

MITOS EN LA INVESTIGACIÓN CUANTITATIVA

John Wesley Taylor V

Asociación General de los Adventistas del Séptimo Día, EE. UU.

La palabra “mito” proviene del griego (μῦθος) y refería a una historia tradicional (Oxford Living Dictionaries, 2018). A través del tiempo, sin embargo, el término cobró un segundo significado, el de una idea o creencia popular, pero errónea.

Tomada esa segunda definición, nos damos cuenta de que los mitos han existido, quizás desde el comienzo de la historia, y algunos han persistido aún —mitos de enormes pulpos marinos que atrapan naves enteras, de extrañas criaturas peludas que caminan como hombres. Y tenemos también mitos contemporáneos, como los que aparecen en las películas. ¿Será que también pueden existir mitos en la investigación? Determinadas ideas que podríamos pensar que son ciertas, aunque populares, son erróneas. En este artículo consideraremos varios de estos mitos. Algunos de ellos, de hecho, fueron identificados hace años (Campbell y Stanley, 1963; Robinson, 1970), pero persisten aún.

Mito N° 1: La investigación contesta toda pregunta.

¿Qué es la investigación? Si tomamos una definición formal, la investigación es una indagación sistemática, basada

en la recopilación y análisis de información, diseñada para desarrollar o contribuir al conocimiento generalizable (U.S. Department of Health and Human Services, 2009). Si realizamos “indagación sistemática” significa que estamos contestando preguntas, respondiendo a las incógnitas. El “conocimiento generalizable” apunta al hecho de que estamos buscando respuestas que van más allá de lo inmediato.

Podemos, sin embargo, hacer diferentes tipos de preguntas, tales como las siguientes:

1. ¿Cuál es el símbolo del hierro?
2. ¿Cuán bien domina Carlos los objetivos de esta materia?
3. ¿Cómo podemos transmitir nuestras prioridades estratégicas?
4. ¿Debería legalizarse el suicidio asistido por médico?

La primera pregunta lo contestamos por medio del aprendizaje. La segunda por un proceso de evaluación. La tercera al desarrollar algo, en este caso, una estrategia o proceso. La cuarta por medio de un análisis ético o de políticas.

El punto clave es que la investigación es tan solo un método para encontrar respuestas a los problemas que nos confrontan. Solamente un método entre varios, pero ciertamente un método importante.

Tenemos que reconocer que la investigación, aunque no omnipotente, puede también apoyarnos al considerar otras preguntas. Por ejemplo, enfocando el tema del suicidio asistido,

John Wesley Taylor V, PhD, Departamento de Educación de la Asociación General de la Iglesia Adventista del Séptimo Día, Silver Spring, MD, EE. UU.

La correspondencia concerniente a este artículo puede ser enviada a John Wesley Taylor V, correo electrónico: taylorjw@gc.adventist.org

la investigación nos puede ayudar a entender mejor, por ejemplo, los siguientes aspectos del tema:

- ¿Cuáles son las actitudes y creencias de los pacientes y de los proveedores de servicios de la salud con respecto al suicidio asistido?
- ¿Qué factores contribuyen a solicitar un suicidio asistido?
- ¿Cuál es la experiencia de las familias cuyos seres queridos optan por el suicidio asistido? (Be-yea y Nicoll, 1998).

Una conclusión, entonces, podría ser que, aunque la investigación no es un método suficiente para contestar toda pregunta, puede esclarecer el entorno de las varias preguntas que definimos como importantes.




Figura 1. Interpretando los datos.

Mito N° 2: Los datos hablan por sí solos.

Consideremos que nos encontramos con cuatro puntos como aparecen a principios de la Figura 1. ¿Qué representan? Obviamente los vértices de un cuadrado. ¿O será que definen un círculo? ¿O quizás algo intermedio? ¿O será una equis? ¿O una flecha? ¿Qué realmente representan esos cuatro puntos?



Figura 2. Los mismos datos. Dos perspectivas. Fuente: <http://www.wolfescape.com/Humour/NonMedPics/MarriageBeforeAfter.gif>

Nuestra conclusión se base en nuestra interpretación de los datos. O sea, los datos no hablan por sí mismos. Deberán siempre ser interpretados. Y esa interpretación está influida por nuestra cosmovisión, nuestra forma de ver y de hacer sentido de lo que nos rodea. Por eso, dos personas pueden mirar los mismos datos, la misma información en un estudio, y ver en ello patrones diferentes, porque los ven desde dos perspectivas diferentes (ver Figura 2).

