferentes variables. Aquí también es fundamental reportar los pasos de selección del tipo de estadístico utilizado para cada análisis de datos, de modo que el lector pueda replicar y comprender detalladamente el tipo de decisiones que realizaron las investigaciones. En este sentido, el compartir las bases de datos en repositorios especializados (Open Science), realizar pre-registros de los estudios, siempre siguiendo los principios éticos y relativos al consentimiento informado, e interpretar los datos con cautela y sin generar sesgos, genera transparencia y aumenta la comunicabilidad y replicabilidad de la ciencia, aspectos que son centrales en el campo de las ciencias.

## Referencias bibliográficas

- Abbasnasab Sardareh, S., Brown, G. T., y Denny, P. (2021). Comparing four contemporary statistical software tools for introductory data science and statistics in the social sciences. *Teaching Statistics*, 43, S157-S172.
- Andrade, C. (2021). Harking, cherry-picking, p-hacking, fishing expeditions, and data dredging and mining as questionable research practices. *The Journal of Clinical Psychiatry*, 82(1), 25941.
- Botella Ausina, J., Suero Suñe, M., y Ximenes Gómez, M.C. (2012). *Análisis de datos en psicología I*. Pirámide.
- Brown, N. (2023). Research ethics in a changing social sciences landscape. *Research Ethics*, 19(2), 157-165.
- Creswell, J. W. y Creswell, J. D. (2022). *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches*. Sage.
- Dabas, P. (2024). *Descriptive and Inferential Statistics Using R*. Sultan Chand y Sons.
- Domínguez-Lara, S. (2018). Magnitud del efecto, una guía rápida. *Educación Médica*, 19(4), 251-254.
- Dziak, J. J., Dierker, L. C., y Abar, B. (2020). The interpretation of statistical power after the data have been gathered. *Current Psychology*, 39, 870-877.
- Gago-Galvagno, L. G., Miller, S. E., De Grandis, C. et al. (2021). Emerging coherence and relations to communication among executive function tasks in toddlers: Evidence from a Latin American sample. *Infancy*, 26(6), 962-979.
- Gago-Galvagno, L. G., Elgier, A. M. Mustaca, A. E. et al. (2024b). Acerca de los diseños de investigación en los estudios sobre desarrollo cognitivo en infancia temprana. Limitaciones y caminos futuros. En Sánchez-Ríos (Ed.), *Discusiones contemporáneas en psicología del desarrollo* (pp. 56-78). AscoFapsi.
- Gago-Galvagno, L. G., Elgier, A. M. et al. (2022). The universal child allowance and its relations with emotion regulation in early childhood. A behavioral study. *Ciencias Psicológicas*, 16(1), 1-14.
- Gago-Galvagno, L. G., Miller, S., Simaes, A. C. et al. (2024a). Importance of cultural context in the study of children's executive functions: Advances in Latin America research. *Child Development Perspectives*, 7, 1-8.
- Gago-Galvagno, L. G., Pérez, M. L., Justo, M. M. et al. (2023). Contributions of screen use on early language and development milestones in Argentinean toddlers from different socioeconomic contexts. *Trends in Psychology*, 1-18.
- Gaskill, B. N. y Garner, J. P. (2020). Power to the people: power, negative results and sample size. *Journal of the American Association for Laboratory Animal Science*, 59(1), 9-16.
- Hernández-Sampieri, R. y Mendoza Torres, C. P. (2018) *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Education.
- Hicks, D. J. (2023). Open science, the replication crisis, and environmental public health. *Accountability in Research*, 30(1), 34-62.
- Kline, R. B. (2023). Questionable practices in statistical analysis. En H. Cooper, M. N. Coutanche, L. M. McMullen et al. (Eds.), *APA Handbook of Research Methods in Psychology: Data Analysis and Research Publication* (2<sup>a</sup> ed., pp. 579-595). American Psychological Association.
- Lee, F., Gago-Galvagno, L., Castillo, M. del P. et al. (2024). Associations between screen exposure and children self-regulation: A systematic review and meta-analysis. *Revista Argentina de Ciencias del Comportamiento*, 16(2), 1-13.
- León García, O. G. y Montero García-Celai, I. (2003). *Metodologías científicas en Psicología*. Editorial UOC.

- Liu, X. S. (2013). *Statistical Power Analysis for the Social and Behavioral Sciences: Basic and Advanced Techniques*. Routledge.
- Lohr, L. S. (2022). *Sampling. Design and Analysis*. CRC Press.
- Mannering, F., Bhat, C. R., Shankar, V. et al. (2020). Big data, traditional data and the tradeoffs between prediction and causality in highway-safety analysis. *Analytic Methods in Accident Research*, 25, 1-16.
- Martin, G. M., Frazier, D. T., y Robert, C. P. (2024). Approximating Bayes in the 21st century. *Statistical Science*, 39(1), 20-45.
- Masuadi, E., Mohamud, M., Almutairi, M. et al. (2021). Trends in the usage of statistical software and their associated study designs in health sciences research: A bibliometric analysis. *Cureus*, 13(1), e12639.
- Miller, S. E., Gago-Galvagno, L. G., y Elgier, A. M. (2023). Universality and context-specificity in early executive function development. *Infant and Behavior Development*, 71, 101841.
- Preuss, M., Arruabarrena, L., Grupp, R. et al. (2024). *Manual de estadística aplicada a la psicología. Guía para estudiantes*. UAI Editorial.
- Ramachandran, R., Bugbee, K., y Murphy, K. (2021). From open data to open science. *Earth and Space Science*, 8(5), e2020EA001562.
- Rousselet, G. A., Pernet, C. R., y Wilcox, R. R. (2021). The percentile bootstrap: a primer with step-by-step instructions in R. *Advances in Methods and Practices in Psychological Science*, 4(1), 1-13.
- Rousselet, G., Pernet, C. R., y Wilcox, R. R. (2023). An introduction to the bootstrap: a versatile method to make inferences by using data-driven simulations. *Meta-Psychology*, 7, 1-24.
- Sabino, C. (1987). *Cómo hacer una tesis (Guía para elaborar y redactar trabajos científicos)*. Editorial Panapo.
- Town, P. y Thabtah, F. (2019). Data analytics tools: A user perspective. *Journal of Information y Knowledge Management*, 18(01), 1950002.
- Verma, J. P. y Verma, P. (2020). *Determining sample size and power in research studies*. Springer Singapore.