Eso no significa de hecho que una de esas interpretaciones es necesariamente más válida que la otra, aunque en algunos casos ciertos argumentos pueden ser vistos como más robustos.

Mito N° 3: Una muestra mayor es mejor.

Frecuentemente se escucha que, cuanto mayor sea el número de participantes en la muestra, mejor será el estudio realizado. Hasta cierto punto esa postura tiene sentido. Muchas fallas en la investigación se derivan de la falta de un tamaño muestral suficiente, lo cual no nos permite sacar conclusiones válidas. Sobre ese punto comentaremos más en un mito siguiente.

Sin embargo, tenemos que reconocer que, al continuar aumentando el tamaño de la muestra, llegamos a una situación de rendimiento decreciente, en la cual lo

que recibimos del proceso es menor a lo que invertimos en ello. Perdemos eficiencia sin aumentar efectividad.

Quizás lo podríamos ilustrar de la siguiente manera. Imaginémosnos sentados en un bote sobre una pequeña laguna. La profundidad de la laguna es de 10 metros y la visibilidad desde la superficie de cinco metros. Desde el bote podemos mirar hacia abajo y percibir algunas características del fondo de esa laguna, características que se evidencian entre la superficie y cinco metros de profundidad. Pero no podemos percibir cómo es la topografía del lago más allá.

Solamente tenemos una herramienta a nuestra disposición para continuar esa exploración. Podemos prender una bomba que puede extraer agua del lago y, al hacerlo, el nivel del agua comienza a bajar. Nosotros, sentados en el bote sobre la superficie y siempre con una visibilidad de cinco metros, ahora comenzamos a distinguir nuevas características del fondo, aspectos que antes no veíamos.

Continuamos sustrayendo agua de la laguna hasta que la superficie está a cinco metros sobre el punto más profundo. Ahora podemos distinguir todas las características importantes de la topografía del fondo de ese lago. Hemos hecho descubrimientos importantes. Conocemos ahora lo que no sabíamos antes.

Pero imaginemos que continuamos el proyecto de extraer el agua. Aunque pudiéramos sacar todavía una buena cantidad de agua de la laguna, lo que podemos ver acerca de su topografía ya no nos presenta nueva información importante.

El agua extraída de la laguna representa la muestra. Con una muestra muy pequeña no descubrimos casi nada más allá de lo que ya sabíamos intuitivamente. Nuestros “hallazgos” no son nada

más que las cosas obvias que ya sabíamos antes de iniciar la investigación, lo que ya se miraba desde la superficie. Pero al ir aumentando el tamaño de la muestra, salimos de lo obvio y comenzamos a descubrir cosas de importancia, hallazgos que no se detectaban desde la superficie. Llega un punto, sin embargo, en el cual lo realmente importante ya se ha identificado y los pequeños detalles que ahora se revelan no son de gran relevancia. Hemos ya pasado de lo importante a lo trivial. Y cuando eso sucede, hemos perdido un retorno positivo. En un proyecto tal como la investigación, que deberá también ser parsimoniosa, hemos perdido eficiencia.

Además, tenemos que reconocer que el tamaño de la muestra es solamente parte de la ecuación. La representatividad es igualmente importante. Si aumentamos el tamaño de una muestra no representativa, parte de otro mito que veremos, nuestros resultados nunca serán más veraces.

Pero siendo representativa, ¿cuál entonces deberá ser el tamaño deseado de una muestra? Esa pregunta nos lleva al siguiente mito.

Mito N° 4: El tamaño mínimo de una muestra aceptable es un número mágico.

A veces, algunos, en un intento de facilitar el proceso, indican que la muestra deberá ser una proporción de la población, por ejemplo, el 10%. Pongamos a un lado, por el momento, la problemática de que muchas veces desconocemos en realidad el tamaño de la población. Si la población fuese de 10 personas, entrevistar 1 persona (el 10%) sería obviamente muy poco para sacar conclusiones confiables. Y si la población fuese de 10,000 personas, entrevistar 1,000

personas (nuevamente, el 10%) sería innecesariamente elevado y habremos gastado mucho tiempo y esfuerzo sin aumentar significativamente la confiabilidad de los resultados.

Con un deseo de agilizar el proceso, otros toman la postura de que el tamaño mínimo de la muestra es un cierto número fijo de participantes, tal como 100 personas. Si la población es de 50 personas, sin embargo, intentar obtener una muestra de 100 será imposible. Y si la población es de 10,000 personas, una muestra de 100 será estadísticamente significativa solamente para “hallazgos” de lo que ya era obvio sin realizar el estudio.

¿Qué deberemos, entonces, hacer para determinar el tamaño mínimo requerido de la muestra? Como respuesta, se utiliza un análisis de potencia. En cualquier estudio hay cuatro factores interrelacionados, de tal manera que cuando tres de ellos se establecen, el cuarto queda determinado por resultado. Estos cuatro factores son α , β , γ y n . En consecuencia, para determinar n , el tamaño mínimo de la muestra, necesitamos establecer α , β y γ . Los factores α y β tienen que ver con la probabilidad de errar, de enunciar una conclusión incorrecta. La γ tiene que ver con lo que el investigador considera de importancia, en contraposición a lo trivial.

Consideremos primero los errores de decisión, cuyas probabilidades límite se representan por α y β . Para ello, una analogía—la decisión de llevar o de no llevar un paraguas al salir de la casa. Si decido llevar un paraguas y luego llueve, tomé la decisión correcta. Pero si decido llevar paraguas y luego no llueve, he cometido un error de decisión (error tipo I, cuya probabilidad se relaciona con α). En forma alterna, puedo decidir

no llevar un paraguas. Si no llueve, estoy bien. Pero si llueve, nuevamente he cometido un error de decisión (error tipo II, cuya probabilidad se relaciona con β).

Cambemos la metáfora. Si soy médico y se me presenta un paciente con una cierta patología, tengo que tomar una decisión: ¿Debo darle un cierto medicamento o no? Si receto el medicamento y el medicamento es eficaz, he hecho bien. Pero si receto el medicamento y ese medicamento no es eficaz, he cometido un error de decisión. En caso contrario, si decido no recetar el medicamento y en realidad ese medicamento no tendría ningún efecto, hice bien. Pero si no receto el medicamento y en realidad el medicamento habría tenido un efecto positivo, cometí otro tipo de error de decisión.

En una investigación en la cual proponemos hipótesis, por ejemplo, también existen posibles errores. Si decidimos rechazar la hipótesis nula (y retenemos la alterna) cuando no deberíamos haberlo hecho, hemos cometido un error tipo I (un falso positivo). Y si decidimos no rechazar la hipótesis nula, cuando en realidad deberíamos haberlo hecho, hemos cometido un error tipo II (un falso negativo). En una investigación de esa naturaleza, α y β son las probabilidades que hemos definido como los límites aceptables de cometer errores tipo I y tipo II.

En una investigación queremos que tanto α como β sean pequeñas probabilidades (por ejemplo, no más de un 5% de probabilidad), pero también reconocemos que nunca podrán ser una probabilidad de cero, porque de ser así, nunca podríamos llegar a una conclusión. Debemos también reconocer que α y β se relacionan de forma inversa. Es decir, al intentar disminuir la probabilidad de

cometer un error, aumentamos la probabilidad del otro.

¿Qué significa todo esto? El coeficiente alfa tiene que ver con la significación estadística, con nuestro nivel de confianza. Generalmente, α se fija en .05 o en .01. Es decir, podemos tener una confianza razonable del 95% o el 99% al afirmar que existe una diferencia o una relación. Beta tiene que ver con la potencia, con la sensibilidad de la investigación. Generalmente, la potencia (1- β) se fija en .80 ó .90. Es decir, podemos estar razonablemente seguros de poder detectar una verdad que es al menos tan grande como el tamaño del efecto (γ) que hemos determinado.

Y eso nos lleva al tercer factor, el tamaño del efecto. El coeficiente gama tiene que ver con la importancia. Es la diferencia mínima o la relación mínima que nos será de valor práctico. Por ejemplo, una diferencia mínima se puede definir en términos de una proporción de σ . Un valor γ definido como $.3\sigma$, por ejemplo, indica que hemos

definido como importante cualquier diferencia mayor a la tercera parte aproximadamente de una desviación típica. Si hablamos de relaciones, la relación mínima que consideremos importante se puede definir en términos de varianza explicada. Un valor γ definido como r igual a .30, por ejemplo, representa un r^2 igual a .09, lo que significa que cualquier valor r que representa más del 9% de la varianza lo consideraremos como importante.

¿Cómo entonces determinamos el tamaño del efecto mínimo? Sencillamente al decidir cuál será la diferencia mínima o la relación mínima que nos será importante. Y esa decisión lo tomamos basado en teoría, en investigaciones previas, en la experiencia y en la lógica.

Hay, por supuesto, paquetes estadísticos que nos pueden ayudar en realizar este análisis. En una pregunta de diferencia, por ejemplo, el tamaño de la muestra (n) requerida en una prueba de dos colas, con una población infinita (o desconocida) y una potencia de .90, sería como lo muestra la Tabla 1.

Tabla 1

Tamaño de la muestra requerido para estudios comparativos según nivel de significación y tamaño del efecto

Nivel de significación	Tamaño del efecto				
	$\gamma = .5\sigma$	$\gamma = .3\sigma$	$\gamma = .25\sigma$	$\gamma = .2\sigma$	$\gamma = .1\sigma$
$\alpha = .05$	44	119	170	264	1050
$\alpha = .01$	63	168	241	374	1487

En cuanto a los resultados, diferencias de .5 o mayores probablemente serían bastante obvias antes de realizar un estudio. Al otro lado del continuo, diferencias de .1s probablemente no representan una diferencia de importancia práctica. Entre medio, encontramos los hallazgos no obvios, pero con importancia práctica.

En forma similar, para una pregunta de relación, el tamaño de la muestra requerida sería como lo muestra la Tabla 2.

Para una población dada, entonces, cuanto menor sea α , cuanto menor sea β (y mayor la potencia, 1- β) y cuanto menor sea γ (el tamaño del efecto que consideraremos importante), mayor

entonces deberá ser n , el tamaño de la muestra requerida.

En resumen, el tamaño de la muestra requerida no es un número mágico, tal como un número fijo para todo estudio

y una proporción de la población. Pero sí es un número específico determinado por un análisis de potencia, en el cual buscamos balancear α y β , tomando en cuenta γ .

Tabla 2

Tamaño de la muestra requerido para estudios correlacionales según nivel de significación y varianza explicada

Nivel de significación	Correlación/varianza explicada				
	$r = .5$ (25%)	$r = .4$ (16%)	$r = .3$ (9%)	$r = .2$ (4%)	$r = .1$ (1%)
$\alpha = .05$	38	62	113	258	1044
$\alpha = .01$	53	86	158	364	1477

Mito N° 5: Si algo es estadísticamente significativo, es importante.

Milgram (1967) propuso la teoría de los seis grados de separación, que indica que cualquier persona en el mundo no es más que seis relaciones de cualquier otra persona. Con el advenimiento de Facebook y otras redes sociales, se estima que ahora existen solamente cuatro grados de separación (Backstrom, Boldi, Rosa, Ugander y Vigna, 2012). ¿Conclusión? Todo está interconectado. Todo se relaciona.

Al mismo tiempo es lógico reconocer que no hay dos cosas idénticas en todas sus características. Es imposible, por ejemplo, que dos entidades tengan la misma forma y función, ocupando el mismo sitio al mismo tiempo. ¿Conclusión? Toda entidad es diferente en algo de toda otra entidad. O sea, en el mundo real, no hay dos cosas completamente iguales.

Por lo tanto, todo lo que existe está relacionado con, pero es diferente de, toda otra entidad. En consecuencia, si incrementamos el tamaño de la muestra hacia la infinidad, dos variables siempre

darán evidencia de una relación estadísticamente significativa. Y la diferencia entre dos categorías de una variable siempre será estadísticamente significativa. ¿Para qué, entonces, investigamos si todo tiene relación y todo tiene diferencia?

Tenemos que recordar primero que la significación estadística tiene que ver con la confianza, con el hecho que deseamos estar bastante seguros de que los resultados sean fidedignos.

Sin embargo, no toda diferencia o relación, aunque fidedigna, es de importancia práctica. Al evaluar, por ejemplo, una estrategia de enseñanza experimental con una muestra extensa es posible que podamos identificar una diferencia de rendimiento del 0.1% como estadísticamente significativa. Pero no es probable que esa sea diferencia importante, en términos del valor educativo o del costo del programa.

Es cierto que el valor p (la probabilidad del error tipo I, que da evidencia de confiabilidad o la carencia de ella) y el tamaño del efecto (γ) tienen cierta relación. La significación estadística es

necesaria, pero insuficiente, para poder hablar de importancia. O sea, es necesario establecer primero que algo sea fidedigno, para poder hablar de su importancia. Pero de que algo sea fidedigno ($p < .05$, por ejemplo), no necesariamente implica que sea de importancia práctica.

La confiabilidad de un resultado y la importancia de ese resultado son dos cosas diferentes. Con grandes muestras es probable que la gran mayoría de las relaciones o diferencias examinadas sean estadísticamente significativas, pero sin mirar el tamaño del efecto, uno no puede pronunciar que algo es importante. Ya que la significación estadística no equivale a importancia, debemos tener cuidado de no permitir que la fascinación científica de medir minucias con precisión nos distraiga de lo que es verdaderamente importante.

Mito N° 6: Si no hay significación estadística, puedo concluir que no hay diferencia o no hay relación.

Si no encuentro una diferencia estadísticamente significativa, ¿será que puedo declarar que no hay ninguna diferencia? Y si no encuentro una relación estadísticamente significativa, ¿podré entonces declarar que no hay ninguna relación?

Como hemos mencionado, la significación estadística nos da confianza de que los resultados sean fidedignos. Por ente, cuando no se alcanza significación, no tenemos confianza en la fidelidad de los resultados.

Cuando un proceso estadístico no devuelve una probabilidad de error tipo I menor al límite de error que hemos definido (es decir, $p < \alpha$), ¿qué podemos concluir? Pues, ¡nada! No se puede hacer ninguna conclusión sobre el tema si los resultados sobre los cuales se funda-

mentaría esa conclusión no son fidedignos. ¿Qué diremos entonces? Lo único que podemos enunciar es que los resultados no son conclusivos.

¿A qué se debe esa situación? Si hice bien el análisis para determinar el número mínimo requerido para la muestra y si obtuve ese tamaño de muestra, los procesos estadísticos me dan una buena probabilidad (por ejemplo, una potencia de 90%) de que se han detectado las relaciones o las diferencias mayores a gama (el tamaño del efecto mínimo que será de importancia práctica). Pero más comúnmente, los “resultados no conclusivos” se deben a que la muestra fue demasiada pequeña, menor de lo que un análisis de potencia hubiera requerido como mínimo. ¿La solución? Para investigaciones a futuro, asegure obtener el número mínimo requerido para la muestra según lo indica un análisis de potencia.

Mito N° 7: Si encuentro diferencia significativa entre A y B, y A es mayor que B, puedo decir que A es mayor que B en general.

Por ejemplo, cuando encuentro en mi estudio una diferencia estadísticamente significativa entre la habilidad lingüística de niños y niñas, favoreciendo las niñas, ¿será que podré declarar que las niñas, en general, tienen mayor habilidad lingüística que los niños?

Cuando obtengo una muestra, esa muestra debe ser representativa de una población dada. La mejor forma de asegurar que sea representativa en sus varios aspectos es teniendo un número suficiente en la muestra, como hemos comentado, y empleando un proceso aleatorio para derivar esa muestra de la población. Sin embargo, lo que considero como población es realmente el

marco de muestreo (todos los niños de preescolar de un determinado pueblo, por ejemplo).

Al tener una muestra representativa, puedo entonces generalizar con confianza mis conclusiones a ese marco de muestreo (ver Figura 3). El problema, sin embargo, es que muchas veces me gustaría generalizar a la población total, es decir, a todos los niños de preescolar que existan. Pero eso es algo que no puedo hacer, sencillamente porque no sé si los niños de preescolar de ese pueblo dado son representativos de todos los niños de preescolar en general. Y probablemente no hay manera de saberlo. Si intento generalizar a una población total, de la cual mi muestra no es representativa, he cometido un error de sobre-generalización. ¿Qué puedo decir entonces? Si la muestra fue representativa, puedo decir que A es mayor que B en la población (marco de muestreo) de mi estudio, solamente. ¿Qué no puedo decir? Que A es mayor que B, para todos los A y B en general.

De paso, ¿qué ocurre si no pude obtener una muestra aleatoria?

Entonces la muestra no es representativa de nada y no puedo generalizar. Únicamente puedo comentar sobre las características de ese grupo de individuos que participaron en el estudio, pero eso no tiene mucho sentido porque no se extiende más allá. Y una investigación deberá resultar en conocimiento generalizable.

Mito N° 8: Si encuentro una relación entre X e Y, puedo decir que X influye en Y.

Si encuentro que el 99% de los adictos a la heroína bebieron leche como niños, ¿puedo concluir que beber leche influye en la adicción? Si encuentro que

existe una fuerte relación entre años de estar casado y mortandad, ¿será que puedo concluir que el matrimonio es causa de muerte? Obviamente esas posturas nos parecen extravagantes, pero solamente porque sabemos mejor. ¿Pero qué ocurre cuando no sabemos?




Figura 3. El problema de la generalización.

Una correlación es necesaria, pero insuficiente para establecer causalidad. En otras palabras, toda causalidad debe ser basada en una correlación subyacente, pero no podemos concluir causalidad simplemente porque hemos encontrado correlación. ¿Por qué?

En primer lugar, muchas veces desconocemos la dirección de la relación. Imagínesse que por primera vez nos

encontramos con un molino de viento. Observando detenidamente, nos damos cuenta de que la velocidad de rotación del molino de viento y la velocidad del viento se correlacionan. Una posible conclusión basado en los datos podría ser que los molinos de viento son enormes abanicos que producen viento. Cambiando la ilustración, imagínese que nos encontramos con un automóvil chocando contra un árbol. El vehículo tiene un neumático reventado. ¿Será que el choque produjo el reventón? ¿O será que el reventón produjo el choque? El punto clave es que, llegando después del hecho, ambas opciones podrían ser viables.

Otra consideración es la posible influencia de una tercera variable. En una investigación, por ejemplo, observamos que a medida que la venta de helados aumenta y decae en el transcurso del año, la tasa de muerte por ahogamiento también se eleva y decae en forma similar. Podríamos ser tentados a concluir que el consumo de helados precipita el ahogamiento. En realidad, ambos índices se incrementan y decaen porque estamos entrando y saliendo del verano, y el cambio de la temperatura ambiental influye tanto en el consumo de helados, como en la probabilidad de que las personas estén nadando, y por ende, con la posibilidad de ahogarse.

Dadas esas circunstancias, ¿qué podemos decir entonces cuando nos encontramos con una correlación? Podemos pronunciar que X se relaciona con Y. O simplemente, que hay una correlación entre X y Y. Lo que no podemos declarar es que una de las variables precipita, produce o conlleva la otra variable. Tampoco podemos hablar de impacto, efecto o influencia. Ni sobre resultado o consecuencia.

Mito N° 9: La investigación confirma. La investigación ha comprobado.

Si queremos certeza, es decir, total confianza, tendríamos que fijar α igual a .000. Y si fijamos α en .000, siempre encontramos que p será mayor que α , indicando que no hay significación estadística. Por lo tanto, como hemos visto, lo único que podremos decir es que los resultados son no conclusivos.

Si fijamos α en algún otro valor, tal como .05, entonces habrá una probabilidad hasta el 5% de que nuestra conclusión pudiera ser incorrecta, aun cuando hemos alcanzado significación estadística.

Como resultado, en la investigación nunca comprobamos ni confirmamos nada. Vivimos científicamente en un mundo de probabilidades y de posibilidades, no de certezas.

Ciertamente, los hallazgos de la investigación pueden proveer apoyo a una premisa. Sin embargo, una teoría nunca será completamente comprobada. De hecho, una teoría exitosa es meramente una que ha sido probada y que, por el momento, se ha escapado de ser no confirmada (Robinson, 1970).

Para decirlo de otra forma, los resultados de la investigación ponen a prueba, pero nunca comprueban una teoría. La investigación no provee respuestas absolutas. Nunca habrá en la investigación una palabra final, solamente habrá la palabra más reciente, que esperamos apunte en una dirección correcta. Con solamente recorrer la historia serpenteante de la ciencia, nos damos cuenta de que los resultados de la investigación no son garantía de conocimiento verdadero (DeWitt, 2018).

Conclusión

Con tantos mitos que pueden atraparnos en la investigación, ¿qué podemos

hacer? El problema fundamental radica comúnmente en nuestro deseo innato de ser algo más allá de lo que realmente somos, de decir algo más abarcante y puntual de lo que podemos legítimamente decir.

Nuestro círculo de conocimiento está rodeado por el vasto universo de nuestra ignorancia, por todo lo que desconocemos. El problema es que, en cuanto a la mayor parte de ese universo, desconocemos que no lo conocemos. De hecho, lo único que nos damos cuenta que desconocemos son los puntos de ese universo que tocan el perímetro de nuestro círculo de conocimiento (ver Figura 4).



Figura 4. Lo que conocemos y desconocemos.

Cuando el círculo es pequeño, también el perímetro es pequeño. Somos tentados a pensar que, aunque hay todavía algunas cosas contadas que desconocemos, ya casi lo sabemos todo. Sin embargo, a medida que aprendemos cosas nuevas, inclusive por la investigación, el círculo de nuestro conocimiento aumenta. Pero también el perímetro se va ampliando. Y cuando eso sucede, comenzamos a toparnos con más y más de lo que aún desconocemos.

Por eso, una investigación genera más preguntas que las que responde. Y por eso también, cuanto más aprendemos, más nos damos cuenta cuánto desconocemos. Y más mansos y humildes seremos.

Notas

¹Por ejemplo, la secuela de Star Wars “The Force Awakens”, “Man of Steel” y “Wonder Woman”.

²Por ejemplo: UnifyPow (un modulo freeware de SAS disponible en <http://www.bio.ri.ccf.org/>

power.html), PASS (del NCSS Statistical Software en <https://www.ncss.com/software/pass/>), Power and Precision (<https://www.power-analysis.com/>), PWR en R (<https://CRAN.R-project.org/package=pwr>) y Sample Power del SPSS, como también una calculadora JAVA applet (<https://homepage.divms.uiowa.edu/~rlenth/Power/>).

³Cohen (1977), por ejemplo, definió los tamaños del efecto como grandes, medianos y pequeños [Cohen, J. (1977). *Statistical power analysis for the behavioral sciences*. New York: Academic Press]. Los tamaños del efecto definidos como “grandes” tienden a ser los que son bastante obvios, aun antes de realizar la investigación. Los tamaños definidos como “pequeños” tienden a caer en la frontera de lo trivial, mientras que los tamaños “medianos” del efecto son los que poseen valor práctico y que probablemente obviaríamos sin haber realizado la investigación.

⁴Algunos investigadores comentan algo así, “En la medida en que el marco de muestreo en este estudio pueda ser representativo de la población total, las conclusiones del estudio pueden ser aplicables a la población general.” Pero esa postura le impone la responsabilidad de generalización al lector, que tampoco está en una mejor posición para determinar si el marco de muestreo es o no es representativo de la población global.

⁵Algunos proponen que se pueda utilizar una muestra estratificada para garantizar que la muestra sea representativa de una población. Sin embargo, uno puede igualar proporciones solo sobre un número muy limitado de factores. En consecuencia, no se sabe si la muestra es representativa en términos de otros factores no considerados en el proceso de estratificación, que también podrían ser importantes para el tema considerado.

Referencias

Backstrom, L., Boldi, P., Rosa, M., Ugander, J. y Vigna, S. (2012). Four degrees of separation. En *WebSci '12 Proceedings of the 4th Annual ACM Web Science Conference* (pp. 33-42). New York: ACM.

Beyea, S. C. y Nicoll, L. H. (1998). Dispelling the myth that research answers all questions. *AORN Journal*, 68(6), 1044-1047. doi:10.1016/S0001-2092(06)62145-5

Campbell, D. T. y Stanley, J. C. (1963). Experimental and quasi-experimental design for research in teaching. En N. L. Gage (Ed.), *Handbook of research in teaching: A project of the American Educational Research Association* (capítulo 5). Chicago: Rand McNally.

Cohen, J. (1977). *Statistical power analysis for the behavioral sciences*. New York: Academic Press.

- DeWitt, R. (2018). *Worldviews: An introduction to the history and philosophy of science*. Hoboken, NJ: John Wiley & Sons.
- Milgram, S. (1967). The small world problem. *Psychology Today*, 1(1), 61-67.
- Oxford Living Dictionaries. (2018). *Myth*. Recuperado de <https://en.oxforddictionaries.com/definition/myth>
- Robinson, G. (1970). Exploring some myths in research design. *The Journal of School Health*, 40(7), 335-338. doi:10.1111/j.1746-1561.1970.tb05618.x

U.S. Department of Health and Human Services, The Office for Human Research Protections. (2009). *Code of Federal Regulations, Title 45, Part 46, Section 102(d)*. Recuperado de <https://www.hhs.gov/ohrp/regulations-and-policy/regulations/45-cfr-46/index.html>

Recibido: 8 de abril de 2017

Revisado: 2 de mayo de 2017

Aceptado: 13 de junio de 2017